



UNIVERSIDADE ESTADUAL DO SUDOESTE DA BAHIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA
ÁREA DE CONCENTRAÇÃO: FITOTECNIA

**DIAGNOSE FOLIAR EM PLANTIOS CAFEEIROS DO SUDOESTE
BAIANO POR ANÁLISES LABORATORIAIS TRADICIONAIS E
ESPECTROSCOPIA DE REFLECTÂNCIA DIFUSA**

CAROL CHAVES NASCIMENTO

VITÓRIA DA CONQUISTA

BAHIA – BRASIL

2022

CAROL CHAVES NASCIMENTO

**DIAGNOSE FOLIAR EM PLANTIOS CAFFEEIROS DO SUDOESTE BAIANO
POR ANÁLISES LABORATORIAIS TRADICIONAIS E ESPECTROSCOPIA
DE REFLECTÂNCIA DIFUSA**

Dissertação apresentada à Universidade Estadual do Sudoeste da Bahia, como parte das exigências do Programa de Pós-Graduação em Agronomia, área de concentração em Fitotecnia, para a obtenção do título de “Mestre”.

Orientador: Prof. Dr. Cácio Luiz Boechat

Coorientador: Dr. Wanderson de Sousa Mendes

VITÓRIA DA CONQUISTA

BAHIA – BRASIL

2022

N244d

Nascimento, Carol Chaves.

Diagnose foliar em plantios cafeeiros do sudoeste baiano por análises laboratoriais tradicionais e espectroscopia de reflectância difusa. / Carol Chaves Nascimento, 2022.

57f.

Orientador (a): Dr. Cácio Luiz Boechat.

Dissertação (mestrado) – Universidade Estadual do Sudoeste da Bahia, Programa de Pós-Graduação em Agronomia, Área de concentração em Fitotecnia. Vitória da Conquista, 2022.

Inclui referência F. 52 – 57.

1. Cultura do café - Espectroscopia. 2. Folhas de café. 3. Modelagem – Nutrição de plantas. 4. VIS-NIR. I. Boechat, Cácio Luiz. II. Universidade Estadual do Sudoeste da Bahia, Programa de Pós-Graduação em Agronomia. III. T.

CDD: 633.73

Catálogo na fonte: Juliana Teixeira de Assunção – CRB 5/1890

Bibliotecária UESB – Campus Vitória da Conquista -BA

**UNIVERSIDADE ESTADUAL DO SUDOESTE DA
BAHIA PROGRAMA DE PÓS-GRADUAÇÃO EM
AGRONOMIA**

Área de Concentração em Fitotecnia

Campus de Vitória da Conquista, BA

DECLARAÇÃO DE APROVAÇÃO

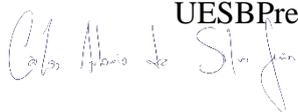
Título: DIAGNOSE FOLIAR EM PLANTIOS DE CAFEEIRO DO SUDOESTE BAIANO POR MÉTODOS TRADICIONAIS E ESPECTROSCOPIA DE REFLECTÂNCIA DIFUSA

Autora: Carol Chaves Nascimento

Aprovada como parte das exigências para obtenção do Título de MESTRE EM AGRONOMIA, ÁREA DE CONCENTRAÇÃO EM FITOTECNIA, pela seguinte Banca Examinadora:

 Documento assinado digitalmente
CACIO LUIZ BOECHAT
Data: 03/03/2022 10:10:47-0300
Verifique em <https://verificador.iti.br>

Cácio Luiz Boechat, D.Sc.,
UESB Presidente



2022.03.01
08:28:03-04'00'

Carlos Antonio da Silva Júnior, D.Sc., UNEMAT



Odair Lacerda Lemos, D.Sc., UESB

Data de realização: 25 de Fevereiro de 2022.

Estrada do Bem Querer, Km 4, CEP 45031-900, Caixa Postal 95, Vitória da Conquista, Bahia, Brasil
Telefone: (77) 3425-9383, e-mail: ppgagronomia@uesb.edu.br

DEDICO

A minha avó, Célia Chaves, de quem jamais me esquecerei.

(In memoriam).

AGRADECIMENTOS

Agradeço, em primeiro lugar, a Deus, por renovar as minhas forças diante de cada novo desafio.

Aos meus pais, Carlete Chaves e Claudinei Ferreira; e ao meu padrasto, Luiz Alberto, pelo apoio, suporte e todo amor incondicional.

Ao meu orientador, Prof. Dr. Cácio Luiz Boechat, por todo apoio, motivação, compreensão, conselhos, pelas oportunidades a mim concedidas, sua amizade e ensinamentos que levarei por toda vida.

Ao meu coorientador, Dr. Wanderson de Sousa Mendes, por tudo, em especial, pela paciência, por sua dedicação, conselhos e ensinamentos.

Ao professor, Dr. José Alexandre Melo Demattê por todo suporte durante as análises.

À UESB, à Coordenação do Curso de Pós-graduação em Agronomia e a todos os professores, agradeço pelo ambiente propício ao crescimento, por todo suporte, apoio, dedicação, assim como pela oportunidade de capacitação profissional.

À UFPI e ESALQ, pela parceria e suporte durante as análises.

À COOPERBAC, por proporcionar que todo o trabalho fosse realizado com maestria e pelo contato com pessoas maravilhosas e dedicadas desde o início do projeto.

À Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB), pela concessão da bolsa de estudo.

À toda a minha família, minhas tias e tios, e aos meus irmãos amados Clayton e Laura, por todo carinho, incentivo, suporte e compreensão.

Aos meus amigos: José Luiz, Maicon Silva, Monalisa Fagundes, Matheus Pereira, Iana Delmare, Mariana Gomes, Verena Brito, Thayane Gomes, Mariana Beatriz, Bruna Lira, Bruna Carvalho, Maida Cynthia, Elismar Oliveira, Ana Pinheiro, Wallace Almeida e Theilon Henrique. E às amigas Paloma Saraiva e Pâmala Grazielly que o intercâmbio institucional me concedeu. Agradeço a vocês por todo amor, cumplicidade, cuidado, boa convivência, novas experiências, alegrias, conversas, carinho e por todos os bons momentos.

Aos meus colegas da Pós-graduação, pela cumplicidade, honestidade e ajuda para seguir durante esses anos de mestrado com mais leveza, companheirismo e alegria.

Agradeço imensamente, pois graças a vocês sou uma pessoa realizada e feliz por não ter me sentido só nesta caminhada.

A quem não mencionei, mas esteve junto, também agradeço com todo meu coração.

Muito obrigada!

A tecnologia ensinou uma lição à humanidade: nada é impossível.

Lewis Mumford

RESUMO

CHAVES, C.C. **DIAGNOSE FOLIAR EM PLANTIOS CAFEEIROS DO SUDOESTE BAIANO POR ANÁLISES LABORATORIAIS TRADICIONAIS E ESPECTROSCOPIA DE REFLETÂNCIA DIFUSA.** Vitória da Conquista - BA, UESB, 2022. 57 p. (Dissertação: Mestrado em Agronomia; Área de Concentração: Fitotecnia)*.

O conhecimento da demanda nutricional das culturas resulta em maior produtividade e proporciona a diagnose, antecedendo estresses abióticos sob plantios de interesse econômico. O monitoramento da cultura do café é de extrema importância para o cenário baiano que vem assumindo destaque na produtividade de grãos, elevando seus padrões de qualidade desde o manejo nutricional até a colheita. Objetivou-se avaliar plantios de café de diferentes variedades, com idade superior a 2 anos, para se atentar à questão nutricional de áreas já produtivas na região do Planalto da Conquista por meio de digestão nitro-perclórica correlacionando-a com a espectroscopia na região do visível e infravermelho. Foram coletadas no município de Barra do Choça, Bahia, 441 amostras de tecido vegetal, sendo georreferenciadas e identificadas, lavadas em água corrente e destilada. O material proveniente das áreas foi seco em estufa a 60°C, moído em moinho de facas tipo Willey e padronizado em peneiras de 30 mesh, para posterior leitura direta de amostras com o sensor FieldSpec 3, que compreende o comprimento de ondas de 350 a 2500 nm, cuja resolução espectral é de 3nm entre os comprimentos de 250 a 700 nm e 10nm de resolução espectral, na faixa de 350 a 700 nm. Para as leituras convencionais, as amostras passaram por digestão nitro-perclórica, quando foram analisados os extratos da digestão, por meio de espectroscopia de absorção e fotômetros de chama, para determinar a concentração de macronutrientes (Ca, Mg, P, K) e micronutrientes (Fe, Zn, Mn e Cu). Processou-se os dados por meio da estatística descritiva, obtendo valores de bias, RPIQ, ccc, RMSE, R², para as técnicas de modelagem *Partial Least Squares Regression* (PLSR), *Random Forest* (RF) e *Cubist* (CUB), combinadas com diferentes pré-processamentos SG (*Savitsky-Golay*) SNV (*Standard Normal Variate*) Det (*Detrend*), CR (*Continuum Removal*) e dados brutos. Os modelos que mais se ajustaram às quantificações nutricionais foram o PLSR e *Cubist*, assumindo uma capacidade de predição superior aos demais para P, Mn e K (a modelagem *Cubist* do último nutriente com capacidade preditiva superior a 70% com o pré-processamento *Detrend*). Os pré-processamentos para a análise de dados, durante a modelagem, também foram importantes, dando foco ao SG e SNV. Tanto o modelo CUB quanto o PLSR podem ser sugeridos para a cultura cafeeira.

Palavras-chave: Espectroscopia; folhas de café; VIS-NIR; modelagem; nutrição de plantas.

* **Orientador:** Prof. Dr. Cácio Luiz Boechat, UFPI e Coorientador Prof. Dr. Wanderson de Sousa Mendes, ZALF.

ABSTRACT

CHAVES, C. C. **Leaf diagnosis in coffee plantations in southwest Bahia by traditional laboratory analysis and diffuse reflectance spectroscopy.** Vitória da Conquista – BA, UESB, 2022. 57 p. (Dissertation: Master Science in Agronomy; Area of Concentration: Crop Science)*.

The knowledge of the nutritional demand of crops results in greater productivity and provides diagnosis before abiotic stresses under plantations of economic interest. Monitoring the coffee crop is extremely important for the Bahian scenario, which has been gaining prominence in terms of grain productivity, raising its quality standards from nutritional management to harvesting. The objective was to evaluate coffee plantations of different varieties, aged over 2 years, to address the nutritional issue of already productive areas in the region of Planalto da Conquista through nitro-perchloric digestion, correlating it with spectroscopy in the visible and infra-red. 441 samples of plant tissue were collected in the municipality of Barra do Choça, Bahia, being georeferenced and identified, washed in running and distilled water. The material from the areas was dried in an oven at 60°C, ground in a Willey-type knife mill and standardized on 30 mesh sieves, for later direct reading of samples with the FieldSpec 3 sensor that comprises wavelengths from 350 to 2500 nm whose spectral resolution is 3nm between the lengths of 250 to 700 nm and 10nm of spectral resolution in the range of 350 to 700 nm. For conventional readings, the samples underwent nitro-perchloric digestion, where the digestion extracts were analyzed by means of absorption spectroscopy and flame photometers to determine the concentration of macronutrients (Ca, Mg, P, K) and micronutrients (Fe, Zn, Mn and Cu). Data were processed using descriptive statistics, obtaining values of bias, RPIQ, ccc, RMSE, R², for the Partial Least Squares Regression (PLSR), Random Forest (RF) and Cubist (CUB) modeling techniques combined with different pre - SG (Savitsky-Golay) SNV (Standard Normal Variate) Det (Detrend), CR (Continuum Removal) and raw data processing. The models that most adjusted to the nutritional quantifications were the PLSR and Cubist, assuming a superior predictive capacity than the others for P, Mn and K (the Cubist modeling of the last nutrient with a predictive capacity greater than 70% with the Detrend pre-processing). Pre-processing for data analysis during modeling was also important, focusing on SG and SNV. Both the CUB model and the PLSR can be suggested for the coffee crop.

