

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE CIÊNCIAS AGRÁRIAS

VALIDAÇÃO EXTERNA DAS ESTIMATIVAS DE
COMPOSIÇÃO QUÍMICA E DE EQUAÇÕES DE
PREDIÇÃO DA ENERGIA METABOLIZÁVEL DO MILHO
PARA SUÍNOS UTILIZANDO DIFERENTES NIRS

Autora: Ana Carolina de Figueiredo

Orientador: Prof. Dr. Paulo Cesar Pozza

MARINGÁ
Estado do Paraná
Fevereiro-2022

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE CIÊNCIAS AGRÁRIAS

VALIDAÇÃO EXTERNA DAS ESTIMATIVAS DE
COMPOSIÇÃO QUÍMICA E DE EQUAÇÕES DE
PREDIÇÃO DA ENERGIA METABOLIZÁVEL DO
MILHO PARA SUÍNOS UTILIZANDO
DIFERENTES NIRS

Autora: Ana Carolina de Figueiredo

Orientador: Prof. Dr. Paulo Cesar Pozza

Dissertação apresentada, como parte das exigências para obtenção do título de MESTRE EM ZOOTECNIA, no Programa de Pós- Graduação em Zootecnia da Universidade Estadual de Maringá - Área de Concentração Produção Animal

MARINGÁ
Estado do Paraná
Fevereiro-2022

Dados Internacionais de Catalogação-na-Publicação (CIP)
(Biblioteca Central - UEM, Maringá - PR, Brasil)

F475v

Figueiredo, Ana Carolina de

Validação externa das estimativas de composição química e de equações de predição da energia metabolizável do milho para suínos utilizando diferentes NIRS / Ana Carolina de Figueiredo. -- Maringá, PR, 2022.

x, 64 f.: il., figs., tabs.

Orientador: Prof. Dr. Paulo Cesar Pozza.

Dissertação (Mestrado) - Universidade Estadual de Maringá, Centro de Ciências Agrárias, Departamento de Zootecnia, Programa de Pós-Graduação em Zootecnia, 2022.

1. Suínos - Nutrição. 2. Milho (*Zea mays* L.). 3. Energia metabolizável. 4. Espectroscopia de reflectância no infravermelho próximo (NIRS. I. Pozza, Paulo Cesar, orient. II. Universidade Estadual de Maringá. Centro de Ciências Agrárias. Departamento de Zootecnia. Programa de Pós-Graduação em Zootecnia. III. Título.

CDD 23.ed. 636.4



UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE CIÊNCIAS AGRÁRIAS

VALIDAÇÃO EXTERNA DAS ESTIMATIVAS DE
COMPOSIÇÃO QUÍMICA E DE EQUAÇÕES DE PREDIÇÃO
DA ENERGIA METABOLIZÁVEL DO MILHO
PARA SUÍNOS UTILIZANDO DIFERENTES NIRS

Autora: Ana Carolina de Figueiredo
Orientador: Prof. Dr. Paulo Cesar Pozza

TITULAÇÃO: Mestre em Zootecnia - Área de Concentração Produção
Animal

APROVADA em 24 de fevereiro de 2022.

Prof. Dr. Newton Tavares
Escocard de Oliveira

Prof. Dr. Ricardo Vianna Nunes

Prof. Dr. Paulo Cesar Pozza
Orientador

*“Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito.
Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes”.*

(Marthin Luther King)

AGRADECIMENTOS

A Deus, por permitir minha existência e por toda resiliência que adquiri.

À Universidade Estadual de Maringá, por ter-me possibilitado desenvolver este trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa de estudos.

Ao Prof. Dr. Paulo Cesar Pozza, pela dedicada orientação, ensinamentos, estímulo e pela paciência.

Ao Departamento de Zootecnia, e os professores do Programa de Pós-Graduação em Zootecnia, da UEM, pelos valiosos ensinamentos.

Aos funcionários do laboratório pelo auxílio na realização das análises e aos funcionários da Fazenda Experimental de Iguatemi- FEI que me auxiliaram no manejo dos animais.

Aos meus pais Marcia Machado e Sebastião Santos de Figueiredo, por todo incentivo e apoio.

Ao meu noivo Daniel Mareze da Costa, seus pais Silvio Cláudio da Costa e Cecília Edna Mareze da Costa pelo apoio e compreensão.

Aos membros do Grupo de Suinocultura que me ajudaram muito com a realização do experimento.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho.

Aos meus avós, Antonia e Gumercindo (*in memoriam*),
por todo amor e carinho a mim dispensado,

DEDICO

BIOGRAFIA

ANA CAROLINA DE FIGUEIREDO, filha de Sebastião Santos de Figueiredo e Marcia Machado, nasceu em Bauru, São Paulo, no dia 20 de dezembro de 1994.

Em março 2014, iniciou o curso de Zootecnia pela Universidade Estadual de Londrina, concluindo o mesmo em dezembro de 2018.

Em março de 2019, iniciou o Programa de Pós-Graduação em Zootecnia, em nível de Mestrado, área de concentração Produção Animal, na Universidade Estadual de Maringá, realizando estudos na área de nutrição de suínos.

No dia 24 de fevereiro de 2022, submeteu-se à banca para defesa da Dissertação.

ÍNDICE

LISTA DE TABELAS.....	vii
LISTA DE FIGURAS.....	viii
RESUMO.....	ix
ABSTRACT.....	x
I - INTRODUÇÃO.....	1
REVISÃO DE LITERATURA	2
1. Características fisiológicas do milho	2
2. Importância da cultura do milho	3
3. Produção de milho no Brasil	5
4. Diferenças entre os milhos	6
5. Energia consumida pelos suínos	8
6. Equações de predição para estimar a energia metabolizável	10
7. A espectroscopia de reflectância no infravermelho próximo – NIRS	12
8. Principais diferenças entre equipamentos NIRS	14
REFERÊNCIAS	16
II - OBJETIVO GERAL	22
III - EXTERNAL VALIDATION OF CHEMICAL COMPOSITION ESTIMATES OF CORN USING DIFFERENT NIRS EQUIPMENTS.....	23
ABSTRACT.....	23
RESUMO.....	24
INTRODUCTION.....	25
MATERIAL AND METHOD	26
RESULTS AND DISCUSSION	28
CONCLUSION.....	39
REFERENCES.....	39
IV - PREDICTION OF THE METABOLIZABLE ENERGY OF CORN FOR SWINE USING NEAR INFRARED REFLECTANCE SPECTROSCOPY - NIRS	42
ABSTRACT.....	43
RESUMO.....	44
INTRODUCTION	45
MATERIAL AND METHOD	46
RESULTS AND DISCUSSION	50
CONCLUSION.....	61
REFERENCES.....	62

LISTA DE TABELAS

Table 1. Chemical composition of corn cultivars obtained by analytical methods, in dry matter.....	30
Table 2. Precision, strictness, and accuracy indices of prediction models of the chemical composition of corns measured in the laboratory as a function of the chemical composition estimated by different NIRS for dry matter (DM), crude protein (CP), ether extract (EE), mineral matter (MM), crude fiber (CF) and non-nitrogen extractive (NNE), based on dry matter ¹	33
Table 3. Precision, strictness, and accuracy indices of prediction models of the chemical composition of corns measured in the laboratory as a function of the chemical composition estimated by the four different NIRS for starch (STA) and organic matter (OM) on a dry matter basis ¹	38
Table 1. Composition of the reference feed in natural matter.....	47
Table 2. Prediction equations used to estimate corn ME.....	49
Table 3. Minimum, maximum, mean, and standard deviation (SD) of the chemical composition of corn cultivars predicted by the four different NIRS equipment in dry matter.....	50
Table 4. Energy values, energy metabolizability coefficients, and energy digestibility coefficients of different types of corn for swine, expressed in natural matter.....	51
Table 5. Mean values, standard deviations, minimum and maximum values, coefficients of variation, and metabolizable energy values estimated by twenty different equations, considering chemical composition values estimated by different NIRS equipment, expressed in dry matter.....	53
Table 6. Lack of correlation weighted by the standard deviations (LCS), squared difference between standard deviations (SDSD) and squared Bias (SB), between observed and predicted values of metabolizable energy based on chemical composition estimated by different NIRS equipment as regressor variables.....	56

LISTA DE FIGURAS

- Figure 1. Mean mean squared deviation (MSD) between the values found in the metabolism assay, predicted by equations (MEx) with regressors determined by different NIRS equipment.....58
- Figure 2. Graphic representation between the observed metabolizable energy (OBS ME) and the metabolizable energy predicted by the best prediction equations (MEx), based on chemical composition estimates obtained by different NIRS equipment.....60

RESUMO

O objetivo deste trabalho foi o de validar as estimativas de composição química e equações de predição da energia metabolizável do milho para suínos, utilizando diferentes NIRS (espectroscopia de refletância no infravermelho próximo). Este estudo foi realizado em duas etapas: Etapa 1: validar as leituras de composição química dos NIRS com os resultados observados obtidos em laboratório, para isso, foi aplicado o modelo de regressão, para a matéria seca (MS), proteína bruta (PB), extrato etéreo (EE), matéria mineral (MM), fibra bruta (FB), extrativo não nitrogenado (ENN), amido (AMI) e matéria orgânica (MO). A melhor predição da composição química foi obtida pelo NIRS 2, seguido pelos NIRS 1 e 4, e por último e menos preciso, está o NIRS 3. Etapa 2: foi realizado um ensaio de digestibilidade para determinar o valor nutricional de diferentes cultivares de milho. Foram utilizados 44 suínos, machos castrados, distribuídos em delineamento experimental de blocos ao acaso com 10 tratamentos e quatro repetições. Os tratamentos consistiram em 10 cultivares de milho, que substituíram em 25% a ração referência, o método de coleta total foi utilizado para determinar os valores de energia metabolizável (EM). Para estimar os valores EM foram utilizadas 20 equações de predição extraídas da literatura. As estimativas de EM ao utilizar as equações de predição, para os 10 milhos avaliados, foram avaliadas mediante determinação do desvio padrão (DV) e coeficiente de variação (CV) e pela abordagem baseada no quadrado médio do erro de predição (QMEP) em relação aos valores de EM observados. Os valores de energia digestível (ED) e energia metabolizável (EM) variaram de 3.360 a 3.596 e de 3.332 a 3.541 kcal/kg, respectivamente, e os coeficientes de digestibilidade e metabolizabilidade da EB apresentaram variação de 84,70 a 91,73% e 84,15 a 90,98%. A relação EM:ED variou de 0,97 a 0,99. Neste trabalho a melhor equação de predição foi a $EM_6 = 16482 - 35,7FB$, que apresentou o menor QMEP, e com relação as equações que melhor estimaram a EM para todos os NIRS destacam-se a $EM_9 = 16,81 - 0,031FB$ e a $EM_{18} = 3675,39 + 50,02EE - 25,62FB$.

Palavras-chave: energia metabolizável, equação de predição, milho, NIRS, suínos

ABSTRACT

The objective of this study was to validate the chemical composition estimates and prediction equations of corn metabolizable energy for swine using different NIRS (near infrared reflectance spectroscopy). This study was carried out in two stages: Step 1: validate the NIRS chemical composition readings with the results obtained in the laboratory, for which the regression model was applied, for dry matter (DM), crude protein (CP), ether extract (EE), mineral matter (MM), crude fiber (CF), non-nitrogen extract (NNE), starch (STA) and organic matter (OM). The best prediction of chemical composition was obtained by NIRS 2, followed by NIRS 1 and 4, and last and least accurate is NIRS 3. Stage 2: a digestibility assay was carried out to determine the nutritional value of different maize cultivars. Forty-four barrows were used, distributed in a randomized block design with 10 treatments and four replications. The treatments consisted of 10 maize cultivars, which replaced by 25% the control diet and the collection method was used to determine the metabolizable energy (ME) values. To estimate the ME values, 20 prediction equations extracted from the literature were used. The ME estimates using the prediction equations, for the 10 evaluated corns, were evaluated by determining the standard deviation (SD) and coefficient of variation (CV) and by the approach based on the mean squared deviation (MSD) in relation to the observed EM values. The digestible energy (DE) and metabolizable energy (ME) values ranged from 3,360 to 3,596 and from 3,332 to 3,541 kcal/Kg, respectively, and the digestibility and metabolizability coefficients of GE ranged from 84.70 to 91.73%. and 84.15 to 90.98%. The ME:DE ratio ranged from 0.97 to 0.99. In this study, the best prediction equation was $EM_6 = 16482 - 35.7CF$, because it presented the lowest MSD, and in relation to the equations that best estimated the EM for all NIRS, the highlight is $ME_9 = 16,81 - 0,031CF$ and $ME_{18} = 3675,39 + 50,02EE - 25,62CF$.

Keywords: chemical composition, corn, metabolizable energy, NIRS, pigs

I - INTRODUÇÃO

O Brasil, atualmente, ocupa a quarta posição no ranking de produção de carne suína no mundo, com 3,88% da produção global, em que 16% do total produzido têm destino internacional, sendo China, Hong Kong e Chile, os principais importadores (Nascimento, 2020).

A alimentação representa a maior fração do custo de produção de suínos e o milho é o principal ingrediente da alimentação, representando 75% dos ingredientes da ração. O custo de produção teve aumento expressivo em 2020 pelos aumentos no valor dos insumos, e conseqüentemente o valor da carne para o consumidor final. (EMBRAPA, 2020).

Desta forma, para se obter bom retorno é necessário atender às exigências nutricionais dos animais e, ao mesmo tempo, formular rações economicamente viáveis. Para tanto, é fundamental o conhecimento da composição química e energética dos ingredientes utilizados nas dietas, principalmente do milho, pois sua composição química apresenta variações (Li et al., 2014).

Dentre os fatores que contribuem para a variação na composição físico-química do milho, estão: a variabilidade genética das sementes, as condições de cultivo, processamento, estocagem e moagem pós-colheita, podendo interferir diretamente no valor nutricional, e proporcionar diferentes efeitos sobre o desempenho e características dos suínos (Zanotto et al., 2015).

O procedimento utilizado para determinar a composição química dos alimentos era realizado por meio de análises laboratoriais. O substituto mais utilizado atualmente é a espectroscopia de refletância no infravermelho próximo (NIRS), uma ferramenta de previsão rápida e econômica, muito utilizada nas indústrias (Wajizah; Munawar, 2018).

O NIRS é uma ferramenta de análise não destrutiva que dispensa o uso de reagentes químicos. Contudo, o sucesso dos resultados depende da confiabilidade dos resultados das análises bromatológicas, da padronização da leitura espectral, dos modelos

matemáticos escolhidos para cada espectro e do ajuste das curvas de calibração (Ferreira et al., 2018).

Além dos valores de composição química, para se formular dietas é necessário o conhecimento adequado dos valores de energia metabolizável (EM) dos ingredientes, que podem ser determinados por métodos diretos ou indiretos (Rostagno et al., 2007). O método direto envolve a realização de ensaios de metabolismo e o indireto utiliza equações de predição, que podem proporcionar valores de energia metabolizável a partir da composição química dos alimentos. Para que os resultados sejam confiáveis as análises laboratoriais precisam ser precisas e acuradas (Noblet et al., 1994; Pelizzeri et al., 2013).

Assim, o objetivo deste estudo foi avaliar estimativas dos valores de EM de diferentes milhos para suínos, utilizando os dados de composição química obtidos por quatro equipamentos NIRS.

REVISÃO DE LITERATURA

1. Características fisiológicas do milho

O milho é uma monocotiledônea pertencente à família Poaceae, subfamília Panicoideae, tribo Maydeae, gênero *Zea* e espécie *Zea mays* L., sendo taxonomicamente identificado como *Zea mays* L. spp *mays*. Uma planta herbácea, produtora de fruto seco, cariopse ou semente nua que apresenta grande quantidade de carboidratos, além de certa quantidade de lipídios, fibras, minerais e proteínas, contudo, a qualidade biológica da proteína do milho é baixa (Takeiti, 2014; Nunes, 2016b).

É uma planta monoica, ou seja, possui sexo masculino e feminino no mesmo exemplar, porém as inflorescências são diferentes. É alógama e faz preferencialmente a polinização cruzada, e a fertilização ocorre quando o pólen de uma planta fertiliza o estigma da flor de outra. Devido a polinização cruzada, existe atualmente grande diversidade genética de milho, possibilitando sua adaptação nas mais diferentes condições ambientais (Denuci, 2015).

O milho é uma planta tropical, pertencente ao grupo C4 e, por ser oriundo de climas quentes, exige calor (temperaturas entre 24° e 30°C) e água para seu desenvolvimento e produção satisfatória (Fancelli, 2015; Nunes, 2016b). Além da temperatura e luminosidade adequadas é necessário também disponibilidade de água no

solo, e umidade do ar superior a 70%, proporcionando boa performance da floração e enchimento dos grãos. Outros fatores, no entanto, podem influenciar no desenvolvimento do milho, como o solo, adubação, intercorrências do clima, práticas culturais e pragas (Fancelli, 2015).

As fases consideradas críticas à deficiência de água são a iniciação floral, o desenvolvimento da inflorescência e o período de fertilização e enchimento dos grãos, estes requerem aproximadamente de 500 a 800 mm de lâmina d'água, bem distribuídos, da semente até o ponto de maturação fisiológica dos grãos (Darós, 2015).

A privação de água influencia no enchimento do grão, ocasionando a diminuição no peso do grão e perda no rendimento, mas não influencia na concentração do conteúdo energético disponível no grão (Newman; Hurburgh; Patience, 2016).

2. Importância da cultura do milho

No decorrer das últimas décadas, o milho alcançou o patamar de principal cultura agrícola produzida no mundo. O aumento de sua produtividade reafirma tal posição, conquistada através do melhoramento de sementes, da biotecnologia, das melhorias no sistema de produção, da mecanização e da maior aplicação de insumos (Miranda, 2018).

Há grande demanda da produção de milho no mundo, por suas diversas aplicações. Estimam-se mais de 3.500 aplicações diferentes para esse cereal, além disso, apresenta importância econômica pelo alto potencial produtivo, composição química e valor nutricional de seus grãos (Souza et al., 2012; Miranda, 2018).

Na indústria, o milho pode ser transformado em farinhas, canjica, flocos, xaropes, óleo (utilizado diretamente no consumo humano e na fabricação de outros produtos, como a margarina), amido (utilizado em enlatados, dextrose) e, também, é utilizado na forma de frutose, principal adoçante da indústria de doces e bebidas. O milho também é utilizado como matéria-prima na produção de etanol (Abimilho, 2019).

Atualmente, o maior produtor de milho são os Estados Unidos, com estimativa de produção de aproximadamente 364,3 milhões de toneladas, seguido pela China com a média de 257,3 milhões de toneladas e ocupando o terceiro lugar está o Brasil, com 101,0 milhões de toneladas (FIESP, 2020).

O milho é excelente fonte de carboidratos e possui papel essencial na cadeia de

produção de proteína animal. Possui importância econômica para a indústria de ração, e aproximadamente 70% da produção total do cereal é designado à alimentação animal, compondo 80% das dietas dos suínos, sendo a principal fonte de energia, pois é predominantemente, composto de amido (Baraviera et al., 2014; Paes, 2006).

Utilizado como base das formulações de rações, principalmente na avicultura e suinocultura, o milho possui valor nutricional relativamente alto em comparação com outros grãos, no entanto, a qualidade da proteína é inferior aos demais, já que a maior parte é constituída pela zeína, pobre nos aminoácidos, lisina e triptofano (Pereira Filho et al., 2010; Nunes, 2016b).

O fornecimento preciso de energia e nutrientes é essencial para otimizar a produção de suínos. Portanto, são necessárias informações das exigências dos animais e os valores nutritivos dos ingredientes da dieta. O objetivo da formulação é combinar as necessidades de nutrientes e energia dos suínos com as disponibilidades de nutrientes e energia dos ingredientes, proporcionando uma ração econômica e funcional (Kil; Kim; Stein, 2013).

Os valores de composição química do milho estão representados em várias tabelas, entretanto, é comum observar variações entre os valores tabelados e os resultados obtidos em análises laboratoriais. Muitos são os fatores que influenciam a composição química e nutricional do milho, entre eles, encontram-se a variabilidade genética das sementes, a adubação, as condições de cultivo, o processamento e o armazenamento (Henz et al., 2013; Li et al., 2014; Zanotto et al., 2015).