Keywords: Spectroscopy, coffee leaves, VIS-NIR, modeling, plant nutrition.

* Advisor: Prof. Dr. Cácio Luiz Boechat, UFPI and Coadvisor: Prof. Dr. Wanderson de Sousa Mendes, ZALF.

LISTA DE FIGURAS

Figura 1 – Espectro da radiação eletromagnética.....	25
Figura 2 – Localização das 49 propriedades rurais selecionadas para amostragem da microrregião produtora do Planalto da Conquista, Bahia, Brasil.....	29
Figura 3 – Coleta, identificação e preparo do tecido vegetal proveniente da microrregião produtora do Planalto da Conquista, Bahia, Brasil.....	30
Figura 4 – Moagem das amostras seguida de padronização do material vegetal em peneira de 30 mesh.....	31
Figura 5 – Procedimento de pesagem das amostras para digestão nitro perclórica (a); armazenamento da solução proveniente da digestão (b); diluição das soluções para quantificação convencional de nutrientes em espectrômetros de chama (c).....	32
Figura 6 – Apresentação do procedimento de leitura de soluções: (a) Leitura de K em Fotômetro de chama; (b) quantificação nutricional de micronutrientes, Ca e Mg por meio do Espectrômetro de absorção atômica Varian.....	33
Figura 7 – Obtenção dos espectros: (a) esquematização geral do equipamento e acessórios para a leitura do material vegetal; (b) calibração do aparelho com placa Spectralon; (c) posicionamento das amostras ao centro do alvo do sensor; (d) detalhamento da disposição de lâmpadas halógenas para iluminação de material vegetal.....	34
Figura 8 – Apresentação dos pré-processamentos dos espectros: (a) Dados brutos, (b) <i>Savitsky-Golay</i> , (c) <i>Standard Normal Variate</i> , (d) <i>Detrend</i> , (e) <i>Continuum Removal</i>	38

LISTA DE TABELAS

Tabela 1 – Estatística descritiva de nutrientes extraídos em plantios cafeeiros no Planalto da Conquista, Brasil.....	37
Tabela 2 – Estatísticas preditivas para calibração e validação dos três modelos para macronutrientes Ca, Mg, P, K e micronutrientes Cu, Mn e Fe, provenientes de tecido vegetal de cafeeiros.....	40
Tabela 3 – Apresentação dos parâmetros auxiliares dos modelos preditivos PLSR, RF e CUB para a quantificação de macro e micronutrientes de tecido vegetal por meio de <i>software R</i>	44

LISTA DE SIGLAS

ABIC	Associação Brasileira da Indústria do Café
ATR	Acessório de Refletância Atenuada
BA	Bahia
bias	Erro médio
°C	Graus celsius
Ca	Cálcio
CCC	Coefficiente de Correlação de Concordância
cLHS	<i>Conditioned Latin Hypercube Sampling</i>
COOPERBAC	Cooperativa Mista dos Cafeicultores de Barra do Choça e Região
CR	<i>Continuum Removal</i>
Cu	Cobre
CUB	<i>Cubist</i>
cv	Validação cruzada
CV	Coefficiente de variação
Det	<i>Detrend</i>
DRIS	Sistema Integrado de Diagnose e Recomendação
ES	Espírito Santo
EUA	Estados Unidos da América
Fe	Ferro
g	Gramas
HCl	Ácido clorídrico
HNO ₃	Ádico nítrico
IQR	Interquartil
K	Potássio
kg	Kilogramas
m	Metros
MG	Minas Gerais
Mg	Magnésio
Mn	Manganês
Ncomp	Número de componentes principais
NIR	Infravermelho próximo
Nobs	Número de observações
OIC	Organização Internacional de Café
P	Fósforo
PCA	Análise de Componentes Principais

PLSR	<i>Partial Least Square Regression</i>
R ²	Coeficiente de determinação
R ² v	Coeficiente de determinação da validação
RF	<i>Random Forest</i>
RMSE	Erro Quadrático Médio
RMSEv	Erro Quadrático Médio da Validação
RO	Rondônia
RPD	Razão de Desempenho para Desvio
RPIQ	Razão de Desempenho para Distância Interquartil
SG	<i>Savitzky-Golay</i>
SNV	<i>Standard Normal Variate</i>
SP	São Paulo
SWIR	Infravermelho de ondas curtas
UE	União Européia
Vis	Região do visível
Zn	Zinco

SUMÁRIO

1 INTRODUÇÃO	15
2 REFERENCIAL TEÓRICO	18
2.1 Cultura do café e suas especificidades	18
2.2 Setor mundial de produção cafeeira do Brasil	19
2.3 Importância das avaliações nutricionais de tecidos vegetais no cultivo de café ..21	
2.4 Métodos de análise de nutrientes em tecido vegetal do café	23
2.5 Avanços tecnológicos, Espectroscopia e aplicabilidade no cenário cafeeiro	24
3. MATERIAL E MÉTODOS	29
3.1 Área de estudo e coleta de amostras	29
3.2 Análises Nutricionais	31
3.2.1 Digestão do material e leitura dos nutrientes	31
3.2.2 Obtenção de dados por sensor FieldSpec 3	33
3.3 Pré-processamento	34
3.4 Modelagem e validação	35
4 RESULTADOS	37
5 DISCUSSÃO	46
5.1 Avaliação dos teores nutricionais	46
5.2 Avaliação dos diferentes tipos de modelagem	47
6 CONCLUSÕES	51
REFERENCIAL BIBLIOGRÁFICO	52

1 INTRODUÇÃO

O café é uma das *commodities* agrícolas mais valiosas do mundo e o Brasil produz a maior quantidade de grãos comercializada mundialmente. Segundo a quantificação de produção mais recente prevista, a produtividade brasileira girará em torno de 56.300 mil sacos de 60 kg na safra de 2021/22, sendo 81% superior do que a estimativa do Vietnã, país com maior produção dos grãos (Péres et al., 2020; Usda, 2021).

O país possui destaque no consumo e exportação de grãos para países pertencentes ao Reino Unido (maiores consumidores mundiais de café), seguido dos EUA. Essa exportação expressiva tem impacto no cultivo das duas principais espécies comercializadas, *Coffea conillon* e *Coffea arabica*, com produções centralizadas nos estados de MG, RO, ES, SP e BA (Conab, 2020).

Além de sua importância em relação às áreas cultivadas com as variáveis de café, o consumo do mesmo deve continuar subindo para um recorde de 23,7 milhões de sacas (Usda, 2021), evidenciando, assim, a importância de programas para a melhoria do manejo de plantios e qualidade dos grãos comercializados dentro e fora do país.

A Bahia se consolidou como produtora dos melhores cafés especiais do país no Concurso Nacional da Associação Brasileira da Indústria do Café (ABIC), e a região do Planalto da Conquista também apresentou destaque, o que impacta diretamente no cenário econômico da região, além de auxiliar na disseminação de práticas importantes para continuar enriquecendo o manejo cafeeiro no estado (Agnocafé, 2018; Agnocafé, 2020).

A produtividade estadual apresenta, assim, uma crescente demanda pela competitividade de produção, especialização e melhorias dentro das áreas produtivas. Com isso, a disseminação de novas tecnologias entre os pequenos produtores é de suma importância, porém, pouco visto no estado. Isso evidencia a necessidade das políticas de integração de pesquisadores às associações de produtores rurais, pois, graças a essa integração, obtém-se o padrão de qualidade consolidado no mercado interno e externo (Seagri, 2011).

Tendo em vista a importância para se estabelecer programas de adubação eficazes para a cultura cafeeira, deve-se identificar quais as necessidades nutricionais da cultura em cada região, quantificando nutrientes limitantes à produtividade, seguido de recomendações coerentes (Martinez et al., 2003). Ao se combinar a análise de tecidos vegetais com os testes do solo, obtém-se um método promissor de quantificação do estado

de fertilidade, pois um fornece dados sobre a quantidade de nutrientes absorvidos e o outro indica a disponibilidade de nutrientes no solo (Johnson et al., 2021).

Visando a otimização do acompanhamento dos plantios, observa-se a crescente demanda por uma caracterização, porém a digestão de tecidos vegetais e análises de solo requerem reagentes específicos e um maior tempo e custo para as análises. Desse modo, o estudo de tecnologias que facilitem o acompanhamento dos plantios, com uma menor geração de resíduos e maior praticidade na recomendação das adubações são vantajosas (Borges et al., 2020; Paulus e Mahlein, 2020; Mendes et al., 2021).

Dentre as tecnologias para otimização de análises, a de interação espectral já é utilizada para classificar propriedades do solo aliada a metodologias convencionais e sensoriamento remoto. Isso se dá por meio dos laboratórios híbridos que permitem maiores indagações sobre sua eficácia e aplicabilidade para solos e na avaliação de culturas vegetais diversas de importância econômica (Poppiel et al., 2019; Borges et al., 2020, Jin et al., 2022).

No tocante à otimização de produtividade, destaca-se a espectroscopia, dentre os crescentes estudos da tecnologia, como método de avaliação de culturas, partindo do conhecimento de suas características espectrais (Wadoux et al., 2021). Desse modo, surge o questionamento sobre sua aplicabilidade nos plantios cafeeiros, de extrema importância no setor econômico do estado baiano, nos quais ainda se tem pouco investimento e disseminação, principalmente para os pequenos produtores.

A espectroscopia auxilia no monitoramento e triagem de plantas para detecção de estresses bióticos e abióticos, assim como suas características fenológicas. Nos últimos anos, as aplicações hiperespectrais têm sido usadas mais amplamente, evidenciando, assim, a necessidade de estudo dessa nova tecnologia em cenários menores, atrelando um nível maior de detalhamento em culturas de interesse (Paulus e Mahlein, 2020; Pérez et al., 2020; Jin et al., 2022).

A espectroscopia leva em consideração a intensidade da luz emitida e sua interação com o alvo de estudo (Paulus e Mahlein, 2020), tal dinamismo é responsável pelo fornecimento da impressão digital com precisão de um objeto. O que é pouco difundido e destrinchado para a cultura do café.

Diante do exposto, objetivou-se definir as melhores combinações de pré-processamentos e modelos de regressão para avaliar a determinação da concentração de macronutrientes e micronutrientes em tecido vegetal de cafeeiro, obtidos por sensor proximal em comparação com os obtidos por método de digestão convencional.

Utilizando a hipótese de que o uso do sensor proximal das bandas Vis-NIR consegue explicar tão bem quanto os métodos de digestão convencionais os diferentes teores nutricionais em plantios de *Coffea* sp. situados na região do Planalto da Conquista – BA.

2 REFERÊNCIAL TEÓRICO

2.1 Cultura do café e suas especificidades

O café, originário do continente Africano, destaca-se como um dos produtos agrícolas mais importantes comercializados no mundo, sendo antecedido apenas pelo petróleo e seus derivados. É uma planta Eudicotiledônea, da classe das Angiospermas, família Rubiácea, pertencente ao gênero *Coffea*.; a cultura perene apresenta como característica natural a bienalidade que consiste em alternar um ano com grande florada seguido por outro de produção menos intensa para a recuperação do plantio. Cultura exigente quanto à imobilização de ativos, geralmente apresentando o início da fase produtiva apenas de dois a três anos, após seu plantio, em determinadas áreas. Sua altura pode variar entre 2 a 6 m, quando manejada e, no estado selvagem, pode chegar a 10 m; apresenta folhas de coloração verde escura, brilhantes, elípticas e bordas onduladas; suas inflorescências dão origem a até quatro flores no glomérulo e apresentam frutos oblongos, variando de coloração amarela a vermelha (Embrapa, 2007; Zabini, 2010; Seagri, 2011; Ferrão et al., 2017; Florez-Valdez et al., 2020).

Atualmente se tem conhecimento de mais de 120 espécies de café no mundo, ressaltando a importância da espécie *Coffea arabica* L., introduzida no Brasil e cultivada inicialmente no estado do Pará, em meados de 1727, disseminando-se e apresentando maior adaptação em climas frios e altitudes elevadas. Outra espécie de amplo cultivo em território brasileiro é a *Coffea canephora*, espécie com características muito distintas da anterior, geralmente sendo observada em menores altitudes e bienalidade menos expressiva do que a espécie anterior (Ferrão et al., 2017).

A *Coffea arabica* L. apresenta qualidade de bebida com sabores mais intensos e diversos, é cultivada nas mais diferentes regiões brasileiras, como Cerrado e Sul de MG, PR, ES, RO e BA. Desenvolve-se melhor em ambientes de altitude acima de 800m, sofrendo maior influência da bienalidade. A maturação de seus grãos é dada de forma mais lenta, possuindo maiores teores de carboidratos e lipídios; a temperatura média de cultivo está entre 18 e 23 °C; e o regime de chuvas ideal gira em torno de 1.200 a 1800 mm, devendo estar distribuídas para atingir períodos de desenvolvimento vegetativo e de frutificação. Suporta um déficit hídrico de até 150 mm, sem grandes prejuízos, mas pode sofrer influência dos ventos, demandando cautela aos índices de umidade relativa de valores extremos, que tendem a favorecer a incidência de pragas e doenças, comprometendo a produtividade (Embrapa, 2007; Mesquita et al., 2016b;

Ferrão et al.,2017; Conab, 2020).

De acordo com a demanda nutricional elevada da cultura para sua produção, acompanhamentos periódicos, tanto do solo quanto de suas partes vegetais são necessários para que não ocorram prejuízos na produtividade do mesmo (Mesquita et al., 2016a). Os macronutrientes mais exigidos pelo cafeeiro são nitrogênio e potássio, geralmente adicionados durante processos de adubação de cobertura após o plantio. Micronutrientes, como cobre e zinco, também são indispensáveis e sua deficiência pode vir a comprometer todo o desenvolvimento da safra com perdas em qualidade e atrasos na geração de capital (Mesquita et al., 2016b).

Mesmo tendo conhecimento da importância da análise de solo e da análise foliar com certa periodicidade, também é preciso lembrar-se de fatores como clima, condições adversas, disponibilidade hídrica, parâmetros nutricionais, demanda e sua interação em relação à cultura de interesse, pois a junção de todos esses fatores apresenta influência na composição dos tecidos vegetais, assim como em relação aos incrementos em produtividade dos plantios (Mesquita et al., 2016a).

2.2 Setor mundial de produção cafeeira do Brasil

A questão do consumo e cultivo de café em escala global segue uma tendência de crescimento desde 1990. Nesse quesito, os três países com a maior produção cafeeira são Brasil, com estimativa de produzir até 56.3 milhões de sacas; Vietnã, com 31,1 milhões; e Colômbia, com 13,8 milhões, sendo estes responsáveis por mais de 60% da produção mundial (Conab, 2020; Mapa, 2020; Usda, 2021).

Segundo dados apresentados pela Organização Internacional de Café – OIC (2020), os maiores importadores da cultura, no senso de setembro de 2019 a fevereiro de 2020, foram a União Europeia (UE), com 6.114 mil; Estados Unidos da América (EUA), com 2.020 mil; e o Japão, com 656 mil sacas de 60 kg de café. Essa quantidade comercializada vem sofrendo incrementos até os dias atuais, com um crescimento expressivo em suas taxas de importação. De acordo com o levantamento da *United States Department of Agriculture* (USDA), apresentado em dezembro de 2021, as quantidades mais recentes de importação feitas pela UE, EUA e Japão subiram para 42.500, 26.150 e 7.190 mil sacas de café importadas.

Nos anos de 2019 e 2018, os preços do café foram relativamente baixos devido à relação entre oferta maior que demanda, além dos impactos de intempéries climáticas

em regiões produtoras, como no caso do Brasil. Com a desvalorização da moeda brasileira, em 2020, a relação negativa de preços médios mensais, apurada no varejo de São Paulo, também permaneceu como reflexo da situação econômica em que o Brasil se encontrava. Recentemente observa-se o crescimento da demanda pela exportação cafeeira, dado pelo aumento global de consumo, impactando diretamente seus níveis de exportação e preço de comercialização (Mapa, 2020; OIC, 2022).

Um grande diferencial do Brasil é seu destaque tanto na produção do café arábica, quanto no café conilon. Em meados de 2019, apresentou área total de café arábica correspondendo a cerca de 81% da área existente no país (1,73 milhão de ha), mantendo-se estável nas últimas safras. Mesmo com os menores preços nos últimos seis anos, a desvalorização do real frente ao dólar estimulou a exportação (Campo e Negócios, 2020; Conab, 2020; Mapa, 2020).

No que se refere à produção de café conilon, a estimativa de produção brasileira apresenta redução de suas áreas de 389,8 mil ha, onde a maior área de produção se encontra situada no estado do Espírito Santo, com produção de 261,5 mil ha; seguido por Rondônia, com 70,5 mil ha; e Bahia, com aproximadamente 39,9 mil ha. Na Bahia, as regiões produtoras de café conilon se restringem ao bioma Atlântico, situado no extremo sul baiano, isso devido às suas condições climáticas e preferências da cultura de cultivo, menos restrito em áreas de temperaturas mais elevadas (Campo e Negócios, 2020).

A produtividade cafeeira da Bahia corresponde à área de interesse na produção de cafés especiais de maior valor agregado, além de uma produtividade para exportações da *commodity*. Dentro do estado, observa-se a divisão de 6 regiões cuja produção de café arábica está concentrada nas regiões Oeste; Chapada; Planalto (com os municípios de Caatiba, Iguai, Itambé, Nova Canaã, Barra do Choça, Encruzilhada, Planalto, Poções, Ribeirão do Largo, Vitória da Conquista, Boa Nova e Dário Meira); a região de Itiruçu/ Vale do Jiquiriçá/ Brejões. Já a produção de café conilon estende-se pelas regiões Sul/Baixo sul e Extremo Sul (Seagri, 2011).

Os cafeicultores, em sua maioria produtores familiares, apresentam menor acesso às tecnologias adotadas por médias e grandes propriedades, no entanto, a realização de eventos, como Seminários da Cafeicultura Familiar e Simpósios Nacionais do Agronegócio Café, permite englobar tais indivíduos ao cenário de pesquisadores responsáveis pela disseminação de informação e avanços tecnológicos às safras (Cafépoint, 2015; Ibge, 2019).

A Bahia está consolidada como produtora dos melhores cafés por meio da cidade de Piatã, que vem agregando maior reconhecimento e destaque em âmbito nacional na produção de cafés especiais. Essa consolidação impacta diretamente no estado com o turismo rural (compradores de vários países visitando o estado no intuito de conhecer as regiões e técnicas de manejo produtoras de cafés premiados). No último Concurso Nacional da Associação Brasileira da Indústria do Café (ABIC), a cidade de Piatã conquistou novamente a maior nota na categoria arábica, ressaltando a influência da produção de qualidade do Estado, já em relação aos campeões por regiões, o Planalto baiano/ Planalto de Vitória da Conquista também apresentou destaque no concurso nacional em relação aos demais territórios produtores do estado (Agnocafé, 2018; Agnocafé, 2020).

A cadeia de produção do estado é altamente competitiva, apresentando a mão de obra como maior fator de custo. Pequenos produtores (cerca de 80% do total) que atendem à necessidade produtiva baiana são impactados pela crescente demanda do padrão de qualidade para a cultura. Padrão que vem sendo consolidado pelo melhoramento genético, uso de novas tecnologias e otimização do trabalho de manejo, já disseminado, por exemplo, em MG, ES e SP que buscam atender ao crescente consumo interno, assim como às principais potências exportadoras (Seagri, 2011).

2.3 Importância das avaliações nutricionais de tecidos vegetais no cultivo de café

O Anuário do Café de 2020 revelou que o crescimento médio anual giraria em torno de 2% em relação à demanda mundial, exigindo, além da renovação dos plantios de cafeeiro, mais investimentos e pesquisas para disseminação de tecnologias, aumentando a longevidade e produtividade de áreas cultivadas. Desse modo, também é vista a busca por tecnologias sustentáveis para se manter no cenário competitivo da cultura, em que sua aplicação na análise foliar permite a manutenção de qualidade e diagnose de possíveis deficiências nutricionais que se diferem de acordo com as cultivares e a área de interesse (Malavolta et al., 2002; Mesquita et al., 2016a; Dubberstein et al., 2019).

Nutrientes no plantio cafeeiro podem ser exportados para partes da planta, retornando pela ciclagem nutricional e decomposição de partes, ou podem ser extraídos sem retorno ao ambiente, como no caso da dinâmica dos frutos. Os frutos podem ter seu desenvolvimento reduzido em decorrência de deficiências nutricionais no interior

do tecido vegetal e em seu solo, impactando em sua qualidade, valor econômico e em sua destinação final (Malavolta et al., 2002; Mesquita et al., 2016a).

Uma das funções em se diagnosticar a deficiência nutricional consiste em corrigir a mesma por meio de técnicas de interpretação dos resultados. Tais técnicas têm sido aprimoradas ao longo dos anos e, dentre elas, além da análise visual de tecidos e testes bioquímicos, também pode ser observada a análise de solo, seguida de sua correção, conforme particularidades de cada região produtora (Zabini, 2010).