Com o objetivo de aumentar a variabilidade genética na cultura do milho foram empregadas diversas técnicas, como a hibridização, indução de mutações e a transgenia. O emprego destas permitiu melhorar diversas características na cultura do milho, como produtividade, eficiência no uso de nutrientes do solo, tolerância à seca, resistência a patógenos e muitos outros benefícios (Machado, 2014).

Outro agente de forte influência na produtividade é a adubação nitrogenada, que permite o aumento nos níveis de proteína bruta presente no milho, diretamente relacionado as altas doses de nitrogênio no solo. Esta adubação é comumente realizada em solos brasileiros, visto que a maioria apresenta insuficiência de nitrogênio, podendo ser aplicado diretamente na forma mineral ou pela adubação verde, através do uso de leguminosas (Castilha et al., 2011; Santos et al., 2010).

As condições de cultivo expressam grande importância para a cultura, dado que práticas de manejo modernas são necessárias para que os cultivares de milho atinjam o

rendimento máximo. Dentre as tecnologias adotadas para o desenvolvimento das culturas destacam-se o plantio direto, a fertilização intensiva, o uso de pesticidas e a rotação de culturas (Tracy et al., 2004).

O armazenamento também tem influência sobre a qualidade dos grãos. O local de armazenamento deve ser ventilado e as sacas colocadas sobre estrados de madeira, evitando empilhá-las contra as paredes, para não adquirir umidade e o desenvolvimento de fungos. A temperatura não deve ultrapassar os 25°C e a umidade relativa deve ser inferior a 70%. O armazenamento requer local limpo e principalmente livre de pragas, como insetos e roedores (Lorini et al., 2015).

3. Produção de milho no Brasil

O milho é uma das culturas mais importantes para a economia brasileira, sendo a segunda maior produção de grãos do país, com grande participação nas exportações. Em 2019, a grande demanda mundial de milho fez com que o Brasil ganhasse destaque nas exportações, atingindo o patamar de maior exportador de milho do mundo, superando inclusive os Estados Unidos, com embarques de 44,9 milhões de toneladas, com crescimento de 88% em relação ao ano de 2018 (FAESC, 2019).

De acordo com o levantamento da FAO (2019), ao longo da última década, a cultura passou por transformações profundas, com a redução da agricultura de subsistência e aumento na agricultura comercial eficiente. A produção brasileira de milho aumentou de 52 milhões de toneladas em 2007/2008 para quase 98 milhões de toneladas em 2017/2018.

O aumento da produção brasileira é consequência da elevação da produtividade, sendo possível pelo avanço tecnológico proporcionado pelo desenvolvimento de híbridos com genética superior, que possuem capacidade de adaptação as diferentes regiões, tipos de solo, níveis de fertilidade, épocas de plantio, tolerância às doenças e às pragas, além de outras características diretamente ligadas à genética (Peixoto, 2013).

O aumento da produção eficiente de milho no Brasil está relacionado também a capacidade climática do país em produzir duas safras no mesmo ano, uma vez que as produções ocorrem em diferentes estações, conforme condições climáticas de cada região. No cultivo da primeira safra, o semeio ocorre na primavera/verão, quando estão concentradas as chuvas, na maioria das regiões produtoras do país, com exceção das

regiões Norte e Nordeste, onde a maior concentração de chuvas é a partir do mês de janeiro, classificando-se semeadura de segunda safra. Há também o cultivo na região Sul e Centro-Oeste, onde o semeio é durante verão/outono, denominado de safrinha (Contini et al., 2019).

A produção da primeira safra de milho no Brasil, em 2019, foi de aproximadamente 26,2 milhões de toneladas. Já a safrinha foi o grande destaque do ano, com 72,4 milhões de toneladas colhidas, com crescimento de 34,2% frente ao volume colhido na safra 2017/18 (Mendes, 2019). O sucesso da safrinha tem sido possibilitado, entre outros fatores, pelo aporte de conhecimento e tecnologias providos pelas entidades brasileiras de pesquisa agrícola (Cruz, Filho e Duarte, 2011).

A agricultura brasileira dispõe de clima e condições favoráveis, terras para cultivo e investimento governamental, e tem tido expansão no mercado de câmbio pelo enfraquecimento do real. Com a desvalorização da moeda nacional frente ao dólar, os valores dos produtos advindos da agricultura interna tornaram-se atrativos para o mercado externo, possibilitando aos agricultores brasileiros a oportunidade de negociar e serem competitivos nas vendas externas (Mendes, 2019).

Mesmo com o crescimento do mercado brasileiro de milho, o setor precisa de algumas alterações, que proporcione mais clareza na formação de preços, facilidades para financiamentos privados, e sobretudo dinamismo no processo de escoamento da produção e a resolução das baixas produtividades observadas em algumas regiões (Contini et al., 2019).

4. Diferenças entre os milhos

O milho é cultivado em praticamente todas as regiões, porém, cada região possui cultivares diferentes, com adaptações específicas para sua localidade. Desta forma, as entidades produtoras de sementes dispõem aos agricultores uma gama de opções de cultivares. Dentre os milhos cultivados, os encontrados frequentemente são os grãos alaranjados, amarelos ou brancos, estes podem ser classificados em duros, dentados, farináceos ou cerosos, conforme o tipo e a disposição do amido contido no endosperma (Denuci, 2015).

No Brasil são utilizados dois tipos de cultivares: as variedades melhoradas e os híbridos. As variedades melhoradas são fruto do melhoramento genético o qual se

beneficia da variação de características, entre diferentes variedades locais, para criar novas variedades, e são capazes de oferecer sementes de menor custo e maior produtividade (Magnavaca e Parentoni, 1990).

Apesar das variedades melhoradas apresentarem maior estabilidade de produção, são inferiores aos híbridos no quesito rendimento e uniformidade. O híbrido é a primeira geração do cruzamento entre duas linhagens puras com genótipos diferentes, os mais comuns são os híbridos de variedades e híbridos de linhagens (Gama; Sousa Jr e Magnavaca, 1993).

Os híbridos podem ser definidos como simples, duplos ou triplos. O híbrido simples é o resultado do cruzamento entre duas linhagens puras, é indicado para sistemas de produção com alta tecnologia, pois são exigentes em relação aos fatores de produção, são produtivos, porém mais caros. O híbrido duplo é o resultado do cruzamento entre dois híbridos simples, sendo indicado para média tecnologia, e possuem características intermediárias de rusticidade, enquanto o híbrido triplo é obtido a partir do cruzamento entre uma linha pura e um híbrido simples e é indicado para média a alta tecnologia (Nunes, 2016a).

Na escolha da cultivar são levados em consideração o ciclo vegetativo (super precoce, precoce e normal); o potencial produtivo; a tolerância a adversidades climáticas como déficits hídricos e geadas; a tolerância ao alumínio tóxico e a baixa fertilidade do solo; a resistência/tolerância a pragas e doenças; um bom empalhamento; sincronismo entre o florescimento masculino e o feminino e baixo índice de grãos ardidos, a fim de que a escolha seja pautada nas possíveis conjugação de fatores que poderão significar prejuízos ao empreendimento (Darós, 2015).

Vários fatores podem distinguir as características físicas dos milhos, dentro dos fatores intrínsecos está o melhoramento genético, que desenvolve plantas cada vez mais adaptadas, com capacidade para serem produzidas desde o nível do mar até altitudes superiores a 3.600m, utilizando para esse fim a tecnologia de recombinação genética, a transgenia (Carneiro et al., 2000).

Os fatores extrínsecos, referente ao ambiente, também influenciam na composição dos grãos. As interferências podem ser de ordem climática, como as baixas temperaturas no período de enchimento dos grãos, que afetam a deposição de amido, ou chuvas em excesso, que prejudicam o desenvolvimento da planta (Magalhães e Durães, 2006).

Outros fatores podem estar relacionados as interferências de espaçamento, que influencia na disponibilidade de nutrientes e na captação de luz, o manejo da cultura, a

adubação do solo, o controle de plantas daninhas e as condições de moagem pós-colheita (Zanotto et al., 2015).

Desta forma, mudanças nas características físicas no milho interferem e modificam a composição química, e para esta variação não prejudiquem a formulação é necessário que seja mensurado a composição química em toda partida de milho, e em seguida determinar o valor da energia metabolizável (EM), que por sua vez é a base para a formulação de dietas precisas (Li et al., 2014).

5. Energia consumida pelos suínos

Para o crescimento adequado e boa deposição muscular, os suínos requerem nutrientes suficientes para o fornecimento de energia. A energia não é um nutriente, mas a propriedade dos nutrientes de se tornarem energia química, deste modo, a energia é obtida a partir da oxidação dos nutrientes (Mbajiorgu; Ng`Ambi e Norris, 2011).

Quando as moléculas orgânicas são oxidadas, a energia é produzida como calor e é utilizada pelos animais para manutenção e atividade muscular e processos metabólicos. A energia liberada da oxidação dos alimentos, assim, como a oriunda do metabolismo energético como calor produzido é expressa em caloria (cal), definida como a quantidade de calor necessária para elevar a temperatura de um grama de água de 14,5°C a 15,5°C (Fernandes e Toro-Velasque, 2014).

Os constituintes dos alimentos fornecem energia para o organismo animal, porém possuem diferentes capacidades energéticas quando completamente oxidados, sendo os lipídios os nutrientes que possuem as maiores quantidades de energia por obterem maior densidade energética (Fernandes e Toro-Velasque, 2014).

A energia dos alimentos pode ser expressa como energia bruta (EB), energia digestível (ED), energia metabolizável (EM) e energia líquida (EL). O valor calórico do alimento é denominado EB e é obtido através da bomba calorimétrica, com alta pressão de oxigênio, ou seja, é a energia liberada na queima do alimento. A concentração de EB de um alimento irá depender das proporções de carboidrato, gordura e proteína presentes no ingrediente, uma vez que a água e os minerais não contribuem com energia (NRC, 2012).

A ED representa a energia que é absorvida após o processo de digestão, e é determinada pela diferença da EB do alimento consumido e a EB das fezes. A EM é a

forma normalmente utilizada para suínos no Brasil, sendo obtida pela diferença entre a EB do alimento e a EB das fezes e urina, e dos gases oriundos da digestão (Sakomura e Rostagno, 2016). Segundo Noblet et al., (1989), no caso dos suínos a energia perdida no trato digestório não é contabilizada, por ser muito baixa, cerca de 0,1 a 3% e por ser difícil a medição.

A EM pode ser expressa de duas formas, energia metabolizável aparente (EMA) ou energia metabolizável verdadeira (EMV), esta é obtida pela diferença entre a EB do alimento consumido e a energia bruta das fezes e urina, sendo corrigida pelas perdas de energia fecal metabólica e urinária endógena (Sakomura e Rostagno, 2016).

A EL é obtida da EM menos a energia perdida com o incremento calórico (IC), sendo que o IC é obtido através da diferença entre o calor produzido pelo animal alimentado e o animal em jejum. O IC é determinado pelo calor liberado pelos processos metabólicos e a energia gasta com atividades físicas, ou seja, representa todas as perdas de energia ocorridas durante o processo de digestão, absorção e metabolismo dos nutrientes (Moehn et al., 2013).

A energia possui participação importante na regulação do consumo dos animais, permitindo um adequado ganho de peso e bom desenvolvimento, portanto ao formular dietas com nível energético preciso e acurado garante-se maior lucralidade, diminuindo o custo de ingredientes em excesso (Yang et al., 2020).

A maior porção de EM das rações é proveniente do milho, contudo os valores de composição química deste ingrediente variam e para a formulação eficiente é essencial analisar quimicamente todas as partidas de milho, garantindo o suprimento de nutrientes e energia adequados para manutenção e funções produtivas (Velayudhan; Kim e Nyachoti, 2015).

A composição química e energética média dos alimentos são disponibilizadas em tabelas nacionais (Rostagno et al., 2017) e estrangeiras (NRC, 2012), porém como existe variação na composição química não é seguro para as indústrias utilizarem valores médios tabelados, pois a formulação de mínimo custo os ingredientes são aceitos ou rejeitados, principalmente em função do conteúdo energético (Li et al., 2014).

O método empírico para obtenção da EM do milho é o método direto, feito por meio de ensaios de metabolismo utilizando animais. Mede-se a diferença da energia consumida pela energia excretada utilizando um calorímetro (Pozza et al., 2008a). Contudo, além da disponibilidade de animais a condução de ensaios metabólicos demandam tempo, infraestrutura e recursos financeiros, tornando-o inviável para a

indústria (Pelizzeri et al., 2013).

A equação de predição, por outro lado, é um método indireto, capaz de estimar a EM a partir da composição química dos alimentos. Sua utilização além de possibilitar mais precisão na formulação, ainda corrige os valores energéticos de acordo com a eficiência de utilização de cada nutriente e é mais viável (Noblet et al., 1994).

6. Equações de predição para estimar a energia metabolizável

As equações de predição são elaboradas através de modelos matemáticos e da composição química obtida em laboratório, estimando valores de ED, EM e até mesmo EL, dependendo do modelo de predição a ser utilizado. Este método é vantajoso, pois não é necessário a realização de ensaios metabólicos (Pelizzeri et al., 2013; Castilho et al., 2015).

Para a indústria de ração as equações são fundamentais, é possível realizar ajustes de acordo com a variação da composição química dos alimentos, principalmente de proteína, gordura e fibra dos ingredientes, que são comumente utilizados como regressoras (Pozza et al., 2008b).

Para que as equações sejam utilizadas, precisam ser confiáveis, e por isso, devem ser validadas. Deste modo, é feito a comparação cruzada entre os valores de EM preditos pelas equações, com os valores de EM resultantes do ensaio metabólico (Oliveira et al., 2019).

Para elaborar uma equação é necessário escolher as regressoras que darão origem aos valores preditos de EM. Sabe-se que equações com até quatro variáveis de composição química demandam menos tempo e menos reagentes para serem analisadas, permitindo rapidez e economia na avaliação (Pozza et al., 2008a).

Noblet e Perez (1993) relataram que as melhores regressoras para os valores da EM são a proteína bruta (PB), o extrato etéreo (EE), a fibra em detergente neutro (FDN) e a matéria mineral (MM). Segundo tais autores, a fibra bruta (FB) não é considerada uma boa regressora, podendo interferir negativamente na digestibilidade de alguns componentes da dieta, como a proteína e a gordura.

A fibra fermenta no intestino grosso e eleva a população microbiana, aumentando as secreções endógenas, na forma de proteína e em menor quantidade, gordura (Noblet e Perez, 1993). O efeito negativo da fibra está também associado a menor digestibilidade

da energia e é menos digestível quando comparada aos outros nutrientes da dieta, pois a fermentação gera ácidos graxos voláteis (AGV), cuja eficiência metabólica é baixa (Castilha et al., 2011; Pozza et al., 2010).

Em relação a PB, Noblet e Perez (1993) mencionaram que é boa preditora de EM, porém, quando em excesso ou quando utilizada uma fonte de baixa qualidade, a proteína tem efeito negativo, uma vez que, os aminoácidos podem não ser utilizados para a síntese proteica e sim serem catabolizados e utilizados como fonte de energia, sendo excretado na urina na forma de nitrogênio (NRC, 2012).

De acordo com Morgan et al., (1987), a MM apresenta efeito negativo para a EM, pois atua como diluente da energia bruta, reduzindo o conteúdo de matéria orgânica dos alimentos. A MM também pode reduzir a digestibilidade de gorduras, pois se combinadas formam sabões (Noblet e Perez, 1993). Enquanto o EE apresenta efeito positivo, pois os lipídios possuem a capacidade de melhorar a digestibilidade dos demais nutrientes (Pozza et al., 2010).

Segundo Esteves et al., (2017), as equações com melhor ajuste para estimar a EM do milho para leitões foram $EM = -6306,15 + 400,652FDA + 117,286AMI + 24924,7Ca + 2489,66P - 148,406PB$ ($R^2 = 0,44$), para os milhos de 1ª safra; $EM = -7560,08 + 2,66895EB - 120,688FDA$ ($R^2 = 0,48$), para os milhos de 2ª safra; e para o período completo de safras foi ajustada a equação $EM = 2848,95 + 68,5714FDN + 161,938EE - 5563,51Ca - 1454,15P$ ($R^2 = 0,41$). Conforme os autores os coeficientes de determinação (R^2) sugerem que a aderência das equações pelos valores observados de EM foi de baixa magnitude.

Da mesma maneira, Ferreira et al., (2018) relataram que as equações mais adequadas para prever os valores de energia metabolizável do milho, utilizando NIRS, foram $EM_1 = 4334 - 8,1MM + 4,1EE - 3,7FDN$ ($R^2 = 0,91$); $EM_2 = 4194 - 9,2MM + 1,0PB + 4,1EE - 3,5FDN$ ($R^2 = 0,92$) e $EM_7 = 16,13 - 9,5FDN + 16EE + 23PB \times FDN - 138MM \times FDN$ ($R^2 = 0,39$).

As análises de correlações apresentadas por Li et al., (2014) mostraram que o teor de EM do milho foi correlacionado positivamente com a ED ($R^2 = 0,95$; $P < 0,01$) e o teor de EE ($R^2 = 0,29$; $P < 0,01$), enquanto as cinzas ($R^2 = -0,28$, $P < 0,01$) e FDN ($R^2 = -0,27$, $P < 0,01$) apresentaram correlação negativa com o conteúdo de EM.

Observaram também que as equações em que as regressoras eram PB, EE, FDN e amido, apresentaram boa acurácia em prever os valores de EM, conforme segue: $EM = 4190,19 - (19,56 \times FDN)$ ($R^2 = 0,22$); $EM = 4664,04 - (17,74 \times FDN) - (310,93 \times MM)$

($R^2 = 0,33$); $EM = 4464,24 + (20,15 \times EE) - (17,84 \times FDN) - (233,72 \times MM)$ ($R^2 = 0,44$) e $EM = 4289,74 + 20,02PB + 22,47EE - 18,40FDN - 245,20MM$ ($R^2 = 0,49$).

Nos dados apresentados por Yang et al., (2020) o EE foi importante estimador de predição de EM para o milho, porque a correlação entre EE e a energia digestível do milho é significativa. Assim, as equações de predição mais adequadas foram $EM = 19,13 - (0,61 \times EE)$ ($R^2 = 0,21$) e $EM = 21,55 - (0,29 \times PB) - (0,55 \times EE)$ ($R^2 = 0,27$).

7. A espectroscopia de reflectância no infravermelho próximo – NIRS

A radiação eletromagnética foi a primeira parte do espectro eletromagnético descoberto por William Hersche em 1800, chamando-a de "calor radiante". Durante uma experiência em que se pretendia medir a temperatura do espectro visível, utilizou um prisma de vidro, e decompôs a luz solar em todas as cores do espectro e mediu o calor relativo. A temperatura mais alta encontrava-se depois da extremidade vermelha do espectro visível, e desta forma, descobriu a radiação no infravermelho próximo, o NIRS (near infrared spectroscopy) (Herschel, 1800; Siesler, 2007; Oliveira e Silva, 2014).

O espectro visível ao olho humano encontra-se na faixa espectral de 400 a 800nm, nessa faixa o menor comprimento de onda da luz visível é representado pelo raio ultravioleta e o mais longo é o da luz vermelha. O NIRS compreende a faixa espectral de 800 a 2.500nm, e a faixa espectral que sucede essa é a do infravermelho médio (MIR), compreendida de 2.500 a 50.000nm que, por sua vez, apresenta maior seletividade devido à região de impressão digital ("fingerprint"). Já o infravermelho distante apresenta ondas muito longas, na faixa de 50.000 a 1.000.000nm, propagando-se como rotações (Trevisan e Poppi, 2006; Siesler, 2007; Instrulab, 2019).

Os coeficientes de absorção na faixa espectral do NIRS são de 10 a 1.000 vezes menores que do MIR, em princípio isso reduz a sensibilidade, no entanto, a existência de fontes de radiação mais intensas e bons detectores para essa região espectral compensa, em partes, esse aspecto negativo (Pasquini, 2018).

Os métodos analíticos baseados no NIRS são os mais utilizados, sendo uma técnica bioanalítica rápida, direta, não destrutiva e não invasiva, que apresenta também maior número de aplicações, tanto no monitoramento de processos de alimentos, como também farmacêuticos, polímeros, ambientais, combustíveis e em bioprocessos (Trevisan e Poppi, 2006).