A tendência de monitoramento das cultivares, além de aperfeiçoar seu manejo, também contribui para o fortalecimento da capacidade produtiva e divulgação de dados e tendências sobre a produção agrícola nacional. Esse monitoramento se reflete na geração de informações, seja por meio do mapeamento das áreas de interesse, acompanhamento do uso do solo, condições meteorológicas, como dos requisitos nutricionais, indo do início do florescimento até a colheita e destinação final dos grãos (Conab, 2020).

A análise foliar auxilia na orientação de ajustes de adubação do solo para a correção de possíveis deficiências, tanto de macro quanto de micronutrientes (Mesquita et al., 2016a). Em contrapartida, o diagnóstico visual, usualmente difundido entre os pequenos produtores, pode prejudicar os ganhos na rentabilidade das safras, visto que, quando observada a olho nu, evidencialmente, uma parte significativa da produção da cultura já foi comprometida por alterações na fisiologia da planta (Zabini, 2010).

Em se tratando de tecnologia, diversos trabalhos são realizados mais voltados para estados brasileiros de maior produtividade cafeeira que, na maioria das vezes, possuem parcerias com instituições de pesquisa ligadas à cadeia produtiva, objetivando um vínculo com a cafeicultura sustentável. Arelado a esses estudos, observa-se a redução das áreas destinadas ao café no país, graças a uma otimização de serviços aumentando a produtividade de áreas (Seagri, 2011; Conab, 2020).

Atualmente se sabe que grande parte dos pequenos produtores ainda mantém o sistema de manejo convencional e apresenta dificuldades em relação à adesão de novas técnicas na cafeicultura de precisão. Isso ocorre em virtude da falta de disseminação de conhecimento para esses produtores e pela ausência de trabalhos efetuados em regiões do estado. O fornecimento de dados e a comparação de metodologias convencionais e inovadoras são importantes para a melhor abrangência e visualização sobre o retorno econômico, otimização de trabalho e redução de impacto ambiental que tais práticas produzem (Carvalho et al., 2017; Ibge, 2019; Poppiel et al., 2019; Borges et al., 2020).

2.4 Métodos de análise de nutrientes em tecido vegetal do café

Atualmente diversos métodos para a análise nutricional das culturas são utilizados, entre eles, a digestão seca, a digestão úmida em sistema aberto ou fechado e a solubilização de HCl. Outra prática consiste no monitoramento do estado nutricional por meio da geração dos índices de vegetação, com base na agricultura de precisão, para observações espaciais e temporais nas unidades produtivas das lavouras, visando recomendações por meio do uso de sensores (Carvalho et al., 2017; Melo e Silva, 2008; Borges et al., 2020).

Em relação aos métodos tradicionais, a digestão seca é caracterizada como uma das técnicas mais antigas e simples para análise de tecido vegetal. O material a ser avaliado é incinerado e seu resíduo inorgânico é dissolvido em solução ácida, permitindo a determinação dos mais diversos elementos. É um método simples, porém, demanda tempo e muito trabalho, o que possibilita perdas dos elementos, seja por volatilização ou pela exigência de equipamentos muito específicos para a quantificação (Carvalho et al., 2017; Menenghetti et al., 2018).

A digestão úmida é dividida em sistema aberto e fechado, o sistema aberto é o mais comumente utilizado e demanda maior consumo de reagentes, levando à geração de passivos ambientais. Um exemplo claro do sistema aberto é a digestão nítrico-perclórica (decomposição oxidativa), que faz uso de solução ácida, demandando também bloco digestor com controle de temperatura e tubos de digestão para a determinação nutricional de tecidos vegetais (Melo e Silva, 2008; Menenghetti et al., 2018).

O sistema de digestão fechado apresenta como benefícios a menor perda por volatilização, menor tempo de digestão, menor consumo de HNO_3 e baixo desprendimento de gases tóxicos. Todavia, como principal dificuldade para análises em séries de materiais pelo método, pode-se observar a redução de amostras avaliadas em cada fornada, elevando, assim, o custo de tal análise (Carmo et al., 2000; Menenghetti et al., 2018).

As metodologias de digestão são dispendiosas, demandam produtos químicos, assim como tempo de trabalho mais longo. Isso acaba fazendo com que métodos alternativos sejam buscados, a exemplo da diagnose foliar através de sensores orbitais (sensoriamento remoto) e até mesmo proximais (equipamentos de fluorescência

portátil e sensores multiespectrais de laboratório), cuja correlação com metodologias convencionais já é estudada para diversos materiais e tecidos vegetais em nível global (Poppiel et al., 2019; Borges et al., 2020, Mendes et al., 2021; Hershberger et al., 2021).

A interpretação do estado nutricional do cafeeiro, com base na análise foliar, pode ser realizada como Sistema Integrado de Diagnóstico e Recomendação (DRIS), nível crítico e/ou faixa de suficiência. O DRIS avalia as interações nutricionais informando sua limitação pelos extremos, um índice negativo indicando deficiência nutricional, valores positivos representando seu excesso e valores próximos de zero indicando um valor ótimo (Kurihara et al., 2005; Ferrão et al., 2017).

O nível crítico se refere à concentração do nutriente na matéria seca da planta, por saber da relação direta entre os teores nutricionais no tecido avaliado e sua produtividade. As faixas de suficiência e a concentração, observadas nas amostras, são comparadas com as faixas consideradas adequadas para aquela cultura, sendo, então, mais flexível na diagnose das culturas avaliadas (Kurihara et al., 2005; Ferrão et al., 2017).

O monitoramento de nutrientes minerais reduz a susceptibilidades a algumas pragas e doenças, tendo o exemplo claro da ferrugem do cafeeiro (Pérez et al., 2020). Desse modo, metodologias alternativas e mais rápidas se fazem cruciais para o desenvolvimento da cultura cafeeira.

2.5 Avanços tecnológicos, espectroscopia e aplicabilidade no cenário cafeeiro

Com a crescente demanda para se reduzir os custos de produção, aumentar sua rentabilidade e melhorar as técnicas de manejo, surge a busca por novas práticas de acompanhamento de áreas produtivas (Borges et al., 2020). Essa nova metodologia de manejo visa a otimização de tempo e ampliação de áreas atendidas, o que permite a robustez de informações elaboradas, saindo de conceituações gerais, indo para cenários menores e mais específicos sem tanta dificuldade (Embrapa, 2007; Marin et al., 2019).

A constante busca pela produção de conhecimento, inovação e melhor manejo de cultivares tem elevado o grau de pesquisas para ampliar a produtividade e reduzir a diferença entre os ciclos de produtividade. Essa disseminação de práticas para otimização de trabalho sobre as propriedades rurais acontece de acordo com a criação de metodologias robustas, confiáveis e de baixo custo para sanar questões de estresses, patologias, fertilidade do solo e demandas nutricionais, abrindo espaço para a aplicação

da espectroscopia e imagens hiperespectrais (Dangal et al., 2019; Marin et al., 2019; Borges et al., 2020; Pérez et al., 2020).

Segundo Paulus e Mahlein (2020), as quantificações pela imagem hiperespectral (HSI) baseiam-se no princípio de que todos os materiais refletem energia eletromagnética em padrões e comprimentos de onda específicos, devido à particularidade em sua composição química e estrutural. Desse modo, a espectroscopia consiste no trabalho com a luz e outras radiações, juntamente com o seu dinamismo de um material alvo em estudo (Mendes et al., 2021).

A maioria dessas alterações na fisiologia e comportamento da planta atuam diretamente em sua reflectância, seja na faixa do visível, como nas faixas do infravermelho, o que permite a formação de índices de vegetação ao se observar diferentes bandas espectrais (Marin et al., 2019).

A espectroscopia abrange as mais diversas faixas do espectro (Figura 1), como, por exemplo, a faixa do visível (Vis), de 350 a 700 nm; do infravermelho próximo (NIR), indo de 700 a 1000 nm; e infravermelho de ondas curtas (SWIR), partindo de 1000 a 2500 nm (Tavares et al., 2020). A espectroscopia de refletância difusa no Vis-NIR consiste num método de detecção de alto rendimento, com aplicações nas mais diversas áreas, como o setor agrícola e ambiental, alimentar e médico (Stevens e Ramirez-Lopez, 2014).

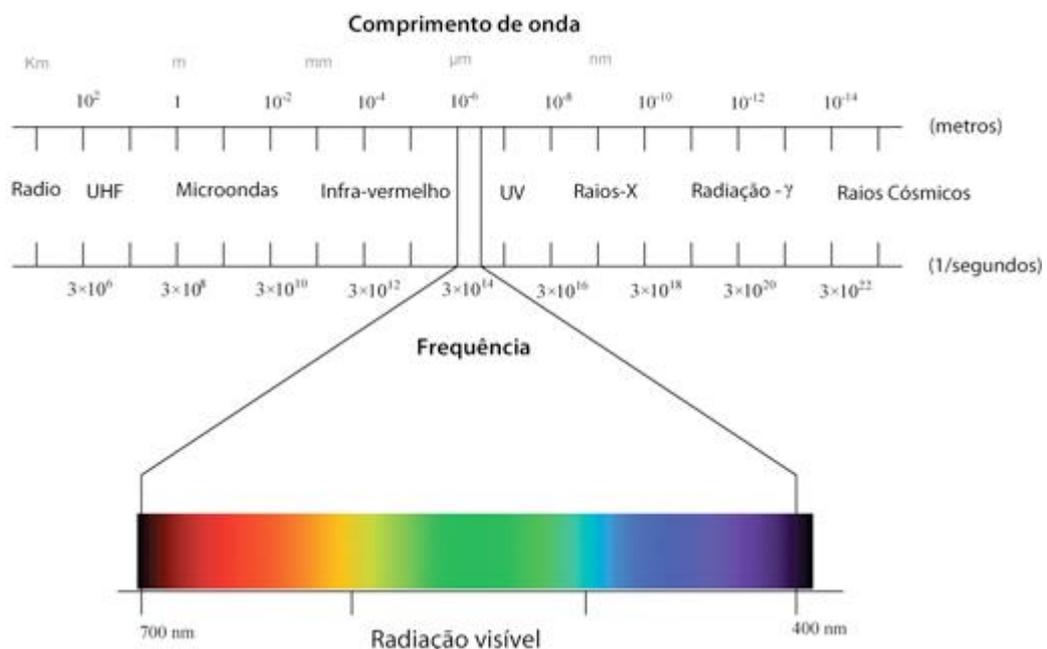


Figura 1 – Espectro da radiação eletromagnética (Universidade de Lisboa, 2022).

Todos os compostos que apresentam ligações covalentes absorvem diferentes

frequências de radiação eletromagnética. Por volta de 1900, obteve-se os espectros de absorção no infravermelho de uma gama elevada de compostos orgânicos em seus diferentes estados. A partir dessa obtenção dos espectros, tornou-se possível analisar e quantificar teores nutricionais em amostras, como no caso de compostos químicos, fragmentos de solos, áreas foliares de culturas de interesse e inúmeros outros (Sala, 2008; Paiva et al., 2010).