É considerada uma técnica de característica universal, embora ao mesmo tempo essa característica também traga preocupações com a seletividade. Por outro lado, a falta de seletividade pode ser compensada satisfatoriamente pela calibração adequada e pelo uso de análise de regressão multivariada dos dados (Pasquini, 2018).

Apesar da luz de radiação da espectroscopia NIRS possuir bom alcance de penetração e profundidade, seus métodos requerem calibração de dados, utilizando para este fim os valores referência, coletados a partir dos métodos químicos tradicionais, sendo que cada componente alimentar irá requerer calibração própria (Sun, 2009).

A capacidade de previsão do tecido vegetal pela espectroscopia NIRS é capaz de revelar a quantidade, composição, estrutura e distribuição dos constituintes químicos do alimento analisado, e até mesmo os grupos funcionais encontrados nos tecidos (Wajizah; Munawar, 2018).

O princípio do NIRS é que a luz refletida contém informações da composição, sendo decifrada através de um computador capaz de relatar análises múltiplas em menos de um minuto, desta forma o NIRS elabora uma composição entre as propriedades químicas através da absorção de luz em diferentes comprimentos de onda na região do infravermelho próximo (Cozzolino, Acosta e Garcia, 2001).

Através da luz, o equipamento irradia o alimento, a absorção da energia eletromagnética atinge frequências correspondentes às vibrações características de grupos funcionais específicos, enquanto a luz de outras frequências será refletida ou transmitida, desta forma, os componentes bioquímicos do alimento são denunciados pela quantidade e a frequência da luz absorvida, sendo possível deduzir a composição química (Sun, 2009). Adicionalmente as leituras dos alimentos obtidas pelo equipamento NIRS são instantaneamente comparadas e ajustadas a matriz de um banco de dados armazenados, responsável pela calibração do software de controle do equipamento (Instrulab, 2019).

Ao longo da sua existência o NIRS vem sendo aprimorado, e os avanços principais são os sistemas de miniaturização e imagem, e as técnicas de pré-processamento e processamento de dados quimiométricos. Essas constantes contribuições mantiveram o interesse pela técnica, ampliando sua finalidade e aplicações, tanto para a pesquisa quanto para a indústria (Pasquini, 2018).

O NIRS é uma metodologia reconhecida por ser confiável, de baixo custo, rápida e que não gera resíduos químicos durante o processo. Além de poupar tempo de análise e reagentes, o NIRS também apresenta como vantagem sua versatilidade, conseguindo analisar qualquer molécula que contenha ligações como C-H, N-H ou O-H, e as análises

dos constituintes são múltiplas, levando no máximo um minuto por amostra (Burns e Ciurczak, 2007).

É muito utilizado pelas indústrias na determinação da composição química dos alimentos, em substituição a metodologia convencional. Tornando-se vantajoso por possuir maior variedade de aferição, como transmissão e reflexão e por possuir superioridade na determinação rápida e não destrutiva (Shao et al., 2012). Deste modo, o NIRS atualmente é a técnica analítica mais versátil do mercado, utilizada para analisar qualquer material que contenha hidrogênio (Analytical Methods Committee, 2006).

8. Principais diferenças entre equipamentos NIRS

Atualmente, existem diferentes equipamentos NIRS, cada um com sua “particularidade”, possuindo diferentes detectores, tamanhos, velocidade de análise, níveis de ruído, precisão e custo. Equipamentos de custo mais elevados não necessariamente têm melhores desempenhos, pois a principal intercorrência no desempenho é a escolha da curva de calibração (Ciurczak, 2006).

A calibração é realizada utilizando amostras de composições conhecidas e determinadas pela análise de referência (laboratorial). Quando relacionadas as informações espectrais as informações de composição química, pode-se definir o tratamento matemático para os dados e o método de regressão mais adequados (Fontaneli et al., 2002).

Os espectroscópios NIRS se diferem por serem de refletância ou de transmitância, os de refletância são utilizados para análise em sólidos e os de transmitância para substâncias líquidas. Na reflexão difusa trabalha-se com amostras mais espessas e densas, sem induzir tanto aquecimento quanto a transmissão (Pasquini, 2003; Agelet e Hurburgh 2010).

Os instrumentos NIRS podem ser classificados em duas categorias principais: analisadores de laboratório para fins de pesquisa e analisadores de processos para uso nas linhas de produção. Os analisadores de laboratório possuem ampla faixa de varredura e podem ser usados para testar uma variedade de amostras, enquanto os analisadores de processo são para aplicações definidas (Sun, 2009).

A instrumentação para espectrômetros NIRS é composta basicamente por uma fonte de radiação eletromagnética (EMR), um mecanismo óptico para irradiar a amostra

e coletar a radiação, um mecanismo óptico para selecionar o comprimento de onda do EMR, um detector para medir a intensidade do EMR e um software capaz de analisar os dados espectrais adquiridos (Analytical Methods Committee, 2006).

A fonte de luz NIRS mais popularmente utilizada é a lâmpada de tungstênio com halogênio, contudo são as lâmpadas LED que, atualmente, recebem maior destaque, pois possuem baixo consumo de energia, melhor valor de mercado e vida útil mais longa (cerca de 25 anos), estas são as recomendadas para instrumentos miniaturizados de aplicações industriais. Já a fonte de luz superluminiscente (SLED) é a mais moderna e quase não possui ruído visível (Stark e Luchter, 2005; Rossetti et al., 2012).

Os instrumentos baseados em filtro, em LED, em filtros acústicos ópticos (AOTF), ópticos dispersivos e em transformada Fourier, são utilizados para a seleção do comprimento de onda. Os instrumentos baseados em LED e filtro são equipamentos de baixo custo, portáteis e práticos. Instrumentos baseados em AOTF possuem velocidades de varredura mais altas em ampla faixa da região espectral e não possuem partes móveis, sendo excelentes para uso em campo ou em plantas fabris. Os espectrofotômetros baseados na transformada Fourier (utilizados em pesquisas), têm maior precisão e exatidão do comprimento de onda, alta relação sinal-ruído e tolera vibrações ambientais sem perder a precisão, mas a velocidade de varredura e a robustez é menor comparado ao AOTF. Quanto aos detectores, geralmente os mais empregados para a região espectral NIRS são baseados em materiais fotocondutivos de silício, PbS e InGaAs (Pasquini, 2003).

Para o sucesso na determinação da composição química pelo NIRS, além da utilização de bom equipamento é necessário também o ajuste das curvas de calibração e manutenção periódica do equipamento (Bernardi et al., 2017).

REFERÊNCIAS

- Abimilho. 2019. O Cereal que enriquece a alimentação humana. Disponível em: <<http://www.abimilho.com.br/milho/cereal>> Acesso em 2 jun. 2020.
- Agelet LE, Hurburgh Jr CR. 2010. A tutorial on near infrared spectroscopy and its calibration. *Critical Reviews in Analytical Chemistry*, 40(4): 246-260.
- Analytical Methods Committee. 2006. Report by the analytical methods committee: evaluation of analytical instrumentation Part XXI NIR instrumentation for process control. *Accreditation and quality assurance*, 11(5): 236-237.
- Baraviera CMC, Canepelle C, Dourado LGA, Agüero NF. 2014. Avaliação de propriedades físicas de grãos de híbridos de milho. *Enciclopédia Biosfera, Centro Científico Conhecer*, 10(19): 291-297.
- Bernardi A, De Lima JD, Oliveira GA, Trentin MG. 2017. Análise de investimento em segregação de milho: estudo de caso em agroindústria produtora de rações para frangos de corte. *Custos e Agronegócio On-line*. 13(4):147-171.
- Burns DA, Ciurczak EW. 2007. *Handbook of Near-infrared Analysis*. New York: Marcel Dekker, (35): 835.
- Carneiro AA, Carneiro NP, Carvalho CHS, Vasconcelos MJV, Paiva E, Lopes MA. 2000. Milho transgênico: melhoria da qualidade nutricional do grão. *Biotecnologia, Ciência e Desenvolvimento*, 15(3): 42-46.
- Castilha LD, Pozza PC, Klosowski ÉS, Lazzeri DB, Dos Santos Pozza MSD, Richart, Nunes RV. 2011. Modelos matemáticos para predição dos valores energéticos do milho para suínos. *Revista Brasileira de Saúde e Produção Animal*, 12(2): 456-467.
- Castilho RA, Pozza PC, Oliveira NTED, Sangali CP, Langer CN, Nunes RV. 2015. Equations to predict the metabolizable energy of meat and bone meal for growing pigs. *Ciência e Agrotecnologia*, 39: 565-573.
- Ciurczak EW. 2006. Near-infrared spectroscopy. In: Ahuja, S.; Jespersen, N. *Comprehensive Analytical Chemistry: Modern Instrumental Analysis*. Holanda: Elsevier Science, (47): 157–176.
- Contini E, Mota MM, Marra R, Borghi E, Miranda RA, Silva AF, Silva DD, Machado JRA, Cota LV, Costa RV, et al. 2019. Milho: caracterização e desafios tecnológicos. Brasília: Embrapa. (Desafios do Agronegócio Brasileiro, 2). Circular Técnica.
- Cruz JC, Filho IAP, Duarte AP. 2011. Árvore do conhecimento: Milho. Ageitec - Agência Embrapa de informação Tecnológica. Disponível em:<www.agencia.cnptia.embrapa.br/gestor/milho/arvore/CONT000fya0krse02wx5ok0pvo4k3mp7ztkf.html#> Acesso em: 2 ago. 2021.

- Cozzolino D, Acosta Y, Garcia J. 2001. Application of near infrared reflectance spectroscopy (NIRS) to forage evaluation in Uruguay. In: International grasslands congresso, (19): 370.
- Darós R. 2015. Cultura do milho: manual de recomendações técnicas. (AGRAER - Agência Regional de Dourados). Dourados, MS. Disponível em: <http://www.agraer.ms.gov.br/wp-content/uploads/2015/05/Manual_de_recomendações_técnicas_cultura_do_milho.pdf> Acesso em: 2 ago. 2020.
- Denuci S. Melhoria em Milho. 2015. Disponível em: <<https://agronomos.ning.com/profiles/blogs/melhoramento-em-milho>> Acesso em 2 ago. 2020.
- EMBRAPA. Central de Inteligência de Aves e Suínos - CIAS. 2020. Disponível em: <<https://www.embrapa.br/suinos-e-ave/cias>>. Acesso em: 5 nov. 2020.
- Esteves LAC, Oliveira NTED, Huepa LMD, Ferreira SL, Castilha LD, Pozza PC. 2017. Predição da energia metabolizável de primeira e segunda safra de milho para leitões. *Ciência e Agrotecnologia*, (41): 683-691.
- FAESC. 2019. Brasil se torna o maior exportador de milho e escassez do produto em 2020 vai atrapalhar o agronegócio de SC. Disponível em: <<http://www.sistemafaesc.com.br/Noticias/Detalhe/16127>> Acesso em: 3 jul. 2020.
- Fancelli, A. L. 2015. Cultivo racional e sustentável requer maior conhecimento sobre planta do milho. *Revista Visão Agrícola*, ESALQ Piracicaba, v. 13 n. 1, p. 20-23.
- FAO, Organização das Nações Unidas para a Agricultura e a Alimentação. 2019. Brasil deve se tornar o segundo maior exportador global de milho. Disponível em: <<http://www.fao.org/brasil/noticias/detail-events/pt/c/1194128/>> Acesso em: 2 ago. 2020.
- Fernandes MHMR, Toro-Velasque PA. Metabolismo energético. p. 77-94. In: Sakomura NK, Silva JHV, Costa FGP, Fernandes JBK, Hauschild L. *Nutrição de Não Ruminantes*. 2014. Jaboticabal, SP: Funep.
- Ferreira SL, Vasconcellos RS, Rossi RM, Paula VRCD, Fachinell, MR, Huepa LMD, Pozza PC. 2018. Using near infrared spectroscopy to predict metabolizable energy of corn for pigs. *Scientia Agricola*, 75(6): 486-493.
- FIESP, Federação das Indústrias do Estado de São Paulo. 2020. Safra Mundial de Milho 2019/20 – 11º Levantamento do USDA. Disponível em: <<https://www.fiesp.com.br/indices-pesquisas-e-publicacoes/safra-mundial-de-milho-2/attachment/file-20200312130632-boletimmilhomarco2020/>> Acesso em: 3 jun. 2020.
- Fontaneli RS, Durr JW, Scheffer-Basso SM, Haubert F, Bortolini F. 2002. Validação do método da reflectância no infravermelho proximal para análise de silagem de milho. *Revista Brasileira de Zootecnia*, 31(2): 594-598.

- Gama EEG, Sousa Jr CL, Magnavaca R. Cultivares de Milho. In: Cruz, JC, Monteiro JDA, Santana DP, Garcia JC, Bahia FDC, Sans LMA, Coelho A. 1993. Recomendações técnicas para o cultivo do milho. EMBRAPA-SP.
- Henz JR, Nunes RV, Pozza PC, Furlan AC, Scherer C, Eying C, Silva WTMD. 2013. Energetic values of different corn cultivar for poultry. *Semina: Ciências Agrárias*, 34: 2403-2414.
- Herschel FW. 1800. Experiments on the Refrangibility of the Invisible Rays of the Sun, *Philosophical Transactions of the Royal Academy* 1800, 284-292. Disponível em: <<https://archive.org/stream/jstor-107057/107057#page/n1/mode/2up>> Acesso em: 17 mai. 2020.
- INSTRULAB. A técnica NIR aplicada a alimentos. 2019. Instrulab Instrumentos para Laboratórios. Disponível em: <<http://www.instrulab.com.br/assets/downloads/ebook%20tecnica%20nir%20aplicada%20a%20alimentos.pdf-4c929.pdf>> Acesso em: 30 jul. 2019.
- Kil DY, Kim BG, Stein HH. 2013. Feed energy evaluation for growing pigs. *Asian-Australasian Journal of Animal Sciences*, 26(9): 1205-127.
- Magalhaes PC, Durães FO. 2006. Fisiologia da produção de milho. Embrapa Milho e Sorgo-Circular Técnica (INFOTECA-E).
- Li Q, Zang J, Liu D, Piao X, Lai C, Li D. 2014. Predicting corn digestible and metabolizable energy content from its chemical composition in growing pigs. *Journal of animal science and biotechnology*, 5(1): 1-8.
- Lorini I, Krzyzanowski FC, França-Neto JB, Henning AA, Henning FA. 2015. Manejo integrado de pragas de grãos e sementes armazenadas. p. 970.
- Machado AT. 2014. Construção histórica do melhoramento genético de plantas: do convencional ao participativo. *Revista Brasileira de Agroecologia*, 9(1): 35-50.
- Magnavaca R, Parentoni SN. 1990. Cultivares x híbridos: conceitos básicos. *Informe Agropecuário, Belo Horizonte- MG*, 14(165): 5-8.
- Mbajorgu CA, Ng`Ambi JW, Norris DD. 2011. Voluntary feed intake and nutrient composition in chickens. *Asian Journal of Animal and Veterinary Advances*, 6(1): 20-28.
- Mendes LG. 2019. Todas as perspectivas para produção de milho 2019 e seu mercado de preços. Disponível em: <<https://blog.aegro.com.br/producao-de-milho-2019/>> Acesso em: 2 ago. 2020.
- Miranda RA. 2018. Uma História de Sucesso da Civilização. *Revista A Granja*. Disponível em: <<https://edcentaurus.com.br/agranja/edicao/829/materia/8972>> Acesso em: 2 ago. 2020.
- Moehn S, Levesque CL, Ball RO. 2013. Protein intake but not feed intake affects dietary energy for finishing pigs. *Journal of Physiology and Animal Nutrition*, 97: 197-204.

- Morgan CA, Whittemore CT, Phillips P, Crooks P. 1987. The prediction of the energy value of compounded pig foods from chemical analysis. *Animal Feed Science and Technology*, 17: 81-107.
- Nascimento H. 2020. A produção e o consumo de carne suína no mundo. *Suinocultura Industrial*. Disponível em: <<https://www.suinoculturaindustrial.com.br/imprensa/a-producao-e-o-consumo-de-carne-suina-no-mundo/20200512-110921-k561>> Acesso em: 2 ago. 2020.
- NATIONAL RESEARCH COUNCIL - NRC. 2012. Nutrient requirements of swine. 11 ed. Washington, DC: National Academy, p. 400.
- Newman MA, Hurburgh CR, Patience JF. 2016. Defining the physical properties of corn grown under drought-stressed conditions and the associated energy and nutrient content for swine. *Journal of animal science*, 94(7): 2843-2850.
- Noblet J, Dourmad JY, Le Dividich J, Dubois S. 1989. Effect of ambient temperature and addition of straw or alfalfa in the diet on energy metabolism in pregnant sows. *Livestock Production Science*, 21(4): 309-324.
- Noblet J, Fortune H, Shi XS, Dubois S. 1994. Prediction of net energy value of feeds for growing pigs. *Journal Of Animal Science*, 72: 344-354.
- Noblet J, Perez JM. 1993. Prediction of digestibility of nutrients and energy values of pig diets from chemical analysis. *Journal of Animal Science*, 71: 3389-3398.
- Nunes JLS. 2016a. Produção de sementes de milho. Agrolink. Disponível em: <https://www.agrolink.com.br/sementes/tecnologia-sementes/producao-de-sementes-de-milho_361338.html> Acesso em: 2 ago. 2020.
- Nunes JLS. 2016b. Características do Milho. Agrolink. Disponível em: <https://www.agrolink.com.br/culturas/milho/informacoes/caracteristicas_361401.html> Acesso em: 2 ago. 2020.
- Oliveira NTED, Pozza PC, Castilha LD, Pasquetti TJ, Langer CN. 2019. Predição da energia metabolizável de ingredientes energéticos e avaliação da validação do stepwise utilizando bootstrap. *Revista Ciência Agronômica*, 50(1): 131-139.
- Oliveira RA, Silva APB. 2014. William Herschel, os raios invisíveis e as primeiras ideias sobre radiação infravermelha. *Revista Brasileira de Ensino de Física*, 36(4): 01-11.
- Paes MCD. 2006. Aspectos físicos, químicos e tecnológicos do grão de milho. Embrapa Milho e Sorgo-Circular Técnica (INFOTECA-E). Sete Lagoas: EMBRAPA - CNPMS, (75): 6.
- Paes MCD. 2008. Manipulação da composição química do milho: impacto na indústria e na saúde humana. Disponível em: <http://www.infobibos.com.br/artigos/2008_4/milho/index.htm> Acesso em: 12 out. 2020.

- Pasquini C. 2003. Near infrared spectroscopy: fundamentals, practical aspects and analytical applications. *Journal of the Brazilian chemical society*, 14: 198-219.
- Pasquini C. 2018. Near infrared spectroscopy: A mature analytical technique with new perspectives – A review. *Analytica Chimica Acta*, 1026: 8-36.
- Peixoto CM. 2013. Sementes e Mudanças: Avanços Tecnológicos da Cultura do Milho no Brasil. *Jornal dia de Campo*. Disponível em: <<http://www.diadecampo.com.br/zpublisher/materias/Materia.asp?id=23562&secao=Sementes%20e%20Mudas>> Acesso em: 2 jun. 2020.
- Pelizzeri RN, Pozza PC, Oliveira NTE, Somensi ML, Furlan AC, Neumann ME. 2013. Avaliação de modelos de predição da energia metabolizável do milho para suínos. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, 65: 460-468.
- Pereira Filho IA, Alvarenga RC, Gontijo Neto MM, Viana JHTM, Oliveira MF. 2010. Cultivo do milho. J. C. C. Cruz (Ed.). Sete Lagoas: Embrapa Milho e Sorgo.
- Pozza P. C, Gomes PC, Donzele JL, Rostagno HS, Santos Pozza MSD, Nunes RV. 2008a. Composição química, digestibilidade e predição dos valores energéticos da farinha de carne e ossos para suínos. *Acta Scientiarum - Animal Science*, v. 30, n. 1, p. 33-40.
- Pozza P. C, Gomes PC, Donzele JL, Rostagno HS, Santos Pozza MSD, Nunes RV. 2008b. Determinação e predição dos valores de energia digestível e metabolizável da farinha de vísceras para suínos. *Revista Brasileira de Saúde e Produção Animal*, v.9, n.4, p.734-742.
- Pozza PC, Nunes RV, Santos Pozza MSD, Richart S, Schumacher GC, Oliveira FGD. 2010. Determinação e predição de valores energéticos de silagens de grãos úmidos de milho para suínos. *Ciência e Agrotecnologia* 34: 226-232.
- Rossetti M, Napierala J, Matuschek N, Achatz U, Duelk M, Velez C, Castiglia A, Grandjean N, Dorsaz J, Feltin E. 2012. Superluminescent light emitting diodes: the best out of two worlds. In *Moems and Miniaturized Systems Xi*, 8252: 825208.
- Rostagno HS, Albino LFT, Hannas MI, Donzele JL, Sakomura NK, Perazzo FG, Saraiva A, Teixeira ML, Rodrigue PB, Oliveira RF, et al. 2017. Tabelas Brasileiras Para Aves e Suínos: Composição de Alimentos e Exigências Nutricionais Departamento de Zootecnia-UFV, Viçosa, MG, BR.
- Rostagno HS, Bünzen S, Sakomura NK, Albino LF. 2007. Avanços metodológicos na avaliação de alimentos e de exigências nutricionais para aves e suínos. *Revista Brasileira de Zootecnia*, 36: 295-304.
- Sakomura NK, Rostagno HS. 2016. Métodos de pesquisa em nutrição de monogástricos. Editora Funep. Jaboticabal, SP, BR.
- Santos PA, Silva AF, Carvalho MAC, Caione G. 2010. Adubos verdes e adubação nitrogenada em cobertura no cultivo do milho. *Revista brasileira de milho e*

sorgo, 9(2): 123-134.