Os espectros de refletância Vis-NIR-SWIR de tecidos foliares, obtidos em laboratório, permitem a calibração de modelos preditivos, visando a quantificação de atributos físico-químicos, com uma importância prática, ou seja, sem resíduos químicos (Tavares et al., 2020), visto que a identificação de elementos e suas concentrações permitem uma fiscalização de teores adequados, ressaltando uma fácil disseminação para análises quantitativas e qualitativas, seja para compostos químicos inorgânicos ou orgânicos (Sala, 2008; Skoog et al., 2020).

Estudos mais generalizados sobre espectroscopia e fluorescência de raios-X, nas principais culturas produzidas no Brasil, foram efetuados por Borges e colaboradores (2020), sendo atrelados, todavia, a um número mais reduzido de amostras para a cultura cafeeira, não atendendo o estado baiano. Outros estudos com a cultura cafeeira e espectroscopia abrangeram as alterações químicas em grãos (Silva et al., 2021) e a ocorrência de adulterantes em seu produto final, o café torrado e moído (Couto et al., 2022). Mesmo com tal dimensionamento da ampla aplicabilidade do uso de sensores, poucos estudos são difundidos sobre o teor nutricional de suas folhas, correlacionados à espectroscopia e à modelagem para áreas produtoras no país.

Pesquisas com o uso de espectroscopia para a quantificação de nutrientes já são vistos para a cultura do arroz (Johnson et al., 2021), assim como o uso de espectrômetros NIR para níveis nutricionais em mudas de teca (Whittier et al., 2021), em amostras foliares de capim Mombaça (Tavares et al., 2020), para a discriminação de solos brasileiros cultivados com diferentes culturas (Sousa et al., 2021) e para a geração de modelos preditivos de valor nutricional em forragem (Smith et al., 2020). Esses levantamentos evidenciam ainda mais o potencial crescente da aplicabilidade de sensores na obtenção mais precisa de teores nutricionais e na caracterização de alvos de interesse.

A espectroscopia aplicada na observação de tecidos vegetais consiste em quantificar a diferença na refletância entre as regiões espectrais, tanto do visível quanto do infravermelho nas plantas avaliadas, permitindo a geração de índices de vegetação

para caracterização de povoamentos vegetais de interesse, de acordo com a absorção de energia que ocasiona transições vibracionais específicas (Marin et al., 2019).

A espectroscopia de infravermelho próximo utiliza acessórios de refletância total atenuada (*attenuated total reflectance* - ATR), sendo mais usual para análise de amostras, principalmente sólidas. A radiação penetra na amostra com profundidade pequena, suficiente para fornecer informações sobre sua composição química, demandando, por exemplo, o contato da amostra de tecido vegetal com o espectrofotômetro, para sua comparação à digestão convencional (informações primárias dos dados espectrais e cromatográficos) para a criação de informações secundárias, como modelos para calibração e classificação (Silva, 2017).

O desenvolvimento dos computadores trouxe uma valiosa contribuição para a espectroscopia, tanto por sua utilização direta nos instrumentos, como em cálculos para auxiliar na predição de algumas variáveis de interesse (Sala, 2008). A partir de um reconhecimento de padrões na análise multivariada, elaborada por meio da avaliação de unidades amostrais e sua composição, é permitida a criação de modelos matemáticos para estudos posteriores em áreas desconhecidas, a serem classificadas de acordo com a semelhança ou diferença entre as amostras de um conjunto de treinamento utilizados para a elaboração de um modelo matemático (Silva, 2017).

Quanto maior o vigor da planta, menor será sua refletância em bandas visíveis, assim como no infravermelho médio. Isso ocorre devido ao aumento do teor de água em sua superfície fotossintetizante, ocasionando maior refletância na banda do infravermelho próximo (Marin et al., 2019).

As informações contidas nos espectros para as avaliações são correlacionadas com os valores obtidos por métodos analíticos, buscando evidenciar suas correlações para usos futuros. A formação do modelo multivariado é, então, calibrado e avaliado para a predição de propriedades em amostras futuras, devido a uma quantidade elevada de amostras para calibração do modelo, gerando uma espécie de "impressão digital" do material avaliado, de acordo com as propriedades semelhantes e a composição química dos materiais (Arriel et al., 2019).

Desde os primórdios do estudos acerca da espectroscopia, tem-se o conhecimento de sua versatilidade e abrangência nos mais diversos setores. Para a agricultura não seria diferente, seja na caracterização físico-química de amostras de madeira, na classificação e interpretação de substâncias orgânicas diversas, na determinação de textura do solo e suas propriedades, assim como para a observação de

teores nutricionais das culturas por intermédio das análises de elementos e seus teores em amostras foliares (Ferraresi et al., 2012; Santos, 2017; Arriel et al., 2019; Dubberstein et al.,2019).

3 MATERIAL E MÉTODOS

3.1 Área de estudo e coleta de amostras

O estudo foi conduzido em lavouras de café localizadas na região do Planalto da Conquista, no Sudoeste da Bahia. O local, alvo de estudo, segundo o sistema de classificação de Koppen, apresenta clima do tipo Cfa e está entre as altitudes de 750 e 900m, cuja precipitação anual vai de 700 a 800mm (Alvares et al., 2013). Durante os meses de janeiro e fevereiro de 2021, foram distribuídos 441 pontos de coleta entre 49 propriedades selecionadas na microrregião de Barra do Choça (Figura 2), obtidos mediante levantamentos e visitas às propriedades rurais associadas à Cooperativa Mista dos Cafeicultores de Barra do Choça e Região (COOPERBAC).

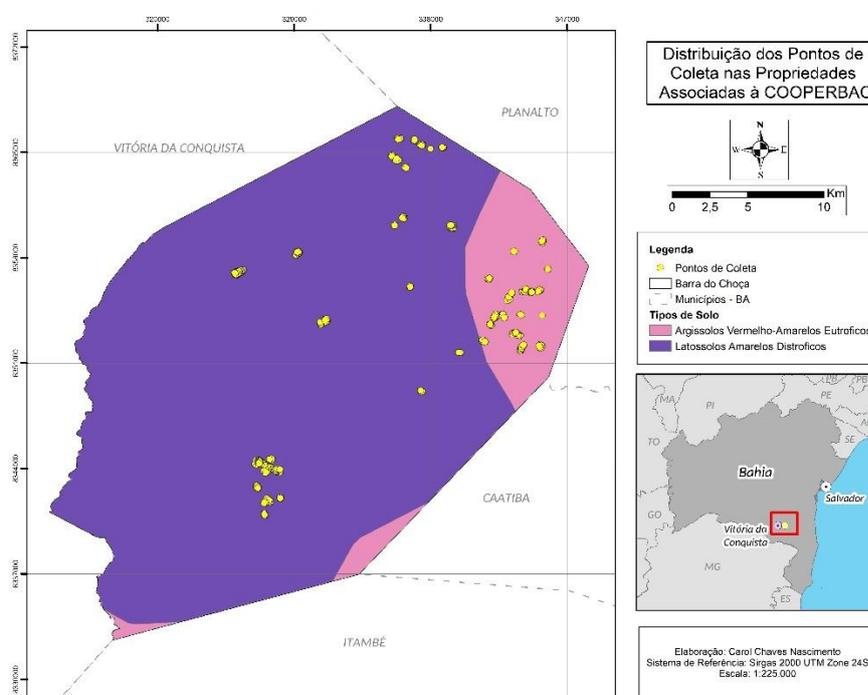


Figura 2 – Localização das 49 propriedades rurais selecionadas para amostragem da microrregião produtora do Planalto da Conquista, Bahia, Brasil.

Dentro dos diferentes plantios, foram distribuídos pontos de forma aleatória, seguindo um *grid* amostral de quatro pontos por hectare de café plantado, buscando representar significativamente toda a extensão das propriedades. Levou-se em consideração a ocorrência de áreas onde os produtores faziam a retirada da parte aérea do plantio para condução da brotação, desconsiderando a mesma na coleta de material vegetal.

Foram obtidas coordenadas geográficas das unidades amostrais com o auxílio de GPS portátil da marca Garmin® Etrex 20, onde foi coletado material vegetal, de acordo com as práticas de cafeicultura convencional. Definiu-se o terço médio das plantas para a retirada do terceiro e o quarto par de folhas completamente desenvolvidas (Figura 3), a partir da extremidade, não contando o primeiro par, caso esse apresentasse tamanho inferior a 2 cm (Embrapa, 2015; Carvalho et al., 2017; Meneghetti et al., 2018). O procedimento de coleta de folhas foi efetuado para até 10 plantas por unidade amostral, a fim de representar de forma mais significativa os teores nutricionais das áreas de coleta.



Figura 3 – Coleta, identificação e preparo do tecido vegetal proveniente da microrregião produtora do Planalto da Conquista, Bahia, Brasil.

Todo o material proveniente das coletas foi acondicionado em sacos de papel com identificação e enviados ao laboratório, onde se procedeu a lavagem deste com água corrente e água destilada (Mesquita et al., 2016a). Posteriormente todo material vegetal foi levado à estufa de circulação forçada, a $60\text{ }^{\circ}\text{C} \pm 5$, até atingirem peso seco constante (Meneghetti, 2018). As amostras secas foram trituradas em Moinho de Facas tipo Willey e homogeneizadas em peneira de 30 mesh (Figura 4) para análises nutricionais e obtenção dos espectros para cada amostra (Meneghetti, 2018; Borges et al., 2020).



Figura 4 – Moagem das amostras seguida de padronização do material vegetal em peneira de 30 mesh.

3.2 Análises Nutricionais

3.2.1 Digestão do material e leitura dos nutrientes

A avaliação nutricional das folhas deu-se pelo método convencional de digestão de tecido vegetal com solução ácida nítrico-perclórica (Silva, 2009), com alterações para a determinação de macro e micronutrientes. Os extratos foram analisados por meio de espectrometria de emissão atômica por plasma, acoplado indutivamente (ICP-OES) para determinar a concentração de macronutrientes (P, K, Ca, Mg) e micronutrientes (Fe, Zn, Mn e Cu) (Yi et al., 2020).

Pesou-se 0,25 g da massa das amostras secas e trituradas, sendo posteriormente tratadas com 3 ml de solução ácida ($\text{HNO}_3\text{:HClO}_4$ 3:1 v/v) e colocadas no bloco digestor para sua digestão. O produto da digestão foi transferido para recipientes plásticos, tendo seu volume completado com 12,5 ml de água Milli-Q® (Figura 5). Para as leituras de K, preparou-se as soluções de 0,5ml dos extratos das digestões para 9,5 ml de água Milli-Q®, quantificando o nutriente em Fotômetro de chama, modelo 910 Analyzer, após calibração do aparelho (Figura 5) (Silva, 2009; Yi et al., 2020).



Figura 5 – Procedimento de pesagem das amostras para digestão nitro perclórica (a); armazenamento da solução proveniente da digestão (b); diluição das soluções para quantificação convencional de nutrientes em espectrômetros de chama (c).

Para a leitura de Ca e Mg, retirou-se 1 ml da solução anterior para 4 ml de La_2O_3 , para quantificação de cálcio e magnésio no aparelho de Espectrômetro de Absorção Atômica Varian, Modelo AA 240FS (Fast Sequential) (Figura 6), fazendo-se a calibração do aparelho a cada 50 leituras. Já para quantificação de P, do extrato proveniente da digestão, retirou-se 2,5 ml do extrato, acrescentando 7,5 ml de água e 4 ml de solução de Molibdato 5% e Vanadato 0,25% (1:1), esperando-se o tempo de reação da solução e efetuando a leitura por meio do Espectrofotômetro UV-VIS a 460 nm, medindo a intensidade da cor amarela ocasionada pela ação da solução reagente (Silva, 2009).

A quantificação de micronutrientes Fe, Mn e Zn foi feita diretamente no extrato da digestão no Espectrômetro de Absorção Atômica Varian, Modelo AA 240FS (Fast Sequential), também fazendo a calibração do aparelho a cada 50 leituras dos extratos

vegetais (Figura 5). Os valores obtidos em cada leitura consistiam da média feita de três leituras, sendo realizada pelo próprio aparelho.



Figura 6 – Apresentação do procedimento de leitura de soluções: (a) Leitura de K em Fotômetro de chama; (b) quantificação nutricional de micronutrientes, Ca e Mg por meio do Espectrômetro de absorção atômica Varian.

3.2.2 Obtenção de dados por sensor FieldSpec 3

Os dados espectrais das 441 amostras foram obtidos através do sensor FieldSpec 3, pertencente ao Laboratório de Geotecnologias ESALQ – USP (Figura 7) (*Analytical Spectral Devices Inc., Boulder, CO, EUA*), cobrindo a faixa de 350 a 2500 nm (VIS-NIR-SWIR), com resolução espectral variando de 3nm, na faixa de 350 a 700 nm e de 10nm partindo dos 700 aos 2500 nm; o qual estava situado em ambiente de condições controladas com a manutenção de temperatura e iluminação do espaço, visando a redução de oscilações e possíveis erros com a utilização do sensor fora de um ambiente padronizado. Antes da leitura do material vegetal, as amostras peneiradas em 30 mesh foram acondicionadas em placas de Petri, preenchendo cerca de metade das placas para que não houvesse interferência dos espaços vazios na obtenção dos espectros (César et al., 2013; Poppiel et al.,2019).

Duas lâmpadas halógenas (50W), a 90° uma da outra, a 0,35 m da superfície amostral e com ângulo zenital de 30°, foram usadas como fonte principal de luz. Um cabo de fibra óptica em posição vertical, a 0,08 m da superfície amostral, foi responsável pela captura da luz refletida, medindo cerca de 2 cm² ao centro de cada amostra acondicionada em placas de Petri (Poppiel et al.,2019).

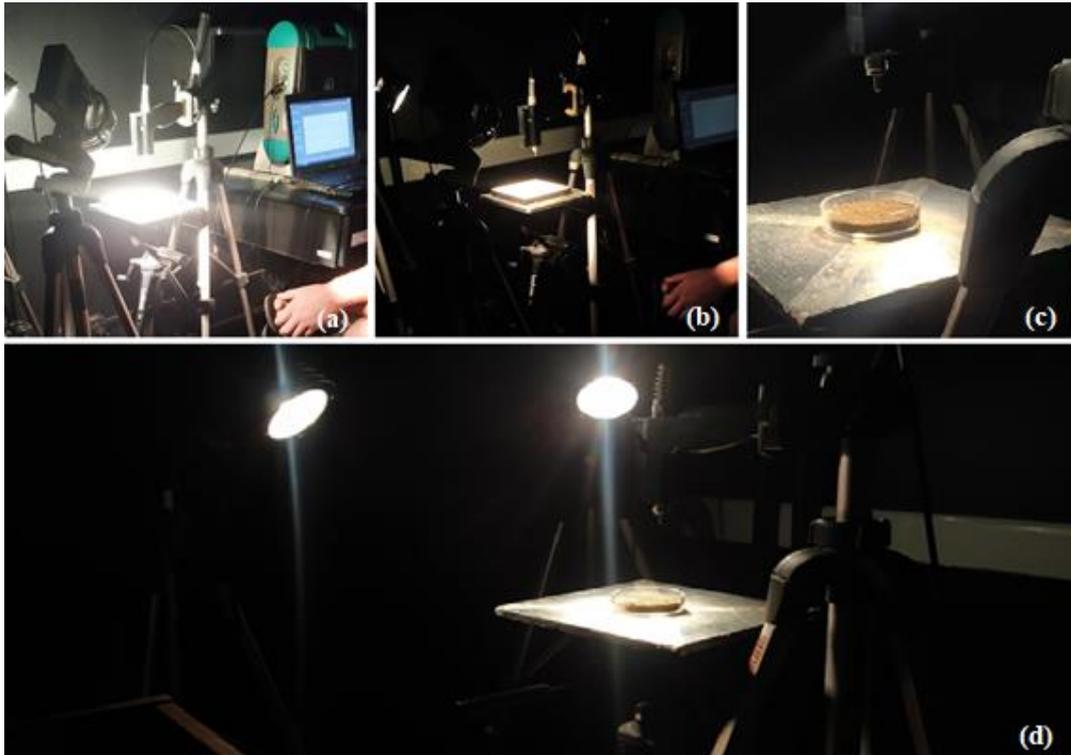


Figura 7 – Obtenção dos espectros: (a) esquematização geral do equipamento e acessórios para a leitura do material vegetal; (b) calibração do aparelho com placa Spectralon; (c) posicionamento das amostras ao centro do alvo do sensor; (d) detalhamento da disposição de lâmpadas halógenas para iluminação de material vegetal.

Os valores de refletância foram obtidos para cada amostra a partir da média de três leituras em posições distintas, após a rotação das placas de Petri em torno de 45° , buscando diminuir os efeitos de sombra sobre as leituras. Durante todas as leituras, ocorria também a calibração do aparelho, logo de início e após o decorrer de 20 minutos, sendo esta calibração efetuada utilizando-se uma placa-padrão branca (Spectralon®) com refletância superior a 99% (Labsphere, North Sutton, NH, EUA) (César et al., 2013; Poppiel et al., 2019).

3.3 Pré-processamento

Para o pré-processamento e criação do modelo, usou-se o *software* R, versão 4.1.1 (R Development Core Team, 2021). Os espectros de refletância foram cortados para redução do sinal-ruído nas extremidades dos espectros da base de dados. Eliminou-se a faixa ultravioleta do espectro, com os dados partindo do visível ao infravermelho (de 400

nm até 2450 nm) que seriam interessantes para a discussão sobre tecidos vegetais (Smith et al., 2020). Também houve a suavização dos espectros, por meio do cálculo da média dos dados espectrais com uma janela de suavização de (9nm) para os espectros de tecido vegetal.

Para as etapas antecessoras à modelagem, observou-se o uso dos espectros originais brutos, assim como de quatro pré-processamentos comuns ao tratamento de espectros: o *Savitzky-Golay* (SG), *Standard Normal Variate* (SNV), *Continuum Removal* (CR) e *Detrend* (Det).

O SG é responsável pela redução do fator de impacto causado pelo espalhamento da luz, com a primeira derivada com polinômio de primeira ordem e tamanho de janela de 9 nm. O SNV é o responsável pelo dimensionamento dos espectros, com base em seu desvio padrão e valor médio, removendo a dispersão nos dados espectrais, sendo este pré-processamento realizado após a filtragem SG (Stevens e Ramirez-Lopez, 2014; Luna e Góis, 2018; Mendes et al., 2020; Smith et al., 2020). Já o Det é utilizado para remover o valor médio e até mesmo possíveis tendências lineares dos espectros (Wadoux et al., 2021) e, por fim, o CR onde os pontos máximos do espectro de refletância local foram identificados e conectados por interpolação linear para formar a remoção contínua, isolando características de absorção (Stevens e Ramirez-Lopez, 2014; Mendes et al., 2021; Wadoux et al., 2021).

3.4 Modelagem e validação

A divisão de dados também se deu no *software* R, versão 4.1.1, usando o método *Conditioned Latin Hypercube Sampling* (cLHS) (Smith et al., 2020), por meio do qual observou-se a separação de 80% (n= 352) dos dados para calibração e 20% (n= 89) para validação do modelo. A retirada de *outliers* se deu pelo método interquartil (iqr), técnica de limpeza de dados que auxilia na detecção de valores discrepantes fora de uma distribuição estatística que não segue o padrão geral em um conjunto de dados, atuando também na previsão de sua dispersão (Mandić-Rajčević e Colosio, 2019; Hernández et al., 2021).

Seu uso resulta em coeficientes de correlação mais altos, possibilitando a observação de melhores predições, visto que, com a remoção de dados extremos, menores são os erros nas interações de dados brutos e dados obtidos via uso de sensores. Já no que se refere à modelagem espectral, esta foi realizada usando três técnicas diferentes, a

Regressão de mínimos quadrados parciais (PLSR), *Random Forest* (RF) e a técnica Cubista (CUB), também fazendo uso do *software* R versão 4.1.1 (R *Development Core Team*, 2021), em que sua otimização pelo método de validação cruzada (cv) foi executada 10 vezes dentro de cada modelo.

O PLSR, caracterizado como método de regressão multivariada, constrói um modelo de regressão linear relacionando os dados espectrais através da combinação da Análise de Componente Principais (PCA) e regressão múltipla (Borges et al., 2020; Wadoux et al., 2021). O PLSR teve o parâmetro ajustável contido na seleção de componentes principais que explicassem 95% das variâncias de suas variáveis latentes com base no número de componentes principais (Ncomp) (Mendes et al., 2021).

Já o RF, criando diversas árvores de regressão pela combinação de preditores, é responsável pelo cálculo da média de todas as saídas, auxiliando a previsão de variáveis dependentes de interesse (Breiman, 2001). Enfim, a modelagem CUB usa um conjunto de modelos multivariados por meio do pacote Cubist, cuja previsão final se baseia em modelos lineares que satisfaçam as condições de suas variáveis predictoras (Dangal et al., 2019; Kuhn et al., 2021)

Foi observada a validação dos modelos usando a divisão de 20% do conjunto de dados, separados para a validação externa. Por fim, avaliou-se o desempenho na predição dos modelos, por meio dos índices: Coeficiente de determinação (R^2), buscando maiores valores, visto que o modelo tende a explicar uma dada quantidade de variância; e o erro quadrático médio de menor valor (RMSE), indicando a precisão do modelo e quão concentrados os dados estão em torno de uma linha (Paulus e Mahlein, 2020; Smith et al., 2020; Mendes et al., 2021; Wadoux et al., 2021).

A razão de desempenho para distância interquartil (RPIQ), contabilizando a distribuição não normal das observações, foi obtida fazendo-se uso do intervalo interquartil, tanto para os dados de calibração quanto de validação; do coeficiente de correlação de concordância (ccc), avaliando a concordância entre as leituras, medindo a variação das linhas nos gráficos, quando comparados à linha de origem (concordância); e, finalmente, do erro médio (Bias), geralmente calculado com o RMSE, avaliando o viés de previsões por meio da média de todos os erros entre previsões e observações (Lawrence e Lin, 1989; Wadoux et al., 2021).