- Shao XG, Ning Y, Liu FX, Li JH, Cai WS. 2012. Application of near-infrared spectroscopy in micro inorganic analysis. *Acta Chimica Sinica*, 70(20): 2109-2114.
- Siesler HW. 2007. Basic Principles of Near-Infrared Spectroscopy In: Burns, D.A; Ciurczak, E.W. *Handbook Near-infrared spectroscopy*. Third Edition. Practical Spectroscopy. 35: 7-20.
- Souza HA, Cavalcante ACR, Pompeu R, Tonucci R, Natale W. 2012. Avaliação da eficiência agrônômica de fontes e doses de nitrogênio na cultura do milho em região Semiárida. In: FERTIBIO 2012, Maceió. A responsabilidade socioambiental da pesquisa agrícola: anais. Viçosa, MG, 1-4.
- Stark E, Luchter K. 2005. Tecnologia de instrumentação NIR. *Notícias do NIR*, 16(7): 13-16.
- Sun DW. 2009. *Infrared spectroscopy for food quality analysis and control*. London: Academic.
- Takeiti CY. Cereais e grãos. Brasília: EMBRAPA, 2014. Disponível em: <https://www.agencia.cnptia.embrapa.br/gestor/tecnologia_de_alimentos/arvore/CONT000fid57plx02wyiv80z4s47384pdxjo.html>. Acesso em 09 out. 2020.
- Tracy WF, Goldman IL, Tiefenthaler AE, Schaber MA. 2004. Trends in productivity of US crops and long-term selection. *Plant breeding reviews*, 24(2): 89-108.
- Trevisan MG, Poppi RJ. 2006. Química analítica de processos. *Química Nova*, 29: 1065-71.
- Velayudhan DE, Kim IH, Nyachoti CM. 2015. Characterization of dietary energy in swine feed and feed ingredients: a review of recent research results. *Asian-Australasian journal of animal sciences*, 28(1): 1.
- Wajizah S, Munawar AA. 2018. Fast and simultaneous prediction of animal feed nutritive values using near infrared reflectance spectroscopy. *IOP Conference Series: Earth and Environmental Science*, 122(1): 1-6 . Disponível em: <<https://iopscience.iop.org/article/10.1088/1755-1315/122/1/012112/pdf>> Acesso em: 07 set. 2019.
- Yang P, Ni JJ, Zhao JB, Zhang G, Huang CF. 2020. Regression Equations of Energy Values of Corn, Soybean Meal, and Wheat Bran Developed by Chemical Composition for Growing Pigs. *Animals*, 10(9): 1490.
- Zanotto DL, Coldebella A, Ludke JV, Bertol TM. 2015. Equação de predição da energia metabolizável do milho para suínos. In: *Salão Internacional de Avicultura e Suinocultura - SIAVS, Anhenbi, SP. Anais...*, Anhenbi, SP, 240 – 243.

II - OBJETIVO GERAL

Validar as estimativas de composição química e equações de predição da energia metabolizável do milho para suínos utilizando diferentes NIRS (espectroscopia de reflectância no infravermelho próximo).

III – EXTERNAL VALIDATION OF CHEMICAL COMPOSITION ESTIMATES OF CORN USING DIFFERENT NIRS EQUIPMENTS

ABSTRACT – Corn is the main energy source of swine rations, but it can present variations in chemical composition, demanding analytical methods that allow determining its chemical composition quickly and accurately. Therefore, the objective of this study was to proceed with an external validation of the chemical composition of corn samples estimated by different NIRS (near infrared spectroscopy). Ten samples of corn were analyzed in two different laboratories and scanned in four NIRS, which presented different calibration curves for this food. Dry matter (DM), crude protein (CP), ether extract (EE), mineral matter (MM), crude fiber (CF), non-nitrogen extractive (NNE), starch (STA) and organic matter (OM) were determined by analytical methods and by the different evaluated NIRS. The results of the chemical composition of corn, obtained by laboratory analysis and NIRS technology were compared using the frequentist approach. It was evaluated whether the independent variable (x) explains the variation in the dependent variable (y). The hypothesis tested was $H_0: \beta_0 = 0$ and $\beta_1 = 0$, versus the alternative hypothesis $H_a: \beta_0 \neq 0$ and $\beta_1 \neq 0$. The statistical parameters adopted to evaluate the variation of the chemical composition for the ten corns were the estimates of the significance probability of intercept and angular coefficient (P_{β_0} and P_{β_1}); the sample correlation coefficient (r_{xy}); the degree of agreement between Y and X (C_b) and the correlation coefficient of agreement (CCC). NIRS 2 provided the best chemical composition estimates when compared with conventional laboratory analyses, followed by NIRS 1 and 4, and last and least accurate is NIRS 3. Chemical composition estimates obtained by NIRS equipment may present adequate estimates, while others are inaccurate, and external validation should be used as a tool to assess the precision and accuracy of chemical composition estimates.

Keywords: near infrared spectroscopy, precision nutrition, prediction

III - VALIDAÇÃO EXTERNA DAS ESTIMATIVAS DE COMPOSIÇÃO QUÍMICA DO MILHO OBTIDA EM DIFERENTES EQUIPAMENTOS NIRS

RESUMO – O milho é a principal fonte energética das rações para suínos, mas pode apresentar variações na composição química, demandando métodos analíticos que permitam determinar sua composição química com rapidez e precisão. O objetivo deste trabalho foi o de proceder com uma validação externa da composição química de amostras de milho estimadas por diferentes NIRS (Espectroscopia no Infravermelho Próximo). Dez amostras de milho foram analisadas em dois diferentes laboratórios e também escaneadas em quatro NIRS, que apresentavam diferentes curvas de calibração para esse alimento. Foram determinadas a matéria seca (MS), proteína bruta (PB), extrato etéreo (EE), matéria mineral (MM), fibra bruta (FB), extrativo não nitrogenado (ENN), amido (AMI) e matéria orgânica (MO), tanto por métodos analíticos quanto pelos diferentes NIRS avaliados. Os resultados de composição química do milho, obtidos pelas análises laboratoriais e pela tecnologia NIRS foram comparados, por meio da abordagem frequentista. Foi avaliado se a variável independente (x) explica a variação na variável dependente (y). A hipótese testada foi $H_0: \beta_0 = 0$ e $\beta_1 = 0$, versus a hipótese alternativa $H_a: \beta_0 \neq 0$ e $\beta_1 \neq 0$. Os parâmetros estatísticos adotados para avaliar a variação da composição química para os dez milhos foram as estimativas da probabilidade de significância do intercepto e do coeficiente angular (P_{b0} e P_{b1}); o coeficiente de correlação amostral (r_{xy}); o grau de concordância entre Y e X (C_b) e o coeficiente de correlação de concordância (CCC). O NIRS 2 foi o que proporcionou as melhores estimativas de composição química ao se comparar com as análises laboratoriais convencionais, seguido pelos NIRS 1 e 4, e por último e menos preciso, está o NIRS 3. As estimativas de composição química obtidas por equipamentos NIRS podem apresentar estimativas adequadas, enquanto outras se mostram imprecisas, devendo-se utilizar a validação externa como ferramenta para avaliar a precisão e acurácia das estimativas de composição química.

Palavras-chave: espectroscopia no infravermelho próximo, nutrição de precisão, predição

INTRODUCTION

Corn is the main raw material used in the formulation of feed for poultry and swine. It has high palatability, relatively low cost and stands out from other cereals due to its higher energy content, constituting it as an important element in animal nutrition (Loy and Lundy, 2019).

However, factors such as soil fertility, genetic variability of cultivars, cultivation conditions and grain storage can change the energy value and chemical composition of this raw material, interfering in the formulation of diets for pigs (Li et al., 2014).

The chemical composition of corn is determined by means of physical chemical analyzes carried out in the laboratory, however, the techniques employed are usually destructive, making the use of samples unfeasible after the end of the analysis. In addition, they use chemical reagents that need appropriate places for disposal, as they are water and soil contaminants (Tallada et al., 2009), in addition to the long period of time required to perform the analyses.

Thus, alternative methods for determining nutrient and energy content have been developed. Currently, near-infrared reflectance spectroscopy (NIRS) is the most used technique in the feed industry, capable of performing fast, economical, reliable and non-destructive measurements (Wajizah; Munawar, 2018).

In this technique, the direct information on the nutritional and energetic result is not obtained, but signals (curves and peaks) that are later treated through chemometrics, using mathematical and statistical methods, to interpret and predict chemical data, enable quantitative determination. of chemical compounds (Siesler, 2007).

The accuracy of NIRS depends directly on the internal database, so the success of the operation is based on the representativeness of the included samples, in order to facilitate the equipment to correctly read other samples of the same ingredient. The adjustment of calibration curves aims to make the values of concentrations and properties of the ingredients known (Sena; Almeida, 2018). Therefore, the success of NIRS also depends on the calibration curves, for each ingredient and in each NIRS equipment.

Additionally, over time, it is necessary to perform maintenance on the equipment and monitor the predictive models. Thus, new laboratory chemical analyzes are required to verify the samples and, if the validated model presents low precision and/or accuracy, new samples must be included with the intention of increasing the variation and improving the prediction of the parameters (Walker et al., 2010).

In this sense, the predictions of the chemical composition values of each ingredient can be evaluated using a cross validation, which uses the NIRS equipment to perform the validation and provide important parameters to evaluate the calibration curves. Examples that should be mentioned are the standard error of calibration (SEC), the standard error of cross-validation (SECV), the standard error of prediction (SEP) and the global distance Mahalanobis (GH). Therefore, it is possible to compare calibrations of different properties, which can show how much a sample differs from the average of the samples of the calibration set (Williams and Sobering, 1993).

However, there are external validation methodologies that can be used to identify possible prediction deviations, due to differences in the sensitivity of the employed validation. Thus, the objective of this study was to proceed with the external validation of the chemical composition of corn estimated by different NIRS equipment.

MATERIAL AND METHOD

Ten maize cultivars from different locations in the State of Paraná were used. Representative samples were extracted from the bags for later determination of chemical composition by analytical methods and NIRS evaluations.

To determine the chemical composition of the cultivars, by analytical methods, the samples were ground in a knife-type mill, equipped with a 1 mm sieve, and stored in closed and identified pots. The analyzes were performed at the Laboratory of Food Analysis and Animal Nutrition at UEM (LANA-DZO/UEM) and the same analyzes were also performed at the Laboratory of Food Analysis at UNIOESTE (LANA - UNIOESTE), to obtain the repeatability regarding chemical composition values.

The performed analyzes include dry matter (DM) (AOAC 950.05), crude protein (CP) (AOAC 2001.11), ether extract (EE) (AOAC 945.16), crude fiber (CF) (AOAC 978.10), neutral detergent fiber (NDF) (AOAC 2002.04), acid detergent fiber (FDA) (AOAC 973.18) and mineral matter (MM) (AOAC 2002.04).

Starch analyzes (STA) were performed by the ABC Foundation laboratory, using the enzymatic colorimetric method for total starch determination. Calcium (Ca) and phosphorus (P) analyzes were performed using the atomic absorption and spectrophotometric methods, respectively (Malavolta, Vitti and Oliveira, 1997).

The determination of the chemical composition of the cultivars was also carried

out using four different NIRS equipment, obtaining the concentration of dry matter (DM), crude protein (CP), ether extract (EE), mineral matter (MM), crude fiber (CF), non-nitrogen extractive (NNe), starch (STA) and organic matter (OM).

The NIRS calibration curves did not need to be elaborated, since the equipment was already in full use and properly calibrated to read the corn samples sent. Each equipment had different calibration curves, in order to identify possible deviations regarding the prediction of the evaluated chemical composition values.

The results of the chemical composition of the corn, obtained through the estimates provided by the four NIRS equipment, were statistically evaluated using the linear regression model, to reveal whether the values obtained were or were not statistically equivalent to the values observed in the laboratory.

The parameters of the linear relationship b_0 and b_1 were adjusted through linear regression, expressed by the equation:

$$Y_i = b_0 + b_1 X_i + \varepsilon_i$$

In which:

Y_i = observed value for the dependent variable Y at the i -th level of the independent variable X .

b_0 = regression constant. It is the intercept of the line, i.e., the point at which the line crosses the ordinate (Y) axis.

b_1 = regression coefficient. It is the slope coefficient of the line, where a unit change in X will result in a change of b_1 in Y .

X_i = i -th level of the independent variable X ($i = 1, 2, \dots, n$)

ε_i = is the error associated with the distance between the observed value Y_i and the corresponding point of the curve from the proposed model, for the same level of i and X .

According to Chein (2019), regression models can be seen as a device to estimate the differences among a group of estimated values and a group of observed values. Thus, the values obtained through laboratory analyzes corresponded to the observed values (Y) and the values estimated by the four different NIRS equipment corresponded to the predicted values (X). The objective of this model was to adjust the equation of the line between the two variables (Y and X), in order to find values of b_0 and b_1 .

Parameters b_0 and b_1 were estimated using the Least Squares method, which

allows the identification of factors (linear combinations of X variables) that best model the Y dependent variables.

To assess whether the independent variable explained the variation in the dependent variable, the tested hypothesis was based on the value at which the fitted line crossed the y-axis, ($H_0: \beta_0 = 0$ and $\beta_1 = 0$) as opposed to the null hypothesis ($H_a: \beta_0 \neq 0$ and $\beta_1 \neq 0$). This alternative hypothesis is referred to as a two-sided hypothesis, and it rejects the null hypothesis if the line does not start from the origin.

Precision, strictness, and accuracy indices of the prediction models from the corn chemical composition provided by NIRS equipment were evaluated.

The statistical parameters, adopted to evaluate the variation of the chemical composition of the ten corns together, were the estimates of the significance probability from the intercept and the angular coefficient (P_{b0} and P_{b1}); the sample correlation coefficient (r_{xy}); the degree of agreement between Y and X (C_b) and the correlation coefficient of agreement (CCC). Statistical analysis was performed using the R program, version 4.1.2, with 5% significance.

In order to assess whether NIRS equipment is effective in correctly predicting chemical composition, these parameters were analyzed separately and together.

RESULTS AND DISCUSSION

The food nutrients are contained in DM, and the ability of animals to consume it is also related to DM, which makes an adequate determination of this important variable. Additionally, the high moisture content in storage can lead to fungal problems, which can be harmful to animals and humans, due to mycotoxins (Prestes et al., 2019; Varga et al., 2015).

The DM values of the evaluated corns ranged from 88.19 to 89.94% (Table 1), similar to the variation from 86.78 to 89.65% obtained by Dong et al. (2020), when evaluating twenty maize cultivars. Likewise, Rostagno et al. (2017) proposed an average value of 88.90% of DM, while the NRC (2012) presented a content of 88.31%, which is in the variation interval observed in this work.

The CV obtained for CP was 4.90% (Table 1), whereas Esteves et al. (2017) reported a CV of 4.00% for the 1st crop cultivars and 4.16% for the 2nd crop, demonstrating an existing variation for this variable, which makes the external validation

robust. Higher levels of CP are usually related to improved varieties for this purpose, or the use of nitrogen fertilization, which increases the levels of ammonium and nitrate in the plant and in the grains (Piovesan; Oliveira and Araújo, 2010).

The EE values found ranged from 3.82 to 4.80% (Table 1), and variations from 3.77 to 4.87% and 3.75 to 4.08% were observed by Smith et al. (2015) and Ferreira et al. (2018), respectively. The variation observed for the EE can be considered relevant, as it present a CV of 7.72%. Adequate knowledge of the EE content of corn is extremely important, as it directly contributes to the caloric value of food (NRC, 2012).

MM levels ranging from 1.06 to 1.55% (Table 1), covering the range from 1.13 to 1.39% were observed by Esteves et al. (2017) and from 1.06 to 1.48% observed by Ellery et al. (2015); however, they were lower than the range from 1.18 to 2.29% reported by Pelizzeri et al. (2013). According to Ferreira et al. (2018), MM does not contribute positively to ME, but it is important that it is correctly estimated, as it is considered a diluter of food energy. In this sense, the determination of MM by analytical methods or by NIRS must be well conducted, since it presents a high variation, which can be observed by the CV of 9.89% (Table 1).

Table 1 - Chemical composition of corn cultivars obtained by analytical methods, in dry matter

Parameters	Corns										Mean	DP	CV(%)	Amplitude
	1	2	3	4	5	6	7	8	9	10				
DM	88,56	88,92	88,39	88,19	88,62	88,51	89,64	89,94	89,07	88,58	88,84	0,56	0,63	1,76
CP	8,53	8,45	7,47	8,85	8,55	7,84	8,42	8,21	8,64	8,56	8,35	0,41	4,90	1,37
EE	4,79	4,27	4,23	4,42	4,08	3,82	4,60	3,94	4,32	4,80	4,33	0,33	7,76	0,98
MM	1,34	1,18	1,26	1,34	1,55	1,24	1,36	1,06	1,26	1,31	1,29	0,13	9,89	0,49
CF	2,14	1,77	2,51	1,81	2,41	2,24	2,19	2,29	2,29	2,40	2,20	0,24	11,10	0,75
NDF	14,00	13,33	11,56	12,10	14,99	12,84	11,61	13,04	15,26	11,88	13,06	0,42	10,28	3,70
ADF	3,14	2,87	2,89	2,94	3,36	3,15	2,81	2,99	3,32	3,52	3,10	0,24	7,72	0,71
NNE	71,75	73,24	72,92	71,76	72,03	73,36	73,07	74,45	72,55	71,51	72,66	0,92	1,27	2,94
STA	71,42	68,78	74,02	70,57	70,86	73,97	71,28	74,24	75,96	75,54	72,67	2,39	3,29	7,18
GE	4435	4457	4420	4484	4508	4413	4436	4353	4434	4476	4438	43,4	0,98	155
Ca	0,006	0,010	0,008	0,010	0,010	0,006	0,008	0,007	0,010	0,006	0,008	0,002	25,32	0,005
P	0,102	0,112	0,091	0,102	0,135	0,113	0,112	0,078	0,101	0,113	0,106	0,015	14,52	0,058
OM	87,22	87,73	87,13	86,85	87,07	87,27	88,28	88,88	87,81	87,27	87,55	0,63	0,72	2,03

DM – dry matter, CP – crude protein, EE – ether extract, MM – mineral matter, CF – crude fiber, NDF – neutral detergent fiber, ADF – acid detergent fiber, NNE – non-nitrogen extractive, GE – gross energy, Ca – calcium, P – phosphorus, OM – organic matter, CV – coefficient of variation, SD – standard deviation.

Still in relation to minerals, it is observed that Ca and P presented higher CV in relation to MM (Table 1). Dong et al. (2020) observed an even greater amplitude, since the variation of Ca was from 0.01 to 0.03%, and for P, the variation was from 0.20 to 0.33%. In order to obtain satisfactory levels of Ca and P in food, fertilization is necessary, especially for P, which is a limiting mineral in tropical soils (Araujo, 2011), which may partially explain the variation observed in phosphorus concentrations.