4 RESULTADOS

Os valores nutricionais médios giraram em torno de 1,78; 7,78; 23,42 e 6,46 g kg⁻¹ para os macronutrientes P, K, Ca e Mg, respectivamente; e 3,01; 68,75; 10,45 e 97,83 mg kg⁻¹ para os micronutrientes Zn, Mn, Cu e Fe, respectivamente (Tabela 1); enquadrando, desse modo, o K e o Fe nos teores abaixo do recomendado (Embrapa, 2015).

Mesmo com a verificação dos valores nutricionais médios, vale a pena mencionar os valores predominantes observados nas medianas de cada elemento (Tabela 1). Dentro desse parâmetro, pode se notar uma quantificação inferior dos teores nutricionais de K e dos demais micronutrientes (Mn, Cu e Fe), evidenciando a importância da adubação pós-safra para reconstituição da capacidade produtiva de plantios cafeeiros.

Tabela 1 – Estatística descritiva de nutrientes extraídos em plantios cafeeiros no Planalto da Conquista, Brasil

Parâmetros	Ca	Mg	P	K	Cu	Mn	Fe	Zn
	g kg ⁻¹				mg kg ⁻¹			
Nobs	441	441	441	441	441	441	441	441
Mínimo	0.34	0.00	0.68	1.00	0.00	4.95	0.00	0.00
1° Quartil	18.21	4.96	14.67	4.00	5.30	32.00	59.15	0.00
Mediana	21.85	6.36	1.71	6.00	8.25	55.65	85.70	0.00
Média	23.42	6.46	1.78	7.78	10.45	68.75	97.83	3.01
3° Quartil	27.33	7.80	20.04	8.50	14.20	92.60	120.95	0.00
Máximo	57.34	23.89	17.69	545.70	54.00	441.20	1116.00	107.00
CV	31.43	37.46	49.44	33.16	71.29	75.19	72.88	291.69
SD	7.36	2.42	0.88	2.58	7.45	51.69	71.30	8.78
Assimetria	0.96	1.43	13.31	20.46	1.50	1.83	7.06	5.49
Curtose	1.38	7.84	235.41	422.46	3.55	6.58	92.73	47.89

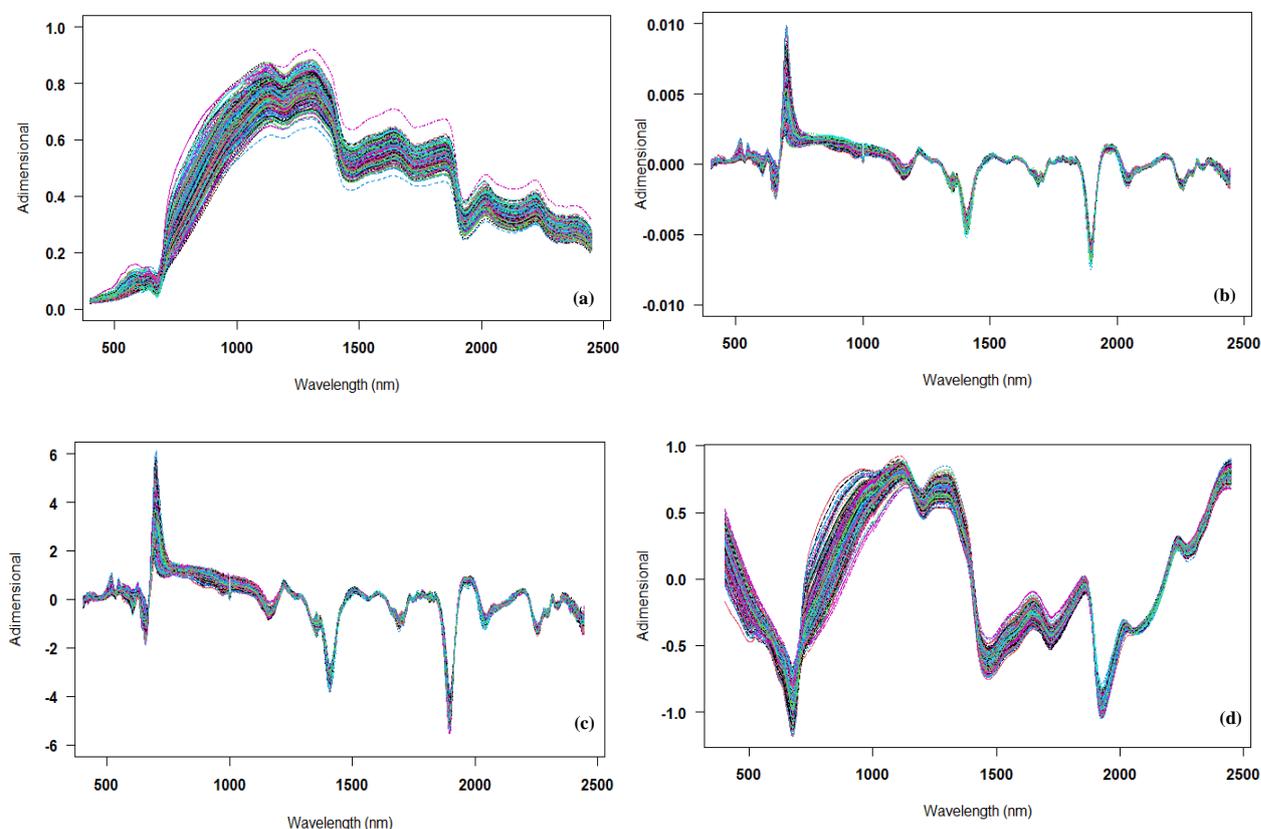
Nobs: Número de observações; SD: Desvio padrão; CV: Coeficiente de variação.

Durante o processo de quantificação e modelagem, observou-se, mediante estatística descritiva, que os níveis de detecção do Zn não eram satisfatórios para sua comparação com as análises de espectroscopia, nem ao menos viáveis para o seu uso nas três diferentes modelagens. A exclusão do elemento se deu pela limitação de leitura via técnicas convencionais de digestão ácida, visto que o espectrômetro de absorção atômica

não conseguia quantificar as concentrações baixas presentes no tecido amostral, fazendo com que o mesmo aparecesse como inexistente em grande parte das leituras.

Para retirada dos *outliers*, observou-se que, das 352 unidades amostrais utilizadas para o treinamento e validação da modelagem, houve a retirada de 18 *outliers* para Ca e Cu, 13 para Fe, 14 para Mn, 5 para Mg, 3 em P e 2 em K. Desse modo, a maior retirada de *outliers* ainda foi inferior a 6% da base de dados total para o treinamento (5,11%).

A Tabela 2 apresenta, de forma geral, a capacidade preditiva de diferentes modelos, graças aos pré-processamentos aplicados na base de dados. Com base nos valores de R^2 , a previsão nutricional decrescia na seguinte ordem: $K > Mg > Ca > Cu > P > Fe > Mn$. Para Ca, os valores de R^2 variavam de 0,07 a 0,29 dentro dos modelos, sendo a técnica cubista (CUB) responsável pela maior predição com os dados brutos ($RMSE_v=5.77 \text{ g kg}^{-1}$, $RPIQ= 1,56$ e $R^2=0,29$), seguido pelo modelo de Regressão de mínimos quadrados parciais (PLSR) junto de dados brutos ($RMSE= 5,91 \text{ g kg}^{-1}$, $RPIQ=1,52$, $R^2=0,26$) e com o tratamento *Savitzky-Golay* (SG) nos dados ($RMSE= 5,95 \text{ g kg}^{-1}$, $RPIQ=1,51$, $R^2= 0,25$). Na figura 8 estão apresentados os pré-processamentos usados nas bases de dados.



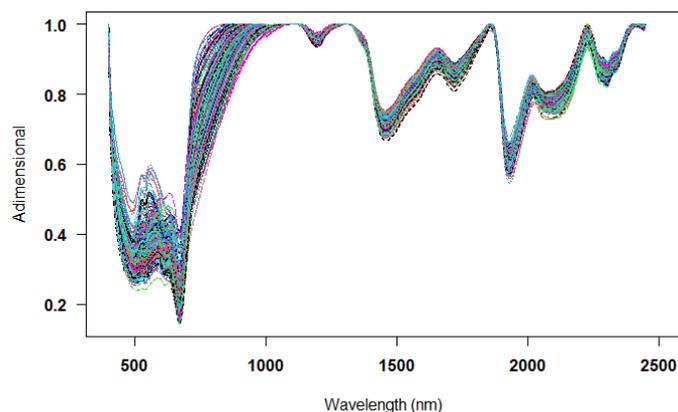


Figura 8 – Apresentação dos pré-processamentos dos espectros: (a) Dados brutos, (b) *Savitsky-Golay*, (c) *Standard Normal Variate*, (d) *Detrend*, (e) *Continuum Removal*.

Para Mg, observou-se uma capacidade de predição um pouco maior que o nutriente anterior (Tabela 2), cuja base de dados de validação se aproxima mais da linha de tendência apresentada com a geração do modelo, evidenciado nos componentes da Figura 9. Nesse nutriente, as melhores métricas foram observadas também na modelagem CUB dos dados brutos de $RMSE=1,93 \text{ g kg}^{-1}$, $RPIQ= 1,29$, $R^2= 0,41$.

Em relação à quantificação de P, as variáveis estatísticas obtidas já apresentaram a modelagem PLSR como mais viável à sua predição, quando comparada aos modelos RF e CUB. Este, por sua vez, foi promissor, fazendo o uso do pré-processamento SNV (Figura 10) de valor $RMSE=0.36 \text{ g kg}^{-1}$, $RPIQ= 1,41$, $R^2=0,25$. Assim como o P, o macronutriente K também apresentou o PLSR como melhor modelo de predição, seguido pelo pré-processamento SG e SNV (Tabela 2).