CF ranged from 1.77 to 2.51% (Table 1), while the variation presented by Pelizzeri et al. (2013) was even higher (1.21 to 6.23%). The variation observed for NDF and ADF were 11.56 to 15.26% and 2.81 to 3.52%, respectively, while Dong et al. (2020) showed variations from 10.18 to 14.86% and 2.04 to 4.58%, and Ferreira et al. (2018) showed a variation from 10.96 to 13.88% and 3.53 to 4.84%, respectively.

Thus, there is an expressive variation in the fibrous fractions of corn, both in the literature and in the fibrous fractions observed in this work. These fractions must be considered when evaluating feed for pigs, since the high fiber content is related to the increase in intestinal fermentation, which contributes to the increase in the synthesis and loss of methane from the intestine (Kil; Kim; Stein, 2013).

The NNE ranged from 71.51 to 74.45% (Table 1), showing a lower amplitude than those reported by Dong et al. (2020) and Smith et al. (2015). The NNE is determined by the difference between DM and the other Weende fractions (CP, MM, EE and CF), which reflects the variation observed for these compounds, including the errors from previous analyzes (Andriguetto et al., 1982).

The starch content ranged from 68.78 to 75.96% (Table 1), close to the range from 69.41 to 77.21% presented by Pelizzeri et al. (2013) and the one proposed by Lyu et al. (2019), which ranged from 69.98 to 78.59%. This variation has a fundamental importance and must be considered, since it effectively collaborates with the gross energy value of corn. The digestion of starch releases energy, and it is influenced by several factors, including the variation in the amylose:amylopectin ratio, which differs among cultivars according to the degree of maturation of the plant (Denardin and Silva, 2009).

The amplitude observed for GE (Table 1) was close to that presented by Esteves et al. (2017), who observed a variation from 4387 to 4511 kcal/kg for first-crop corn and 4302 to 4560 kcal/kg for second-crop corn. Despite the low CV, the amplitude of 155 kcal/kg observed among maize cultivars should not be neglected, since GE directly influences the values of metabolizable energy (ME) of the maize.

According to the chemical composition of the data presented, there is an expressive variation between the chemical components, which may be related to the genetic variability of the seeds, the cultivation conditions and post-harvest milling conditions. This variation interferes with the nutritional and energy value of corn, and for this reason it is important to evaluate the chemical composition to formulate rations, to avoid working with average values and to ensure greater precision (Zanotto et al., 2015). Thus, the estimates made by NIRS equipment must present high precision and accuracy, and cross-validation ought to be used, as well as external validations.

A wide variety of samples are necessary be included in the NIRS for its calibration, thus ensuring the reliability of the results (Gottardo; De Oliveira and Bernardo, 2015). In addition to the adjustment of calibration curves, the success in determining the chemical composition by NIRS is also related to the periodic maintenance of the equipment (Bernardi et al., 2017).

Regarding the determinations of DM carried out in the different NIRS (Table 2), the Pb0 observed for NIRS 3 presented a significant estimate ($P < 0.05$), rejecting the null hypothesis, since the other NIRS showed non-significant Pb0 ($P > 0.05$), accepting the null hypothesis. When Pb0 is not significant, the intercept of the line (b0) will be statistically equivalent to zero, considering that the line will start from the origin (Cecon et al., 2012).

In the values of Pb1 for DM, the estimates were not significant ($P > 0.05$) for NIRS 1, 2 and 3, thus, for these NIRS, the angular coefficient (b1) is statistically equivalent to 0, as it was accepted the null hypothesis ($H_0: \beta_1 = 0$). The NIRS 4 estimates were significant ($P < 0.05$), therefore, accepting the alternative hypothesis ($H_a: \beta_1 \neq 0$). In this sense, the expected estimate of Pb1 tends to be significant ($P < 0.05$), so b1 will be different from zero, which grants the slope on the line (Minitab, 2013).

Pearson's correlation coefficient (r_{xy}) can be represented by a range from +1 to -1. Zero indicates that there is no association between the two variables, and a value greater than zero indicates a positive association. This means that, as the value of a variable increases, so does the value of the other variable; a value less than zero indicates a negative association, that is, as the value of one variable increases, the value of the other decreases (Guimarães, 2017). For DM r_{xy} , NIRS 1, 2 and 4 had a positive association and NIRS 3 a negative association, and the values of NIRS 2 and 4 are closer to 1, that is, for these the observations did not deviate much of the best-fit line, and this coefficient is indicative of precision (Lin, 1989).

Table 2. Precision, strictness, and accuracy indices of prediction models of the chemical composition of corns measured in the laboratory as a function of the chemical composition estimated by different NIRS for dry matter (DM), crude protein (CP), ether extract (EE), mineral matter (MM), crude fiber (CF) and non-nitrogen extractive (NNE), based on dry matter¹

	NIRS	P _{b0}	P _{b1}	r _{XY}	C _b	CCC
DM	1	0,889	0,141	0,500	0,136	0,068
	2	0,383	0,084	0,572	0,963	0,551
	3	0,001	0,582	-0,199	0,081	-0,016
	4	0,442	0,031	0,680	0,332	0,226
CP	1	0,803	0,001	0,901	0,406	0,366
	2	0,833	0,001	0,870	0,457	0,397
	3	0,240	0,001	0,889	0,512	0,455
	4	0,830	0,001	0,894	0,524	0,468
EE	1	0,683	0,021	0,712	0,788	0,561
	2	0,065	0,409	-0,295	0,554	-0,163
	3	0,704	0,133	0,510	0,649	0,330
	4	0,930	0,083	0,573	0,405	0,232
MM	1	0,984	0,396	0,302	0,254	0,077
	2	0,078	0,478	-0,254	0,729	-0,185
	3	0,012	0,181	-0,460	0,828	-0,381
	4	0,561	0,286	0,375	0,323	0,121
CF	1	0,447	0,380	0,312	0,046	0,014
	2	0,665	0,135	0,507	0,620	0,314
	3	0,393	0,378	0,314	0,112	0,035
	4	0,325	0,816	0,085	0,746	0,063
NNE	1	0,926	0,033	0,674	0,456	0,307
	2	0,489	0,483	0,252	0,502	0,126
	3	0,002	0,201	-0,442	0,108	-0,048
	4	0,218	0,033	0,673	0,316	0,212

¹n = number of pairs of sample observations = 10; P_{b0}: probability of significance for b₀; P_{b1}: probability of significance for b₁; r_{XY}: sample correlation coefficient between pairs of X and Y values; C_b: degree of agreement between Y and X; CCC: Lin's correlation coefficient of agreement or model accuracy index.

C_b, which is the degree of agreement between Y and X, represents an accuracy index, and measures how close the estimated line is to the equity line (Lin, 1989). For this index, the value closest to 1 for DM was obtained for NIRS 2 (Table 2), which indicates that for the other NIRS there is no proximity to the estimated line in relation to equity.

The CCC represents the correlation coefficient of linear agreement and was developed for pairs of independent measurements sampled from a bivariate population normally distributed with means (Lin, 1989). In this index, when the estimated value is closer to 1, the greater the chances of reproducibility of the values observed in the laboratory. The highest CCC for DM was presented by NIRS 2, showing itself to be closer to the fitted line.

The CCC is the model's accuracy index and can be estimated by replacing the population mean value, the variance, and the covariance parameters with their sample

counterparts. In other words, it is the product of the degree of agreement (C_b) and the coefficient of Pearson's correlation (Lin, 1989). The negative value for this coefficient observed in NIRS 3 refers to a low accuracy, due to low precision and accuracy.

Thus, it can be inferred that the best DM estimate was obtained by NIRS 2 in relation to the observed results, since it presented better r_{xy} , C_b and CCC. One way to ensure that the NIRS equipment provides a reliable reading of the chemical composition of the ingredients is by adjusting the calibration curves correctly, being necessary that the calibration set presents the quantity and variability of samples (Gontijo et al., 2010).

Regarding BP, it is noted that P_{b0} was not significant ($P_{b0} > 0.05$) in the case of all NIRS evaluated, therefore, the null hypothesis was accepted, and P_{b1} was also significant for all NIRS ($P < 0.05$), which indicates that the values of b_1 are statistically different from zero, which granted all the lines the desired slope.

The slope of the line (b_1) and the intercept (b_0) are responsible for defining the linear relationship between two variables and can be used to estimate an average rate of change. The greater the magnitude of the slope, the steeper the line and the greater the rate of change (Minitab, 2019b).

Still in relation to BP, r_{xy} indicated a positive association for all NIRS (Table 2) and all values were close to 1, that is, for these values the observations did not deviate much from the best fit line. When the value of r_{xy} is 1, the fitted line will be ideal. Thus, this parameter measures the linear relationship and how much each observation deviates from the best fit line (precision measure), but when analyzed individually it may fail to detect deviations (Lin, 1989).

The C_b for BP obtained by NIRS 3 and 4 were the closest to 1 (Table 2), which indicates that the line estimated by these NIRS is close to the equity line (accuracy measure) (Lin, 1989). It is observed that the CCC observed for all NIRS remained far from 1, which demonstrates that the data are far from the best fitted line. However, according to Lin (1989), there are flaws in all parameters, none is capable of evaluating completely the desired reproducibility characteristics and, for this reason, they were evaluated together in this work.

In this way, the NIRS that best estimated the CP values of the corn samples were NIRS 3 and 4, followed by NIRS 1 and 2 that showed lower effectiveness, as the accuracy was not so good, but all were able to estimate the CP. Ferreira et al. (2018), when using Bayesian inference in external validation, reported that BP was properly determined by the NIRS used.

As for the EE predictions, it is noted that for Pb0 all NIRS were not significant ($P>0.05$). Therefore, the null hypothesis in which b_0 is statistically equivalent to zero was accepted. As for Pb1, only NIRS 1 presented a significant estimate ($P<0.05$), which granted the line the desired slope.

The r_{xy} indicated a positive association for NIRS 1, 3 and 4 and a negative association for NIRS 2, that is, as the value of one variable increases, the value of the other decreases, and the r_{xy} obtained for NIRS 1, 3 and 4 are closer to 1, showing that the observations are not far from the best fit line. When the value of the precision measure (r_{xy}) is close to 1, the data are also close to the best fitted line, that is, the point cloud of the values estimated by NIRS is close to the best fit line of the values observed in the laboratory.

The C_b calculated for the EE showed that the values estimated by NIRS 1, 2 and 3 were close to 1 (Table 2), which indicates that the degree of proximity of the estimated line is close to the equity line. When the accuracy measure (C_b) approaches 1, it means that there is a high degree of proximity of the line estimated by NIRS in relation to the line of equity obtained by laboratory analyses.

The CCC gave all NIRS values far from 1, except for NIRS 1, so that the CCC evaluates the distance of pairs of measurements in relation to the bisector of the first quadrant; in other words, the distance between the best fitted straight line data and the bisector. When its value is close to 1, the measurements can be around the bisector of the first quadrant, and may therefore be considered concordant, since they have the reproducibility of measurements, that is, the estimated values will be equivalent to the observed values (Filgueira, 1990).

Regarding the EE, NIRS 1 was the one that best estimated the values, followed by NIRS 3 and NIRS 4 and 2, which showed similar efficacy. The results obtained corroborate those of Ferreira et al. (2018), in which they reported that the EE presented an adequate estimate when using the NIRS.

In the case of MM, it is noted that Pb0 was not significant ($P>0.05$) for NIRS 1, 2 and 4, therefore, the null hypothesis was accepted, being a result that is desirable when comparing the estimated values of NIRS in relation to those determined in the laboratory (observed). The NIRS 3 showed significant Pb0 ($P<0.05$). As for Pb1, all NIRS showed non-significant estimates ($P>0.05$), with no angulation on the estimated line.

The r_{xy} indicated a positive association for NIRS 1 and 4 and a negative association for NIRS 2 and 3. The C_b values observed for NIRS 2 and 3 were close to 1

for MM (Table 2), indicating that the degree of proximity of the estimated line is close to the equity line, and the CCC values for all NIRS remained far from 1.

The negative values found for r_{xy} and CCC for NIRS 2 and 3 may be related to the low specificity of the equipment in predicting the mineral content of the ingredients. According to Clark et al. (1987), minerals are indirectly read by NIRS, due to their associations with organic molecules.

Thus, for the MM estimates, the best result found was for the NIRS 2, but when comparing these results with the results of the other analyses, the NIRS did not provide a good prediction of the MM.

As for the CF predictions, the Pb_0 of all NIRS were not significant ($P < 0.05$), therefore, the null hypothesis was accepted. Pb_1 were not significant ($P > 0.05$) and did not confer an angulation to the estimated lines for these NIRS.

The r_{xy} for CF indicated a positive association for all NIRS (Table 2), but only NIRS 2 showed r_{xy} close to 1. The values obtained for Cb for NIRS 2 and 4 are the closest to 1, and for the CCC all NIRS remained far from 1. However, in order to obtain an agreement among the data, it is necessary that they present a good linear relationship, and that their values are similar across the spectrum of the data variation (Filgueira, 2005).

The best results found for CF were observed in NIRS 2, followed by NIRS 4. The other NIRS did not present a good estimate for CF. According to Ferreira et al. (2018), a good correlation was observed for the NDF estimation and a low correlation for the ADF estimation in the laboratory results and in those predicted by the NIRS. However, the results obtained in the present work show that the CF can demonstrate an adequate estimate in some NIRS, which demands greater attention to this parameter.

Only NIRS 3 presented significant Pb_0 ($P < 0.05$) for NNE, therefore, the null hypothesis was rejected (Table 2). NIRS 1, 2 and 4 were statistically equivalent to zero. As for Pb_1 , NIRS 1 and 4 were significant ($P < 0.05$), thus, for these NIRS, b_1 is different from zero, which granted a slope on the estimated line.

The r_{xy} for the NNE indicated a positive association for the NIRS 1, 2 and 4 and a negative association for the NIRS 3; for the NIRS 1 and 4 the value of r_{xy} is close to 1. The Cb show that the NIRS 2 presented a value closer to 1, and the CCC of all NIRS were far from 1.

The best results for the estimates of NNE were observed for NIRS 1 and 4, followed by NIRS 2. However, the NNE has limitations, as it is an estimate that incorporates all the errors of the analyzes that compose it (DM, CP, CF, EE, and MM),

especially CF, since it also has limitations related to the loss of part of the lignin and the non-separation of cellulose and hemicellulose (Andrigheto et al., 1982).

In the case of the starch estimates for the different maize cultivars (Table 3), it is noted that the Pb0 parameter of NIRS 1 and 2 were not significant ($P>0.05$), and NIRS 3 and 4 did not show a good set to b0 ($P<0.05$). When evaluating Pb1, it is noted that all NIRS were not significant ($P>0.05$).

The rxy for starch (Table 3) indicated a positive association for NIRS 1, 2 and 4 and a negative association for NIRS 3, but no value approached 1. For Cb, the value obtained by NIRS 2 was the closest to 1, which indicates that the degree of proximity of the estimated line is close to the equity line, and the CCC values of all NIRS remained far from 1.

The NIRS that best estimated the starch value was NIRS 2, followed by NIRS 3 and 4. It is extremely important that the NIRS correctly estimate the starch content of corn, as it effectively collaborates with the gross energy value of corn (Esteves et al., 2017). In addition, starch is used as a regressor in equations for predicting energy values for non-ruminant animals, such as the equation $NE = 0.730EM + 1.31EE + 0.37STA - 0.67CP - 0.97CF$ adjusted by Noblet et al. (1994) and which was also proposed by Rostagno et al. (2017) to predict the NE of ingredients for swine. However, there are external evaluation methodologies that can be performed to identify possible prediction deviations, due to differences in the sensitivity of the validation to be used.

Table 3. Precision, strictness, and accuracy indices of prediction models of the chemical composition of corns measured in the laboratory as a function of the chemical composition estimated by the four different NIRS for starch (STA) and organic matter (OM) on a dry matter basis¹

	NIRS	P _{b0}	P _{b1}	r _{XY}	C _b	CCC
STA	1	0,768	0,937	0,029	0,256	0,007
	2	0,439	0,926	0,034	0,569	0,019
	3	0,036	0,224	-0,423	0,643	-0,272
	4	0,001	0,634	0,172	0,519	0,089
OM	1	0,871	0,165	0,476	0,126	0,060
	2	0,395	0,192	0,450	0,932	0,419
	3	0,001	0,499	-0,243	0,093	-0,023
	4	0,527	0,043	0,647	0,452	0,293

¹n = number of pairs of sample observations = 10; P_{b0}: probability of significance for b₀; P_{b1}: probability of significance for b₁; r_{XY}: sample correlation coefficient between pairs of X and Y values; C_b: degree of agreement between Y and X; CCC: Lin's correlation coefficient of agreement or model accuracy index.

As for the calculated OM, it is noted that the P_{b0} (Table 3) of NIRS 1, 2 and 4 were not significant (P>0.05), therefore, the null hypothesis was accepted. As for P_{b1}, only NIRS 4 was significant (P<0.05), which granted the slope to the estimated line.

Regarding r_{xy} to evaluate the estimates of OM in different NIRS, a positive association is observed for NIRS 1, 2 and 4 and a negative association for NIRS 3, with only NIRS 4 having a value close to 1. For C_b, the value obtained by NIRS 2 is the closest to 1, indicating that the degree of proximity to the estimated line is close to the equity line. The CCC values of all NIRS remained far from 1.

The best result estimated for corn OM was obtained by NIRS 4, followed by NIRS 2. However, as the OM is calculated from other variables, it can aggregate their errors, as it happens with the NNE.

When evaluating Tables 2 and 3 together, it can be inferred that NIRS 2 and 4 provided the best estimates of chemical composition when compared to conventional laboratory analyses, followed by NIRS 1 and 3.

The obtained results may also be related to equipment calibration, in addition to component maintenance, which in turn is essential to obtain accurate and reliable results. The verification of curves and readjustment is performed when necessary (Sena; Almeida, 2018), and external validation is a tool used to assess the precision and accuracy of NIRS equipment.

The success of the results estimated by the NIRS depends on the reliability of the results of the bromatological analyses, the standardization of the spectral reading, the mathematical treatments chosen for each spectrum and the adjustment of the calibration curves (Ferreira et al., 2018).

CONCLUSION

It is concluded that the chemical composition estimates obtained by the NIRS equipment with different calibration curves present variables with adequate estimates (crude protein, ether extract and starch), while others are inaccurate (dry matter, mineral matter, crude fiber, non-nitrogen extractives and organic matter). Therefore, the external validation should be used as a tool to assess the precision and accuracy of chemical composition estimates.

REFERENCES

- Andriguetto JM, Perly L, Minardi I, Gemael A, Flemming JS, Souza GA, Bona Filho A. *Nutrição animal: as bases e os fundamentos da nutrição animal - Os Alimentos*, Vol. I, São Paulo:Nobel, 1982. 395 p.
- Araujo FFD. 2011. Disponibilização de fósforo, correção do solo, teores foliares e rendimento de milho após a incorporação de fosfatos e lodo de curtume natural e compostado. *Acta Scientiarum. Agronomy*, 33: 355-360.
- Bernardi A, De Lima JD, Oliveira GA, Trentin MG. 2017. Análise de investimento em segregação de milho: estudo de caso em agroindústria produtora de rações para frangos de corte. *Custos e Agronegócio On-line*. 13(4):147-171.
- Cecon PR, Silva AR, Nascimento M, Ferreira A. 2012. *Métodos Estatísticos*. Viçosa: Ed. UFV. p. 229.
- Chein F. 2019. Introdução aos modelos de regressão linear: um passo inicial para compreensão da econometria como uma ferramenta de avaliação de políticas públicas.
- Clark DH; Mayland HF, Lamb RC. 1987. Mineral Analysis of Forages with near Infrared Reflectance Spectroscopy1. *Agronomy Journal* 79: 485-490.
- Denardin CC, Silva LPD. 2009. Estrutura dos grânulos de amido e sua relação com propriedades físico-químicas. *Ciência Rural*, 39: 945-954.
- Dong W, Li J, Li Z, Zhang S, Li X, Yang C, Liu L, Zhang S. 2020. Physicochemical properties and energy content of yellow dent corn from different climatic origins in growing pigs. *Asian-Australasian journal of animal sciences*, 33(11): 1787.
- Donzele JL, Silva FDO, Ferreira AS, Freitas RD, Kill JL. 1998. Digestibilidade e Metabolizabilidade da Energia de Rações com Diferentes Níveis de Óleo de Soja para Suínos. *Revista Brasileira de Zootecnia*, 27(5): 922-927.

- Ellery EAC, Watanabe PH, Carvalho LE, Bertol TM, Freitas ER, Gomes TR, Oliveira, EL, Nepomuceno RC. 2015. Development and ex post validation of prediction equations of corn energy values for growing pigs. *Semina: Ciências Agrárias*, 36(3): 1755-1763.
- Esteves LAC, Oliveira NTED, Huepa LMD, Ferreira SL, Castilha LD, Pozza PC. 2017. Predicting the metabolizable energy of first and second corn harvests for piglets. *Ciência e Agrotecnologia*, 41(6): 683-691.
- Ferreira SL, Vasconcellos RS, Rossi RM, Paula VRCD, Fachinello MR, Huepa LMD, Pozza PC. 2018. Using near infrared spectroscopy to predict metabolizable energy of corn for pigs. *Scientia Agricola*, 75(6): 486-493.
- Filgueira JM. 2005. Avaliação De Satisfação de Cliente: Proposta de Utilização do Coeficiente de Correlação de Concordância. *Holos*, 2: 47-56.
- Gontijo MMN, Simeone M, Guimaraes CDC, Vasconcelos FV. 2010. Predição de proteína em grãos de milho pela espectroscopia de reflectância no infravermelho próximo. In: Embrapa Milho e Sorgo-Artigo em anais de congresso (ALICE). In: CONGRESSO NACIONAL DE MILHO E SORGO, 28.; SIMPÓSIO BRASILEIRO SOBRE A LAGARTA DO CARTUCHO, 4., 2010, Goiânia. Potencialidades, desafios e sustentabilidade: resumos expandidos... Sete Lagoas: ABMS.
- Gottardo A, De Oliveira L, Bernardo TRT. 2015. Calibração do equipamento de espectroscopia de infravermelho próximo (NIRS) para a determinação da qualidade bromatológica de concentrados e pastagens. *Salão do Conhecimento*.
- Guimarães PRB. 2017. Análise de Correlação e medidas de associação. Universidade Federal do Paraná. Disponível em:< <https://docs.ufpr.br/~jomarc/correlacao.pdf>>. Acesso em, 9/10/2020.
- Kil DY, Kim BG, Stein HH. 2013. Feed energy evaluation for growing pigs. *Asian-Australasian Journal of Animal Sciences*, 26(9): 1205-127.
- Li Q, Zang J, Liu D, Piao X, Lai C, Li D. 2014. Predicting corn digestible and metabolizable energy content from its chemical composition in growing pigs. *Journal of animal science and biotechnology*, 5(1): 1-8.
- Lin IKL. 1989. A concordance correlation coefficient to evaluate reproducibility. *Biometrics*, 255-268.
- Loy DD, Lundy EL. 2019. Nutritional properties and feeding value of corn and its coproducts. In: S. O., and Serna-Saldivar, editors, *Corn: chemistry and technology*. Elsevier Inc., Cambridge, MA, United States. p. 633-654.
- Lyu Z, Li Q, Zhang S, Lai C, Huang C. 2019. Available energy and amino acid digestibility of yellow dent corn fed to growing pigs. *Journal of animal science*, 97(7):. 2952-2964.
- Malavolta E, Vitti GC, Oliveira SA. 1997 Avaliação do estado nutricional das plantas: princípios e aplicações. 2.ed. Piracicaba, POTAFOS, 319p.

- Minitab. 2013. How to Interpret Regression Analysis Results: P-values and Coefficients. Disponível em: <<https://blog.minitab.com/en/adventures-in-statistics-2/how-to-interpret-regression-analysis-results-p-values-and-coefficients>> Acesso em: 20 dez. 2021.
- Minitab. 2019a. Understanding t-tests: t-values and t-distributions. Disponível em: <<https://blog.minitab.com/pt/como-entender-os-testes-t-valores-t-e-distribuicoes-t>> Acesso em: 20 dez. 2021.
- Minitab. 2019b. Como escolher o melhor modelo de regressão. Disponível em: <<https://blog.minitab.com/pt/como-escolher-o-melhor-modelo-de-regressao>> Acesso em: 20 dez. 2021.
- NATIONAL RESEARCH COUNCIL - NRC. 2012. Nutrient requirements of swine. 11 ed. Washington, DC: National Academy.
- Noblet J, Fortune H, Shi XS, Dubois S. 1994. Prediction of net energy value of feeds for growing pigs. *Journal of animal science*, 72(2): 344-354.
- Pelizzeri RN, Pozza PC, Oliveira NTE, Somensi ML, Furlan AC, Neumann ME. 2013. Avaliação de modelos de predição da energia metabolizável do milho para suínos. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, 65(2): 460-468.
- Piovesan V, Oliveira VD, Araújo JDS. 2010. Predição do conteúdo de aminoácidos essenciais do grão de milho. *Ciência e Agrotecnologia*, 34: 758-764.
- Prestes ID, Rocha LO, Nuñez KV, Silva NC. 2019. Principais fungos e micotoxinas em grãos de milho e suas consequências. *Scientia Agropecuaria*, 10(4): 559-570.
- R Core Team 2021. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<http://www.R-project.org/>> Acesso em: 02/02/2022.
- Rostagno HS, Albino LFT, Hannas MI, Donzele JL, Sakomura NK, Perazzo FG, Saraiva A, Teixeira ML, Rodrigues PB, Oliveira RF, Barreto SL, Brito CO. 2017. Tabelas Brasileiras Para Aves e Suínos: Composição de Alimentos e Exigências Nutricionais Departamento de Zootecnia-UFV, Viçosa, MG, BR.
- Santos T. 2019. Valor dado pela tangente do ângulo de inclinação. *Educa Mais Brasil*. Disponível em: <<https://www.educamaisbrasil.com.br/enem/matematica/coeficiente-angular>> Acesso em: 20 dez. 2021.
- Sena MM, Almeida MR. Quimiometria Aplicada aos Dados Espectrais no Infravermelho Próximo. In: Tibola CS, Medeiros EP, Simeone MLF, Oliveira MA. 2018. Espectroscopia no infravermelho próximo para avaliar indicadores de qualidade tecnológica e contaminantes em grãos. Embrapa Trigo-Livro científico (ALICE).
- Siesler HW. 2007. Basic Principles of Near-Infrared Spectroscopy In: Burns, D.A; Ciurczak, E.W. *Handbook Near-infrared spectroscopy*. Third Edition. Practical Spectroscopy. 35: 7-20.

- Silva DJ, Queiroz AC. 2005. Análises de alimentos: métodos químicos e biológicos. 3.ed. Viçosa: UFV, 235p.
- Smith B, Hassen A, Hinds M, Rice D, Jones D, Sauber T, Iiams C, Sevenich D, Allen R, Owens F, et al. 2015. Predicting the digestible energy of corn determined with growing swine from nutrient composition and cross-species measurements. *Journal of animal science*, 93(3): 1025-1038.
- Tallada JG, Palacios-Rojas N, Armstrong PR. 2009. Prediction of maize seed attributes using a rapid single kernel near infrared instrument. *Journal of Cereal Science* 50: 381-387.
- Varga J, Baranyi N, Chandrasekaran M, Vágvölgyi C, Kocsubé S. 2015. Mycotoxin producers in the *Aspergillus* genus: An update. *Acta Biologica Szegediensis*, 59(2): 151-167.
- Wajizah S, Munawar AA. 2018. Fast and simultaneous prediction of animal feed nutritive values using near infrared reflectance spectroscopy. *IOP Conference Series: Earth and Environmental Science*, v. 122, n. 1. Disponível em: <<https://iopscience.iop.org/article/10.1088/1755-1315/122/1/012112/pdf>> Acesso em: 07 set. 2019.
- Walker J, Tolleson D, Byrns S, Bengé P. 2010. Shining light on manure improves livestock and land management. SANG, 2010.
- Williams PC, Sobering DC. 1993. Comparison of commercial near infrared transmittance and reflectance instruments for analysis of whole grains and seeds. *Journal of Near Infrared Spectroscopy*, 1(1): 25-33.
- Zanotto DL, Coldebella A, Ludke JV, Bertol TM. 2015. Equação de predição da energia metabolizável do milho para suínos. In: Salão Internacional de Avicultura e Suinocultura - SIAVS, Anhenbi, SP. Anais..., Anhenbi, SP, 240 – 243.

IV - PREDICTION OF THE METABOLIZABLE ENERGY OF CORN FOR SWINE USING NEAR INFRARED REFLECTANCE SPECTROSCOPY - NIRS

ABSTRACT - The objective of this study was to evaluate the prediction of metabolizable energy (ME) of corn for swine, using the chemical composition estimates obtained by different NIRS (near infrared reflectance spectroscopy) equipment in different prediction equations. The forty-four barrows used were distributed in a randomized block design with 10 treatments and 4 replications. The treatments consisted of 10 corn cultivars, which replaced 25% of the reference feed, and the Total Collection Method was used. The values of ME determined in the metabolism assay were considered as 'observed'. NIRS was used to determine the regressors of the prediction equations to evaluate the predicted ME, and 20 prediction equations were used. The ME estimates obtained by using the prediction equations for the 10 corn cultivars were evaluated by determining the standard deviation (SD) and coefficient of variation (CV), and also by the approach based on the mean squared deviation (MSD) concerning the ME values found. The digestible energy (DE) and ME values ranged from 3,360 to 3,596, and from 3,332 to 3,541 kcal/kg, respectively. The equations that presented the lowest SD and CV values were equations 20, with 3.33 and 0.09%, and 19, with 4.49 and 0.12% (for NIRS 1); equations 20, with 4.47 and 0.12%, and 19, with 5.51 and 0.14% (for NIRS 2); equations 18, with 2.89 and 0.08%, and 20, with 5.55 and 0.14% (for NIRS 3); and, finally, equations 20, with 5.00 and 0.13%, and 19, with 7.52 and 0.19% (for NIRS 4). It can be concluded that the best prediction equation was $EM_6 = 16482 - 35,7CF$, as it presented the lowest MSD. As for the equations that best estimated the ME for all the four NIRS equipment, $ME_9 = 16,81 - 0,031CF$ and $ME_{18} = 3675,39 + 50,02EE - 25,62CF$ stood out.

Keywords: chemical composition, prediction equation, precision

IV - PREDIÇÃO DA ENERGIA METABOLIZÁVEL DO MILHO PARA SUÍNOS COM O USO DA ESPECTROSCOPIA DE REFLECTÂNCIA NO INFRAVERMELHO PRÓXIMO - NIRS

RESUMO – O objetivo deste trabalho foi avaliar a predição da energia metabolizável (EM) do milho para suínos, utilizando as estimativas de composição química obtidas por diferentes NIRS (espectroscopia de refletância no infravermelho próximo) em diferentes equações de predição. Foram utilizados 44 suínos, machos castrados, distribuídos em delineamento experimental de blocos ao acaso com 10 tratamentos e 4 repetições. Os tratamentos consistiram de 10 cultivares de milho, os quais substituíram em 25% a ração referência, o método de coleta total foi utilizado. Os valores de EM determinados no ensaio de metabolismo foram considerados como observados e foram utilizados os NIRS para determinação das regressoras das equações de predição para proceder com a avaliação das EM preditas, sendo utilizadas 20 equações de predição. As estimativas de EM ao utilizar as equações de predição, para os 10 milhos avaliados, foram avaliadas mediante determinação do desvio padrão (DP) e coeficiente de variação (CV) e também pela abordagem baseada no quadrado médio do erro de predição (QMEP) em relação aos valores de EM observados. Os valores de energia digestível (ED) e EM variaram de 3.360 a 3.596 e de 3.332 a 3.541 kcal/Kg, respectivamente. As equações que apresentaram os menores valores de DP e CV para o NIRS 1 foram a equação 20 com 3,33 e 0,09% e a equação 19 com 4,49 e 0,12%; para o NIRS 2 a equação 20 com 4,47 e 0,12% e a equação 19 com 5,51 e 0,14%; o NIRS 3 a equação 18 com 2,89 e 0,08% e a equação 20 com 5,55 e 0,14% e o NIRS 4 apresentou a equação 20 com 5,00 e 0,13% e a equação 19 com 7,52 e 0,19%. Neste trabalho, pode-se concluir que a melhor equação de predição foi a $EM_6 = 16482 - 35,7FB$, pois apresentou o menor QMEP, e com relação as equações que melhor estimaram a EM para todos os NIRS destacam-se a $EM_9 = 16,81 - 0,031FB$ e a $EM_{18} = 3675,39 + 50,02EE - 25,62FB$.

Palavras-chave: composição química, equação de predição, precisão

INTRODUCTION

Corn is commonly used in commercial diets for swine, with high energy content and few problems related to anti-nutritional factors, high concentration of starch, and low concentration of fiber. One of the ways to maximize apparent digestibility is to provide corn with adequate particle size, allowing its nutrients to have a good rate of digestion and absorption in the intestine of the animals (Rojas et al., 2015; Stein et al., 2016).

Energy is the most expensive nutritional component in animal feed, and corn has a significant contribution in this sense, for it represents 50 to 70% of the metabolizable energy (ME) of a corn and soybean meal-based diet (Kil et al., 2014). However, its nutrient content can vary, which consequently leads to variations in energy concentration. This influences the animal's feed conversion, which may cause significant economic losses (Dozier et al., 2011; Li et al., 2014). Thus, variations in chemical composition and in ME values of corn must be paid attention to when formulating diets, so that pigs can express their maximum genetic potential.

This being said, making sure that formulations will be accurate requires adequate knowledge of the energy content of foods, and direct or indirect methods can be used to determine it (Esteves et al., 2017). Metabolism assays (direct method) are laborious, time-consuming, and costly. They also require specific infrastructure and demand animals to be available, which makes it difficult to put them into practice (Noblet et al., 1994). On the other hand, prediction equations (indirect method), which are used to obtain ME values from the chemical composition of foods, are a practical way to predict ME (Pelizzeri et al., 2013).

The functionality of the ME prediction equations combined with the practicality of determining the chemical composition of foods by using the NIRS (Near Infrared Spectroscopy) technology allows for the formulation of more accurate diets, avoiding unnecessary expenses related to excessive amounts of ingredients (Ferreira et al., 2018).

The use of ME prediction equations, combined with NIRS chemical composition readings, must be properly evaluated, as there might be prediction errors related to both the composition estimates and the models adjusted to estimate the ME of feed ingredients (Ferreira et al., 2018).

This work aimed to evaluate the prediction of the metabolizable energy of corn for swine, using chemical composition estimates obtained by different NIRS equipment through different prediction equations.

MATERIAL AND METHOD

The experiment was carried out in the swine metabolism room of the Experimental Farm of Iguatemi (FEI), which belongs to the State University of Maringá (UEM). The experimental procedures were approved by the Animal Research Ethics Committee (CEUA n° 7058300320).

To obtain great variability in chemical composition, ten corn cultivars, from different regions of the state of Paraná, were used. Forty-four barrows, with an average initial weight of $72.61\text{kg} \pm 6.10\text{kg}$, were housed in metabolism cages and distributed in a randomized block experimental design, with ten treatments (corn cultivars) and a reference diet, and each experimental unit consisted of one animal. The initial weight of the animals was taken into consideration for dividing the blocks. They were separated and individually housed in metabolic cages, located in a partially acclimatized room. The average minimum and maximum temperatures during the experiment were $19.91\text{ °C} \pm 2.34$ and $23.79\text{ °C} \pm 2.79$, respectively.

The corn cultivars replaced 25% of the reference feed (Table 1), whose formula was based on corn and soybean meal, to meet the nutritional requirements of barrows with high genetic potential and medium-high performance, weighing 70 to 100 kg (Rostagno et al., 2017).

Table 1. Composition of the reference feed in natural matter

Ingredients	%
Corn grain	80,78
Soybean meal	14,08
Soybean oil	2,00
Dicalcium phosphate	0,80
Limestone	0,63
Salt	0,39
L-Lysine HCl 78,4%	0,40
DL-Methionine 99,0%	0,11
L- Threonine 98,0%	0,14
L- Tryptophan 98,5%	0,05
L-Valine 99,9%	0,05
Mineral Vitamin Mixture ¹	0,40
Enramycin	0,02
BHT ²	0,01
Calculated Composition (%)	
Metabolizable Energy (kcal/kg)	3350
Crude Protein	12,73
Calcium	0,50
Available Phosphorus	0,24
Sodium	0,17
Potassium	0,52
Chlorine	0,31
Digestible Lysine	0,81
Methionine + Digestible Cystine	0,48
Digestible methionine	0,28
Digestible tryptophan	0,16
Digestible threonine	0,52
Digestible phenylalanine	0,55
Phenylalanine + Digestible Tyrosine	0,95
Digestible histidine	0,30
Digestible isoleucine	0,44
Digestible leucine	1,06
Digestible valine	0,56

¹Supplementation of vitamins, minerals and additives per kg of product: Vit A - 30000 UI; Vit D3 - 5000 UI; Vit E - 120 UI; Vit B12 - 120 mcg; Vit K - 5 mg; Niacin - 150 mg; Calcium Pantothenate - 75 mg; Folic Acid - 8 mg; Choline Hydrochloride - 0.48 g; Iron - 350 mg; Copper - 15 mg; Magnesium - 250 mg; Zinc - 0.75 g; Iodine - 10 mg; Selenium 3 mg; ²Butylated hydroxytoluene.

The ten different corn cultivars evaluated were ground by a hammer grinder, equipped with a sieve which had 2.5mm diameter holes.

The daily amount of feed provided was calculated based on the metabolic weight ($\text{kg}^{0.75}$) of each animal and the average consumption throughout the 7 days of the adaptation period. To avoid losses and facilitate ingestion, the feed was moistened with water, by approximately 30% of the feed content, and pigs were provided with it twice a day, at 7:30 am and 3:30 pm.

After each meal, water was placed in the feeder. The proportion was 3mL of water/g of feed to avoid excessive water intake and, thus, not compromise feed consumption. The experimental period lasted 12 days, that is, seven days for the animals to adapt to the metabolism cages and the feed, and five days for feces and urine collection, which was performed once a day, at 8:00 am.

To determine the initial and final period of feces collection, 2% of ferric oxide (Fe₂O₃) were added to the diets. The collected feces were placed in plastic bags and stored in a freezer (-18 °C). In the end, each sample was thawed and homogenized, and a 300 g aliquot was removed and dried in a forced ventilation oven (55 °C) for 72 hours. Subsequently, the samples were ground by a knife grinder equipped with a 1mm sieve.

Urine was daily collected in plastic buckets containing 20 mL of 1:1 HCl to prevent bacterial proliferation. After being filtered, aliquots of urine (10% of the total volume) were placed in plastic bottles, identified according to each animal, and stored in a refrigerator (3 °C), so that the gross energy (GE) analysis could be performed later.

The GE values of the corn cultivars, reference feed, feces, and urine were quantified at the Research Support Center Complex - COMCAP, by using an adiabatic calorimeter (Parr ® Instrument Co. AC6200), according to the procedures described by Silva and Queiroz (2005).

The values of digestible energy (DE), metabolizable energy (ME), gross energy digestibility coefficients (GEDC), and gross energy metabolizability coefficients (GEMC) were determined, as well as the ME:DE ratio of each cultivar.

Analysis of variance (ANOVA) was performed using the PROC GLM command with the aid of the SAS statistical program, version 9.2 (SAS Inst. Inc., Cary, NC), followed by the Student Newman Keuls – SNK test to compare the GEDC and GEMC means.

Twenty ME prediction equations found in the literature were evaluated (Table 2). To obtain the predicted ME, the values of the chemical composition of corn obtained by each NIRS equipment were used in the equations, whose regressors were crude protein (CP), ether extract (EE), mineral matter (MM), crude fiber (CF) and organic matter (OM).

Table 2. Prediction equations used to estimate corn ME

Item ¹	Equation	Unit	R ²	Source
ME ₁	4369 - 10,9MM + 4,1EE - 6,5CF	(Kcal/Kg)	0,87	Noblet & Perez (1993)
ME ₂	4168 - 12,3 MM + 1,4CP+ 4,1EE - 6,1CF	(Kcal/Kg)	0,88	Noblet & Perez (1993)
ME ₃	17498 - 49,6CF	(KJ/Kg)	0,83	Just et al. (1984)
ME ₄	15894 + 10,3EE - 35,1CF	(KJ/Kg)	0,74	Just et al. (1984)
ME ₅	15240 + 3,3CP + 9,5EE - 34,9CF	(KJ/Kg)	0,76	Just et al. (1984)
ME ₆	16482 - 35,7CF	(KJ/Kg)	0,69	Just et al. (1984)
ME ₇	-3068 + 20,2OM - 28,7 CF	(KJ/Kg)	0,70	Just et al. (1984)
ME ₈	-3001 + 20OM - 28,3CF	(KJ/Kg)	0,70	Just et al. (1984)
ME ₉	16,81 - 0,031CF	(MJ/Kg)	0,68	Lekule et al. (1990)
ME ₁₀	16,34 - 0,034CF + 0,003CP	(MJ/Kg)	0,73	Lekule et al. (1990)
ME ₁₁	3221,47 + 60,91CP - 29,04MM	(Kcal/Kg)	0,86	Ferreira et al. (1997)
ME ₁₂	5086,31 + 142,047EE - 328,102MM - 154,842CP	(Kcal/Kg)	0,39	Esteves et al. (2017)
ME ₁₃	4578,66 + 155,598EE - 150,446CP	(Kcal/Kg)	0,30	Esteves et al. (2017)
ME ₁₄	3522,57 + 82,2153EE	(Kcal/Kg)	0,11	Esteves et al. (2017)
ME ₁₅	5815,85 - 229,461CP	(Kcal/Kg)	0,23	Esteves et al. (2017)
ME ₁₆	19,13 - 0,61EE	(MJ/Kg)	0,21	Yang et al. (2020)
ME ₁₇	21,55 - 0,29CP - 0,55EE	(MJ/Kg)	0,27	Yang et al. (2020)
ME ₁₈	3675,39 + 50,02EE - 25,62CF	(Kcal/Kg)	-	Oliveira et al. (2018)
ME ₁₉	3824,44 - 105,29MM + 45,01EE	(Kcal/Kg)	-	Oliveira et al. (2018)
ME ₂₀	3982,99 - 79,97MM	(Kcal/Kg)	-	Oliveira et al. (2018)

¹ME(x), the suffixes correspond to the number of equations analyzed; R² - Determination coefficient.

The evaluation of the prediction equations consisted of the analysis of the standard deviation (SD) and the coefficient of variation (CV) of the estimated ME means for the corn cultivars, using the values of chemical composition determined by the four NIRS equipment and, also, through the approach based on the mean squared deviation (MSD), which, according to Kobayashi and Salam (2000), is the most suitable method for comparing observed and predicted values, in addition to being an easily interpretable analysis.

RESULTS AND DISCUSSION

The SD of the OM that was calculated, estimated by NIRS 3 and 4, was higher (Table 3). Yet, OM is a calculated estimate related to MS and MM. Therefore, it aggregates the prediction errors of these two estimates determined through NIRS.

Regarding MM, the SD for NIRS 1 had the lowest numerical value compared to the others (Table 3). In the validation set used by Ferreira et al. (2018), the SD of the nine corn cultivars was 0.15. The authors also reported that the MM estimates obtained through NIRS were not very accurate.

The SD values found for CP and EE were lower than 0.67 and 0.34, which are values presented by Ferreira et al. (2018), with emphasis on greater dispersion for the SD of the CP of NIRS 3 (0.48) (Table 3). In general, the SD values were not high for all NIRS determinations (Table 3).

Table 3. Minimum, maximum, mean, and standard deviation (SD) of the chemical composition of corn cultivars predicted by the four different NIRS equipment in dry matter

Item	NIRS	Minimum	Maximum	Mean	SD
OM ¹	1	98,47	98,60	98,56	0,04
	2	98,65	98,77	98,72	0,06
	3	98,68	98,90	98,73	0,07
	4	98,79	98,95	98,89	0,07
MM ²	1	1,40	1,53	1,44	0,04
	2	1,23	1,35	1,28	0,06
	3	1,10	1,32	1,27	0,07
	4	1,05	1,21	1,11	0,07
CP ³	1	8,05	9,39	8,99	0,38
	2	7,94	9,34	8,94	0,40
	3	7,86	9,45	8,93	0,48
	4	7,84	9,18	8,85	0,40
EE ⁴	1	3,95	4,54	4,21	0,20
	2	4,31	4,82	4,53	0,15
	3	4,14	4,52	4,27	0,13
	4	4,41	5,08	4,72	0,19
CF ⁵	1	1,17	1,43	1,33	0,09
	2	2,13	2,38	2,27	0,09
	3	1,43	1,74	1,60	0,11
	4	2,11	2,44	2,24	0,11

¹Organic Matter, ²Mineral Matter, ³Crude Protein, ⁴Ether Extract, ⁵Crude Fiber.

The GB of the corn cultivars under evaluation (Table 4) ranged from 3.906 to 3.995 kcal/kg, a variation of 89 kcal/kg, which is superior to the 3.865 to 3.936 Kcal/kg range proposed by Rostagno et al. (2017).

The GEDC ranged from 84.7 to 91.70% (Table 4), which is higher than the 87.42 to 89.37% range obtained by Castilha et al. (2011). Despite the variations in the GEDC found for the different corn cultivars, there were no statistical differences ($P>0.05$). The chemical composition of food is the main determinant factor for digestible energy, more precisely EE, CP, CF, and STA, whereas NDF and MM relate negatively to DE and ME (Li et al., 2014).

The DE results (Table 4) ranged from 3,360 to 3,596 kcal/kg, a high variation which suggests that the values of each corn cultivar should be considered in feed formulation, since average values may not adequately represent the DE values, like the average value suggested by Li et al. (2016), that is, 3,482 kcal/kg. However, the ME values ranged from 3,332 to 3,541 kcal/kg, a variation that was greater than the 3,280 to 3,383 kcal/kg range reported by Castilha et al. (2011), which stresses how necessary it is to be aware of ME values.

Table 4. Energy values, energy metabolizability coefficients, and energy digestibility coefficients of different types of corn for swine, expressed in natural matter

Corn	GE ¹ (kcal/kg)	GEDC ² (%)	DE ³ (kcal/kg)	GEMC ⁴ (%)	ME ⁵ (kcal/kg)	ME:DE ⁶
1	3928	91,73	3587	89,76	3541	98,70
2	3963	84,70	3360	84,15	3332	99,16
3	3907	89,50	3497	88,27	3449	98,61
4	3954	88,99	3528	85,68	3449	97,73
5	3995	87,34	3514	87,36	3458	98,39
6	3906	88,56	3466	87,47	3409	98,38
7	3977	88,41	3516	86,91	3456	98,28
8	3915	90,27	3596	90,98	3499	97,54
9	3950	87,87	3477	86,08	3393	97,53
10	3965	90,18	3576	89,11	3533	98,81
CV% ⁷	-	3,32	-	3,43	-	-

¹Gross energy, ²Gross energy digestibility coefficient, ³Digestible energy, ⁴Gross energy metabolizability coefficient, ⁵Metabolizable energy, ⁶ME:DE ratio, ⁷Coefficient of variation.

According to Noblet and Perez (1993), the use of DE and ME by pigs is influenced by the composition of the diet, and high values mean good use of nutrients, which was the case of all cultivars evaluated in this study.

Regarding the GEMC, there was a variation of 84.15 to 90.98% between the different corn samples (Table 4). It is higher than that found by Castilha et al. (2011), which ranged from 84.01 to 86.00%. However, the GEMC values were similar ($P>0.05$) among themselves, despite the amplitude between the data.

The values of the ME:ED ratio (Table 4) were superior to 97.60%, higher than the ones presented by Rostagno et al. (2017), and the 96.00 to 97.00% variation reported by Castilha et al. (2011), but close to 98.00%, the value suggested by the NRC (2012). According to Noblet and Perez (1993), the ME:DE ratio is linearly correlated with the CP content of a diet. In this study, corn CP did not present significant SD (Table 3), which may have contributed to a smaller variation between the ME:DE of the different cultivars (Table 4).

The mean, minimum and maximum values, SD, and CV of the ME estimated by twenty different prediction equations, using chemical composition data estimated by four NIRS equipment, are shown in Table 5.

NIRS 1 (Table 5) had the lowest SD for equations 1, 19, and 20, with 3.33 for equation 20, 4.49 for equation 19, and 6.19 for equation 1. As for NIRS 2, the lowest SD values were found for equations 20 (4.47), 19 (5.51), and 8 (6.24). Regarding NIRS 3, equations 18, 20, and 19 had the lowest SD values, that is, 2.89, 5.55, and 7.11, respectively. Finally, for NIRS 4, equations 20, 19, and 8 had the lowest SD values, which were 5.00, 7.52, and 8.00, respectively.

SD is used to measure how homogeneous a data set is. However, when analyzed in isolation, it may fail to detect intensity because, as it can be noticed (Table 5), it oscillates as the mean increases or decreases (Reed; Lynn; Meade, 2002).

Thus, SD must be analyzed together with the CV, which weighted the dispersion around the average value of the set (Al-Saleh; Yousif, 2009). Thus, NIRS 1 (Table 5) presented CV of 0.09% for equation 20; 0.12% for equation 19 and 0.14% for equation 1; NIRS 2 presented CV of 0.12% for equation 20; 0.14% for equation 19 and 0.16% for equation 8; NIRS 3 presented CV of 0.08% for equation 18; 0.14% for 20 and 0.18% for 19; and NIRS 4 presented CV of 0.13% for equation 20; 0.19% for equation 19 and 0.21% for equation 8.

Table 5. Mean values, standard deviations, minimum and maximum values, coefficients of variation, and metabolizable energy values estimated by twenty different equations, considering chemical composition values estimated by different NIRS equipment, expressed in dry matter

		ME ₁	ME ₂	ME ₃	ME ₄	ME ₅	ME ₆	ME ₇	ME ₈	ME ₉	ME ₁₀	ME ₁₁	ME ₁₂	ME ₁₃	ME ₁₄	ME ₁₅	ME ₁₆	ME ₁₇	ME ₁₈	ME ₁₉	ME ₂₀
NIRS1	Mean	4297,74	4207,75	4024,76	3790,93	3698,15	3826,03	3933,88	3904,05	3916,78	3859,46	3727,36	3817,24	3879,9	3868,32	3752,06	3956,47	3971,77	3851,74	3861,69	3867,51
	SD	6,19	9,42	10,04	7,94	9,90	7,23	6,52	6,43	6,27	8,42	22,52	57,09	52,87	16,15	87,31	28,62	43,71	9,31	4,49	3,33
	Min	4288,71	4188,63	4013,08	3779,67	3679,75	3817,62	3927,71	3897,95	3909,49	3844,72	3671,28	3752,71	3806,1	3847,55	3661,3	3907,61	3900,32	3837,6	3855,25	3860,73
	Max	4305,13	4218,27	4043,8	3800,28	3710,25	3839,74	3946,13	3916,14	3928,68	3874,78	3749	3958,98	4002,45	3895,89	3967,81	3993,29	4052,86	3867,74	3868,02	3871,26
	CV	0,14	0,22	0,25	0,21	0,27	0,19	0,17	0,16	0,16	0,22	0,60	1,50	1,36	0,42	2,33	0,72	1,10	0,24	0,12	0,09
NIRS2	Mean	4267,47	4182,83	3912,88	3719,78	3626,43	3745,5	3876,98	3847,98	3846,9	3782,45	3729,02	3924,65	3938,21	3895,14	3763,61	3908,95	3932,41	3843,87	3893,47	3880,5
	SD	7,30	11,06	10,98	8,49	10,32	7,91	6,33	6,24	6,86	9,16	24,29	61,47	58,70	12,16	91,92	21,55	37,76	7,71	5,51	4,47
	Min	4254,94	4157,12	3899,87	3705,08	3604,27	3736,14	3868,36	3839,46	3838,77	3766,32	3668,67	3857,36	3857,04	3876,79	3672,25	3867,31	3900,24	3829,9	3884,86	3875,01
	Max	4277,43	4196,97	3930,04	3733,09	3642,08	3757,85	3889,34	3860,18	3857,62	3795,89	3754,49	4060,2	4055,02	3918,63	3994,73	3941,47	4031,5	3856,08	3902,03	3884,54
	CV	0,17	0,26	0,28	0,23	0,28	0,21	0,16	0,16	0,18	0,24	0,65	1,57	1,49	0,31	2,44	0,55	0,96	0,20	0,14	0,12
NIRS3	Mean	4301,38	4214,02	3992,5	3769,6	3676,34	3802,81	3923,55	3893,9	3896,63	3836,91	3728,55	3892,3	3898,83	3873,33	3766,49	3947,6	3968,13	3847,81	3882,61	3881,32
	SD	11,28	17,17	13,05	7,28	10,41	9,40	10,56	10,42	8,15	11,20	30,32	63,95	73,48	10,58	110,41	18,76	38,61	2,89	7,11	5,55
	Min	4289,28	4186,93	3975,27	3758,76	3657,07	3790,41	3910,99	3881,5	3885,87	3818,17	3662,19	3840,64	3801,41	3863,26	3646,68	3910	3902,25	3841,94	3872,44	3877,04
	Max	4326,29	4247,95	4012,9	3781,04	3692,05	3817,49	3943,63	3913,74	3909,37	3854,62	3765,34	4048,82	4063,69	3894,55	4012,23	3965,45	4039,15	3858,75	3895,22	3895,05
	CV	0,26	0,41	0,33	0,19	0,28	0,25	0,27	0,27	0,21	0,29	0,81	1,64	1,88	0,27	2,93	0,48	0,97	0,08	0,18	0,14
NIRS4	Mean	4295,48	4211,96	3916,24	3727,61	3633,29	3747,92	3886,49	3857,39	3849	3784,26	3729,41	4018,13	3982,96	3913,35	3779,28	3876,68	3908,05	3855,68	3919,94	3893,04
	SD	10,85	10,85	13,32	12,04	13,19	9,59	8,11	8,00	8,32	9,73	23,99	51,14	43,37	18,13	93,00	32,13	52,9	11,40	7,52	5,00
	Min	4282,46	4190,02	3892,85	3708,55	3614,09	3731,09	3874,72	3845,79	3834,39	3767,86	3668,21	3961,75	3914,25	3884,83	3708,8	3828,9	3847,01	3838,33	3910,08	3885,94
	Max	4314,74	4233,95	3933,85	3747,87	3654,99	3760,6	3897	3867,77	3860	3798,25	3749,16	4146,36	4084,06	3940,31	4015,8	3927,22	4025,01	3875,33	3930,93	3899,11
	CV	0,25	0,32	0,34	0,32	0,36	0,26	0,21	0,21	0,22	0,26	0,64	1,27	1,09	0,46	2,46	0,83	1,35	0,30	0,19	0,13

ME_x – Metabolizable energy estimated by equation (x), based on the chemical composition of the corn cultivars obtained by the different NIRS equipment; SD – Standard deviation; Min – Minimum (Kcal/Kg); Max – Maximum (Kcal/Kg); CV – Coefficient of Variation (%).

In general, equations 20 and 19 presented the lowest SD and CV for the four NIRS equipment (Table 5). These equations were fitted by Oliveira et al. (2018), who used at most two regressors. According to Wiseman, Cole and Lewis (1982), there has been great interest in the use of ME prediction equations composed of either a single chemical composition variable or a small combination of them.

The results (Table 5) show high SD. Regarding NIRS 1, equations 15, 12, and 13 presented the highest SD values, that is, 87.31, 57.09, and 52.87, respectively. As for NIRS 2, the highest SD values were 91.92 for equation 15, 61.47 for equation 12, and 58.70 for equation 13. The highest SD values for NIRS 3 were presented by equations 15 (110,41), 13 (73,48), and 12 (63,95). Finally, for NIRS 4, equations 15, 17, and 12 had 93.00, 52.90, and 51.14 respectively.

Regarding the CV (Table 5), the highest results were as follows: NIRS 1 – equations 15 (2.33%), 12 (1.50%), and 13 (1.36%); NIRS 2 – equations 15 (2.44%), 12 (1.57%), and 13 (1.49%); NIRS 3 – equations 15 (2.93%), 13 (1.88%) and 12 (1.64%); NIRS 4 – equations 15 (2.46%), 17 (1.35%), and 12 (1.27%). It is observed that the equations with the highest CV are the ones that also had expressive SD.

The ME estimates from equations 12, 13 and, 15 (Table 5), fitted by Esteves et al. (2017), showed significant variations (SD and CV) when using the chemical composition variables (regressors) for all the NIRS. However, the authors used piglets to determine the ME values to fit the equations, whereas this study made use of finishing pigs, which shows that the use of equations to predict ME values should consider the production phase. Additionally, Le Goff and Noblet (2001) reported that the digestibility of nutrients and energy increases as pigs gain weight.

The ME estimates of equation 17 (Table 5), fitted by Yang et al. (2020), also showed significant variations between the analyzed sets. However, the authors used growing pigs, whose initial weight was 40.7 ± 2.5 kg, whereas, in this study, the animals were heavier. Weight gain leads to higher rates of fiber degradation in the intestine, whereas cellulose, hemicellulose, and pectin are degraded to short-chain fatty acids, which increases the amount of energy available (Gomes et al., 2007; Le Goff and Noblet, 2001). It should also be considered that international studies fit equations based on the chemical composition of locally produced corn, under different climate and genetic conditions compared to those in this study.

The sample mean and the SD analyzed (Table 5) are classic estimators of the location and scale parameter of a statistical distribution. However, they are not reliable in

the presence of outliers (Siraj-Ud-Douhah, 2018). Therefore, another way to assess predicted ME outcomes is by using the approach based on the mean squared deviation (MSD). According to Kobayashi and Salam (2000), this is the most appropriate approach for comparing observed and predicted values. Besides, it is an easy-to-interpret type of analysis, because the lower the MSD value, the closer the predicted values.

It is observed that the equations that presented the lowest values for the lack of correlation weighted by the standard deviations (LCS), squared difference between standard deviations (SDSD), and squared bias (SB) (Tabela 6), had the best results. Regarding NIRS 1, the lowest values for LCS and SDSD were observed in equations 20 and 19, in that order, and equations 12 and 6 for SB. NIRS 2 had the lowest values of LCS in equations 8 and 7, SDSD in equations 20 and 19, and SB in equations 18 and 9. NIRS 3 presented the lowest values of LCS in equations 18 and 14, SDSD in equations 18 and 20, and SB in equations 10 and 6. As for NIRS 4, the results were as follows: LCS (equations 19 and 20), SDSD (equations 20 and 19), and SB (equations 9 and 18).

Table 6. Lack of correlation weighted by the standard deviations (LCS), squared difference between standard deviations (SDSD) and squared Bias (SB), between observed and predicted values of metabolizable energy based on chemical composition estimated by different NIRS equipment as regressor variables

	Item	ME1	ME2	ME3	ME4	ME5	ME6	ME7	ME8	ME9	ME10	ME11	ME12	ME13	ME14	ME15	ME16	ME17	ME18	ME19	ME20
NIRS1	LCS	17,2	29,6	32,7	24,4	32	23,5	21,9	21,6	20,4	28,1	87,5	240,3	221	59,9	385,4	131,5	199,8	34,1	14,9	14,7
	SDSD	13,6	45,5	53,8	28,6	51,9	21,8	15,9	15,3	14,1	33,6	367,7	2701,4	2301,1	172,4	6503,3	622,9	1542,8	49,5	4,4	1,4
	SB	227301	149592	41525	903	15088	25	12745	6900	9177	1480	8764	14	3472	2241	4750	18357	22736	946	1657	2165
NIRS2	LCS	22,5	34,5	15,4	20,4	25,1	11,1	7,9	7,8	9,6	15,1	81,1	335,5	332,2	72,1	454,2	51,2	144,1	38,6	35,5	17,1
	SDSD	22,4	69	67,7	34,5	57,8	28,2	14,6	13,9	18,7	42,2	434,9	3150,7	2862,2	87,3	7227,2	333,1	1130,9	26,2	13,4	4,2
	SB	199356	130934	8445	10241	37849	5697	3136	729	672	1484	8458	10746	13743	5499	3292	7739	12416	524	5254	3543
NIRS3	LCS	51,3	72,8	74	35	46,7	53,3	59,3	58,5	46,2	58,3	113,6	276,6	282,9	13	514,1	132,8	226,6	5,4	17,3	29,9
	SDSD	72,5	198,7	104	22,3	59	45,2	61,3	59,3	30,8	71,2	706	3419,8	4559,5	61,6	10518,4	243,5	1186,3	5,6	13,3	9,9
	SB	230783	154477	29420	2640	20922	330	10520	5317	5723	254	8544	5086	6061	2740	2969	16032	21651	720	3799	3641
NIRS4	LCS	51,7	60,5	63,1	49,1	52,1	45,4	44	43,4	39,4	43,7	86	258,2	181,9	53,9	450,8	171,4	273,4	38,9	28,6	30,7
	SDSD	65,7	114,4	109,1	85,2	106,5	47,7	30,3	29,2	32,5	49,6	423,3	2146,6	1517,7	225,3	7402,1	800,2	2303,8	86,3	17,1	7
	SB	225153	152868	9073	8718	35230	5338	4292	1325	785	1348	8386	38866	26236	8531	1739	3103	7580	1204	9794	5192

ME_x – Metabolizable energy estimated by prediction equation (x).

The lowest values for the mentioned indices were found in different equations because they are part of an additive methodology, in which it is necessary to evaluate the sum. To obtain the MSD, it is necessary to add LCS, SDS, and SB, which makes it easy to identify the main component (Kobayashi and Salam, 2000). Once the component has been identified, the results of the comparison between predicted and observed data can be clearly visualized (Jamison et al., 1998). Therefore, the equations that best fitted the observed values, determined in the metabolism assay, were the ones that presented the lowest MSD.

The lowest MSD in NIRS 1 corresponded to equations 6, 4, 18, and 10, in that order (Figure 1A). Regarding NIRS 2, the lowest MSD values were found by equations 18, 9, 8, and 10 (Figure 1B). As for NIRS 3, it was equations 10, 6, 18, and 4 (Figure 1C). Finally, for NIRS 4, equations 9, 18, 8, and 10 (Figure 1D) were the ones to present the lowest MSD values.

The best equations to predict ME, for each NIRS, were not the same, which may be explained by the fact that each NIRS presents a specific calibration curve to determine the regressors that are part of the prediction equations evaluated. In general, it is noted that the lowest MSD values were obtained by equations 4, 6, 10, and 18 (Figure 1), which use EE, CP, and CF as regressors. According to Lekule et al. (1990) and Pozza et al. (2010), EE and CP have a positive correlation with ME, however, both must be properly estimated by the NIRS. In this sense, Ferreira et al. (2018) observed that EE, CP, and NDF were the chemical composition variables properly determined by the NIRS.

It is also noted (Figure 1A, 1B, 1C, 1D) that equations 1 and 2 presented considerably higher values of MSD compared to the others. These two equations were fitted using a complete feed, not specifically for corn. Additionally, their regressor is MM, whose correlation is negative for ME, as it acts as a diluent of gross energy, reducing the organic matter content of foods (Morgan et al., 1987; Pelizzeri et al., 2013). It can also reduce the digestibility of fats because, when combined, they can form soaps (Noblet and Perez, 1993). In addition, NIRS technology is not a proper tool to read MM, since infrared light is absorbed by organic and non-mineral compounds (Clark et al., 1987).




Figure 1. Mean squared deviation (MSD) between the values found in the metabolism assay, predicted by equations (MEx) with regressors determined by different NIRS equipment

The equations with the lowest MSD provided a good fit of the predicted lines compared to the ones that were observed (Figure 2). Thus, in MSD-based analysis, the most relevant aspect is not whether the model is right or wrong, but how different its outcome is from the measurement of observed data, and why they differ (Kobayashi and Salam, 2000).

The best equations for NIRS 1 (Figure 2) were equation 6, which has CF as a regressor, and equation 4, which uses CF and EE. Both equations were fitted by Just et al. (1984) and suggested to be used in food prediction in general. Regarding NIRS 2, the best equations were 18, which uses EE and CF, and 9, whose only regressor is CF. Equation 18 was fitted by Oliveira et al. (2018), specifically for corn, and equation 9 was proposed by Lekule et al. (1990) to predict food DM in general. As for NIS 3, the best equations were 10 and 6. The former, whose regressors are CF and CP, was fitted by Lekule et al. (1990) for food in general. Finally, for NIRS 4, similarly to NIRS 2, the best equations were 9 and 18.

The best MSD-based equations have chemical composition regressors that are properly determined by NIRS equipment, according to Ferreira et al. (2018) and, despite not being specifically fitted for corn, they provided results close to those observed (Figure 2).

It can also be pointed out that the equations with the lowest number of regressors were relatively more successful (Figure 2). There has been great interest in the use of ME prediction equations composed of only one, or a small combination of chemical composition variables (Wiseman, Cole, and Lewis, 1982), because, in a way, equations with few regressors provide greater practicality in estimating ME values (Pozza et al., 2008). However, with the increasingly efficient use of NIRS in animal feed plants, attention should be paid to both the calibration curves of each ingredient and to the fact that chemical composition variables can be good regressors in equations to predict ME values.

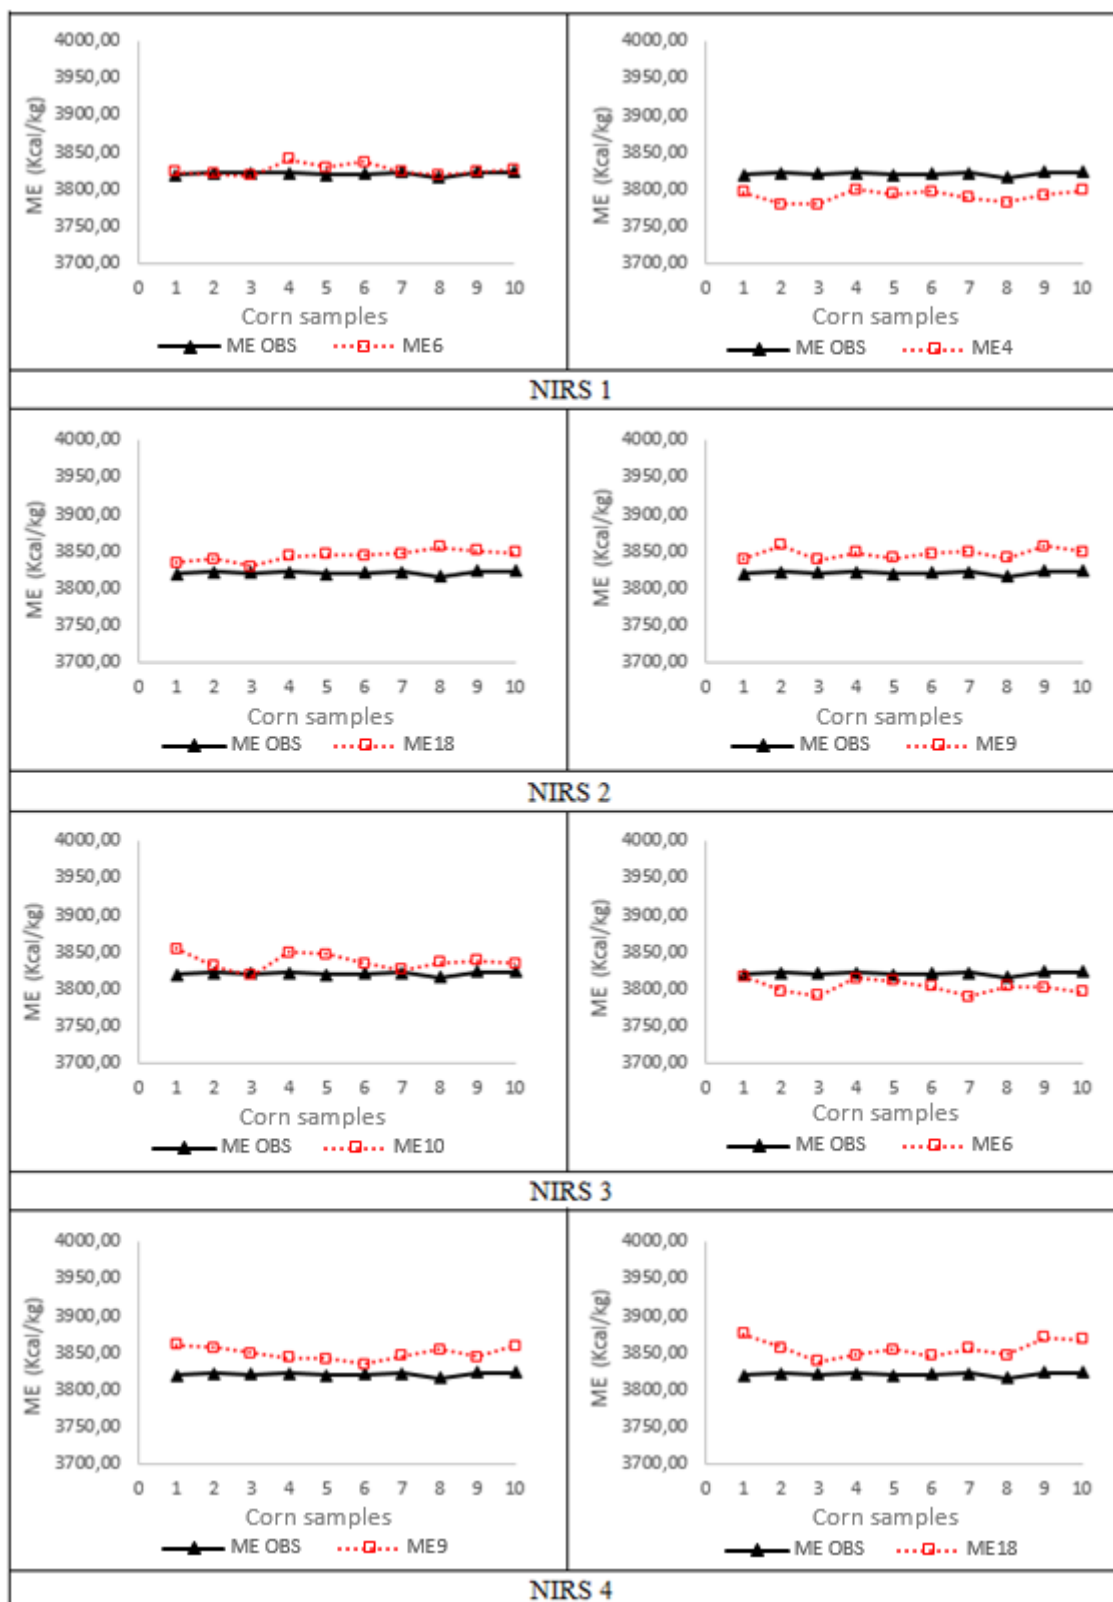


Figure 2. Graphic representation between the observed metabolizable energy (OBS ME) and the metabolizable energy predicted by the best prediction equations (ME_x), based on chemical composition estimates obtained by different NIRS equipment.

NIRS equipment usually includes calibration curves. Yet, most curves are based on food samples from the manufacturing countries, whose conditions are not similar to those found in Brazil. Therefore, the equipment must be calibrated with a wide variety of samples, thus, ensuring more reliable results (Gottardo; De Oliveira and Bernardo, 2015).

The graphic representation of the predicted values in comparison with the observed ones (Figure 2) proves that the chemical composition variables of equations 6, 4, 9, 10, and 18 are good regressors for equations to predict ME values, after all, the estimated results were close to those observed.

The fit of the curves between the predicted ME values in contrast with the observed ones shows that equations 1 and 2 provided unsatisfactory results in predicting the ME of corn for swine (Figure 3) for all the four NIRS equipment evaluated. Both equations were fitted by Noblet and Perez (1993) for the prediction of complete feeds and not for ingredients. This is probably the reason why the values for the prediction of corn ME were not assertive.

Moreover, the regressor of the two aforementioned equations is MM, which, as previously mentioned, is not a good regressor for DM. Besides, NIRS is not the proper equipment to read MM, which makes its determination limited (Clark et al., 1987). Finally, the constants of the equations presented proportionally high values in relation to the product of the regressors and their respective coefficients, thus, providing high predicted ME values.

CONCLUSION

The findings of this study show that, regarding a single NIRS equipment, the best equation for the prediction of metabolizable energy values of corn to swine was $EM_6 = 16482 - 35.7CF$. As for the equations that best estimated the ME for all the NIRS evaluated, $EM_9 = 16.81 - 0.031CF$ and $EM_{18} = 3675.39 + 50.02EE - 25.62CF$ stood out.

REFERENCES

- Al-Saleh MF, Yousif AE. 2009. Properties of the standard deviation that are rarely mentioned in classrooms. *Austrian Journal of Statistic*. 38(3): 193–202.
- Castilha LD, Pozza PC, Klosowski ÉS, Lazzeri DB, Dos Santos Pozza MSD, Richart, Nunes RV. 2011. Modelos matemáticos para predição dos valores energéticos do milho para suínos. *Revista Brasileira de Saúde e Produção Animal*, 12(2): 456-467.
- Dozier III WA, Gehring CK, Corzo A, Olanrewaju HA. 2011. Apparent metabolizable energy needs of male and female broilers from 36 to 47 days of age. *Poultry science*, 90(4): 804-814.
- Esteves LAC, Oliveira NTED, Huepa LMD, Ferreira SL, Castilha LD, Pozza PC. 2017. Predição da energia metabolizável de primeira e segunda safra de milho para leitões. *Ciência e Agrotecnologia*, 41: 683-691.
- Ferreira ERA, Fialho ET, Teixeira AS. 1997. Avaliação da composição e determinação de valores energéticos e equação de predição de alguns alimentos para suínos. *Rev. Bras. Zootec*. 26: 514- 523.
- Ferreira SL, Vasconcellos RS, Rossi RM, Paula VRCD, Fachinell, MR, Huepa LMD, Pozza PC. 2018. Using near infrared spectroscopy to predict metabolizable energy of corn for pigs. *Scientia Agricola*, 75(6): 486-493.
- Gomes JDF, Putrino SM, Grossklaus C, Utiyama CE, Oetting LL, De Oliveira Souza LW, Fukushima RS, Fagundes ACA, Sobral PJA, Lima CG. 2007. Efeitos do incremento de fibra dietética sobre a digestibilidade, desempenho e características de carcaça: I. suínos em crescimento e terminação. *Semina: Ciências Agrárias*, 28(3): 483-492.
- Gottardo A, De Oliveira L, Bernardo TRT. 2015. Calibração do equipamento de espectroscopia de infravermelho próximo (NIRS) para a determinação da qualidade bromatológica de concentrados e pastagens. *Salão do Conhecimento*.
- Jamieson PD, Porter JR, Goudriaan J, Ritchie JV, Van Keulen H, Stol W. 1998. A comparison of the models AFRCWHEAT2, CERES-Wheat, Sirius, SUCROS2 and SWHEAT with measurements from wheat grown under drought. *Field Crops Research*, 55(1-2), 23-44.
- Just A, Jørgensen H, Fernandez JA. 1984. Prediction of metabolizable energy for pigs on the basis of crude nutrients in the feeds. *Livestock Production Science*, 11(1): 105-128.
- Kil DY, Park CS, Son AR, Ji SY, Kim BG. 2014. Digestibility of crude protein and amino acids in corn grains from different origins for pigs. *Animal Feed Science and Technology*, 196: 68-75.
- Kobayashi K, Salam MU. 2000. Comparing simulated and measured values using mean

- squared deviation and its components. *Agronomy Journal*, 92(2): 345-352.
- Le Goff G, Noblet J. 2001. Comparative total tract digestibility of dietary energy and nutrients in growing pigs and adult sows. *Journal of Animal Science*, 79(1): 2418-2427.
- Lekule FP, Jorgensen H, Fernandez JA, Just A. 1990. Nutritive value of some tropical feedstuffs for pigs. Chemical composition, digestibility and metabolizable energy content. *Animal Feed Science and Technology*, 28:91-101.
- Li J, Li Q, Li D, Chen Y, Wang X, Yang W, Zhang L. 2016. Use of near-infrared reflectance spectroscopy for the rapid determination of the digestible energy and metabolizable energy content of corn fed to growing pigs. *Journal of animal science and biotechnology*, 7(1): 1-9.
- Li Q, Zang J, Liu D, Piao X, Lai C, Li D. 2014. Predicting corn digestible and metabolizable energy content from its chemical composition in growing pigs. *Journal of animal science and biotechnology*, 5(1): 1-8.
- Morgan CA, Whittemore CT, Phillips P, Crooks P. 1987. The prediction of the energy value of compounded pig foods from chemical analysis. *Animal Feed Science and Technology* 17: 81-107.
- NATIONAL RESEARCH COUNCIL - NRC. 2012. Nutrient requirements of swine. 11 ed. Washington, DC: National Academy, p. 400.
- Noblet J, Fortune H, Shi XS, Dubois S. 1994. Prediction of net energy value of feeds for growing pigs. *Journal Of Animal Science*, 72: 344-354.
- Noblet J, Perez JM. 1993. Prediction of digestibility of nutrients and energy values of pig diets from chemical analysis. *Journal of Animal Science*. 71: 3389-3398.
- Oliveira NTED, Pozza PC, Castilha LD, Pasquetti TJ, Langer CN. 2018. Metabolizable energy in energy food for growing pigs and cross-validation regression models. *Revista Ciência Agrônômica*, 49, 150-158.
- Pelizzeri RN, Pozza PC, Oliveira NTE, Somensi ML, Furlan AC, Neumann ME. 2013. Avaliação de modelos de predição da energia metabolizável do milho para suínos. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, 65: 460-468.
- Pozza PC, Gomes PC, Donzele JL, Rostagno HS, Santos Pozza, MSD, Rodrigueiro RJB, Nunes RV. 2008. Determinação e predição dos valores de energia digestível e metabolizável da farinha de vísceras para suínos. *Revista Brasileira de Saúde e Produção Animal* 9: 734-742.
- Pozza PC, Nunes RV, Santos Pozza MSD, Richart S, Schumacher GC, Oliveira FGD. 2010. Determinação e predição de valores energéticos de silagens de grãos úmidos de milho para suínos. *Ciência e Agrotecnologia*, 34 (1): 226-232, 2010.
- Reed GF, Lynn F, Meade BD. 2002. Use of coefficient of variation in assessing variability of quantitative assays. *Clinical and Vaccine Immunology*, 9(6): 1235-1239.

- Rodrigues CFDS, Lima FJCD, Barbosa FT. 2017. Importância do uso adequado da estatística básica nas pesquisas. *Revista Brasileira de Anestesiologia* , 67: 619-625.
- Rojas OJ, Stein HH, 2015. Effects of reducing the particle size of corn grain on the concentration of digestible and metabolizable energy and on the digestibility of energy and nutrients in corn grain fed to growing pigs. *Livest. Sci.*, 181: 187-193.
- Rostagno HS, Albino LFT, Hannas MI, Donzele JL, Sakomura NK, Perazzo FG, Saraiva A, Teixeira ML, Rodrigues PB, Oliveira RF, et al. 2017. *Tabelas Brasileiras Para Aves e Suínos: Composição de Alimentos e Exigências Nutricionais* Departamento de Zootecnia-UFV, Viçosa, MG, BR.
- Silva DJ, Queiroz AC. 2005. *Análises de alimentos: métodos químicos e biológicos*. 3.ed. Viçosa: UFV, 235.
- Siraj-Ud-Douh M. 2018. Alternative Measures of Standard Deviation Coefficient of Variation and Standard Error. *International Journal of Statistics and Applications*. 8(6): 309-315.
- Stein HH, Lagos LV, Casas GA. 2016. Valor nutricional de ingredientes alimentares de origem vegetal na alimentação de suínos. *Animal Feed Science and Technology*, 218: 33-69.
- Wiseman J, Cole DJA, Lewis D. 1982. Energy value in pig nutrition. 3. The digestible and metabolisable energy content of barley, wheat, maize, oats and rye. *Journal of Agricultural Science, Cambridge* 98: 89-97.
- Yang P, Ni JJ, Zhao JB, Zhang G, Huang CF. 2020. Regression Equations of Energy Values of Corn, Soybean Meal, and Wheat Bran Developed by Chemical Composition for Growing Pigs. *Animals*, 10(9): 1490.