Tabela 2 – Estatísticas preditivas para calibração e validação dos três modelos para macronutrientes Ca, Mg, P, K e micronutrientes Cu, Mn e Fe, provenientes de tecido vegetal de cafeeiros

Trat.	PLSR							CUB							RF							
	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	
Ca (g kg ⁻¹)																						
Orig	5,62	0,29	5,91	0,26	0,36	0,43	1,52	5,31	0,39	5,77	0,29	-0,22	0,43	1,56	5,74	0,27	6,18	0,18	-0,04	0,33	1,45	
SNV	5,47	0,33	6,10	0,22	0,23	0,40	1,47	5,24	0,4	6,20	0,19	-0,52	0,35	1,45	5,35	0,37	6,16	0,19	-0,23	0,32	1,46	
CR	5,51	0,31	6,10	0,22	0,14	0,43	1,47	6,97	0,17	7,05	0,09	-0,09	0,30	1,27	5,59	0,31	6,19	0,18	-0,20	0,33	1,45	
Det	5,52	0,31	6,07	0,22	0,40	0,39	1,48	5,24	0,39	6,06	0,22	-0,51	0,37	1,48	5,77	0,26	6,75	0,07	-0,25	0,22	1,33	
SG	5,46	0,33	5,95	0,25	0,40	0,44	1,51	5,50	0,32	6,16	0,21	0,24	0,41	1,46	5,47	0,35	6,14	0,20	-0,18	0,34	1,46	
Mg (g kg ⁻¹)																						
Orig	1,39	0,57	2,07	0,32	-0,33	0,51	1,21	1,24	0,66	1,93	0,41	-0,30	0,56	1,29	2,00	0,12	2,51	0,03	-0,57	0,09	0,99	
SNV	1,34	0,59	1,97	0,38	-0,25	0,56	1,27	1,26	0,64	1,99	0,37	-0,31	0,53	1,25	1,73	0,39	2,36	0,12	-0,45	0,21	1,06	
CR	1,45	0,53	2,07	0,33	-0,33	0,53	1,21	1,61	0,48	2,26	0,24	-0,28	0,47	1,10	1,85	0,24	2,41	0,09	-0,47	0,17	1,04	
Det	1,36	0,58	1,95	0,39	-0,32	0,55	1,28	1,21	0,68	1,92	0,42	-0,35	0,58	1,30	1,81	0,28	2,60	0,01	-0,41	0,10	0,96	
SG	1,36	0,58	2,02	0,35	-0,21	0,56	1,24	1,94	0,18	2,41	0,07	-0,25	0,19	1,04	1,73	0,37	2,29	0,18	-0,40	0,25	1,09	
P (g kg ⁻¹)																						
Orig	0,38	0,26	0,38	0,20	0,06	0,42	1,34	0,39	0,21	0,35	0,23	0,01	0,36	1,44	0,43	0,07	0,40	0,03	0,05	0,12	1,27	
SNV	0,38	0,26	0,36	0,25	0,05	0,47	1,41	0,35	0,37	0,37	0,23	0,05	0,46	1,38	0,38	0,29	0,36	0,22	0,06	0,32	1,41	
CR	0,40	0,18	0,36	0,24	0,05	0,46	1,40	0,50	0,11	0,43	0,13	0,07	0,36	1,18	0,40	0,18	0,40	0,08	0,07	0,21	1,28	
Det	0,39	0,20	0,38	0,17	0,04	0,39	1,34	0,38	0,28	0,36	0,19	0,04	0,36	1,39	0,41	0,15	0,39	0,10	0,08	0,24	1,29	
SG	0,38	0,23	0,37	0,21	0,07	0,42	1,38	0,42	0,11	0,37	0,17	0,04	0,33	1,38	0,39	0,26	0,36	0,20	0,04	0,26	1,39	

Trat.: tratamentos espectros; Orig: dados brutos; SNV: *Standard Normal Variate*; CR: *Continuum Removal*; SG: *Savitzky-Golay*; Det: *Detrend*; RMSEc: erro quadrático médio de calibração; R²c: coeficiente de determinação calibração; RMSEv: erro quadrático médio de validação; R²v: coeficiente de determinação de validação; BIAS: erro médio; CCC: coeficiente de correlação de concordância; RPIQ: relação desempenho/distância interquartil. Os modelos com melhor eficiência em negrito.

Tabela 2 cont. – Estatísticas preditivas para calibração e validação dos três modelos para macronutrientes Ca, Mg, P, K e micronutrientes Cu, Mn e Fe, provenientes de tecido vegetal de cafeeiros

Trat.	PLSR							CUB							RF						
	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ
K (g kg ⁻¹)																					
Orig	1,74	0,65	1,47	0,69	0,15	0,80	2,73	1,62	0,68	1,46	0,69	-0,05	0,80	2,73	2,15	0,48	2,09	0,37	-0,10	0,55	1,92
SNV	1,72	0,66	1,40	0,72	0,00	0,83	2,86	1,60	0,69	1,44	0,70	-0,15	0,81	2,77	1,83	0,62	1,75	0,56	-0,16	0,69	2,28
CR	1,69	0,67	1,58	0,64	0,09	0,78	2,54	1,95	0,59	2,09	0,44	-0,14	0,66	1,92	1,98	0,55	1,86	0,50	-0,26	0,65	2,15
Det	1,73	0,65	1,55	0,65	0,11	0,78	2,58	1,65	0,69	1,41	0,73	-0,10	0,80	2,84	1,93	0,58	1,94	0,46	-0,26	0,60	2,06
SG	1,71	0,66	1,50	0,67	0,05	0,8	2,67	1,88	0,59	1,81	0,54	-0,19	0,72	2,21	1,79	0,64	1,68	0,60	-0,08	0,72	2,38
Cu (mg kg ⁻¹)																					
Orig	5,47	0,31	5,97	0,18	0,43	0,42	1,31	5,20	0,40	5,36	0,25	-0,05	0,45	1,46	5,82	0,23	6,02	0,10	1,11	0,26	1,30
SNV	5,38	0,33	5,75	0,25	0,35	0,49	1,37	4,68	0,50	5,41	0,27	0,51	0,5	1,45	5,01	0,44	5,65	0,19	0,58	0,37	1,39
CR	5,29	0,35	5,58	0,25	0,46	0,48	1,41	6,39	0,23	6,92	0,11	0,55	0,34	1,13	5,60	0,28	6,96	0,14	0,37	0,38	1,13
Det	5,35	0,34	5,83	0,24	0,44	0,48	1,35	5,16	0,40	6,06	0,14	0,45	0,36	1,29	5,39	0,34	6,07	0,10	0,64	0,27	1,29
SG	5,46	0,31	5,76	0,23	0,62	0,46	1,36	5,14	0,40	6,01	0,14	0,65	0,35	1,31	5,10	0,42	5,79	0,15	0,77	0,32	1,36
Mn (mg kg ⁻¹)																					
Orig	36,64	0,12	64,23	0,04	-7,89	0,14	0,80	36,77	0,15	62,24	0,10	-7,57	0,16	0,83	38,29	0,09	63,74	0,05	-5,33	0,09	0,81
SNV	36,88	0,10	59,17	0,19	-9,13	0,31	0,87	34,70	0,22	61,20	0,13	-8,73	0,22	0,84	34,80	0,23	64,13	0,04	-6,81	0,08	0,80
CR	37,33	0,08	64,47	0,03	-7,12	0,10	0,80	43,62	0,10	68,61	0,03	-3,39	0,16	0,75	35,82	0,18	66,32	0,01	-5,84	0,03	0,77
Det	36,08	0,14	63,85	0,05	-7,11	0,16	0,80	34,16	0,24	63,10	0,07	-7,74	0,17	0,81	34,91	0,21	64,54	0,03	-5,97	0,10	0,80
SG	36,55	0,12	59,65	0,17	-8,98	0,30	0,86	36,94	0,14	64,49	0,04	-9,63	0,11	0,80	36,01	0,16	63,29	0,07	-6,83	0,10	0,81

Trat.: tratamentos espectros; Orig: dados brutos; SNV: *Standard Normal Variate*; CR: *Continuum Removal*; SG: *Savitzky-Golay*; Det: *Detrend*; RMSEc: erro quadrático médio de calibração; R²c: coeficiente de determinação calibração; RMSEv: erro quadrático médio de validação; R²v: coeficiente de determinação de validação; BIAS: erro médio; CCC: coeficiente de correlação de concordância; RPIQ: relação desempenho/distância interquartil. Os modelos com melhor eficiência em negrito.

Tabela 2. cont. – Estatísticas preditivas para calibração e validação dos três modelos para macronutrientes Ca, Mg, P, K e micronutrientes Cu, Mn e Fe, provenientes de tecido vegetal de cafeeiros

Trat.	PLSR							CUB							RF							
	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	RMSEc	R ² c	RMSEv	R ² v	BIAS	CCC	RPIQ	
Fe (mg kg ⁻¹)																						
Orig	38,77	0,16	52,37	0,06	-11,74	0,21	0,99	38,43	0,20	51,90	0,08	-14,84	0,20	1,00	40,65	0,12	51,22	0,07	-11,86	0,07	1,02	
SNV	37,64	0,21	55,54	0,02	-12,05	0,14	0,94	36,47	0,27	51,76	0,10	-17,14	0,20	1,01	37,13	0,25	50,24	0,10	-12,28	0,19	1,04	
CR	38,19	0,19	52,34	0,05	-10,13	0,18	0,99	46,32	0,15	55,05	0,14	-9,48	0,37	0,95	37,39	0,23	51,50	0,07	-13,12	0,17	1,01	
Det	38,42	0,18	54,13	0,04	-12,29	0,17	0,96	37,64	0,23	50,92	0,11	-15,03	0,23	1,02	38,85	0,18	49,12	0,16	-13,38	0,23	1,06	
SG	38,26	0,19	55,81	0,02	-12,37	0,14	0,93	38,88	0,19	51,00	0,11	-14,19	0,25	1,02	37,19	0,26	48,24	0,20	-12,81	0,25	1,08	

Trat.: tratamentos espectros; Orig: dados brutos; SNV: *Standard Normal Variate*; CR: *Continuum Removal*; SG: *Savitzky-Golay*; Det: *Detrend*; RMSEc: erro quadrático médio de calibração; R²c: coeficiente de determinação calibração; RMSEv: erro quadrático médio de validação; R²v: coeficiente de determinação de validação; BIAS: erro médio; CCC: coeficiente de correlação de concordância; RPIQ: relação desempenho/distância interquartil. Os modelos com melhor eficiência em negrito.

Apenas o nutriente K apresentou valores de predição extremamente fortes, quando comparado aos outros nutrientes, apresentando uma capacidade preditiva elevada com valores de R^2 de 0,72 para SNV em PLSR e R^2 de 0,73 para *Detrendind* em Cubist. Todos os modelos preditivos apresentaram, dentro de K, valores de R^2 elevados (Tabela 2). Em CUB, para o nutriente, observou-se que DET e SNV obtiveram valores consideráveis no modelo (RPIQ de 2,84 e 2,77; R^2v de 0,70 e 0,73; RMSEv de 1,41 e 1,44, respectivamente). Já em RF, essa capacidade preditiva foi menos expressiva que os anteriores, porém os maiores valores de R^2v também foram observados nos pré-processamentos SG e SNV (R^2v para SNV de 0,56 e R^2v para SG de 0,60).

Mediante a avaliação dos modelos de predição nutricional, a modelagem PLSR apresenta números de componentes principais elevados para se conseguir explicar cerca de 95% das variações entre os pré-processamentos e diferentes nutrientes. Dentro de todos os elementos, os pré-processamentos SG e SNV foram responsáveis pela melhor explicação do percentual de variância, utilizando uma menor quantidade de componentes principais (Tabela 3). De modo geral, o pré-processamento SNV mais se adequou aos modelos de predição nos elementos quantificados, porém, para a predição de K, por meio da modelagem Cubist, também se observou o impacto do Det como pré-processamento da base de dados, possibilitando observar maior valor de R^2 .

Tabela 3 – Apresentação dos parâmetros auxiliares dos modelos preditivos PLSR, RF e CUB para a quantificação de macro e micronutrientes de tecido vegetal por meio de *software R*

Elemento	pré-processamento	PLSR	RF	CUB	
		Ncomp	Mtry	Commite	Neighbors
Ca	Orig	12	64	20	0
	SG	7	63	20	9
	CR	14	2051	20	0
	Detrend	12	64	20	0
	SNV	6	63	20	0
Mg	Orig	13	2051	20	0
	SG	8	2043	10	9
	CR	15	64	20	0
	Detrend	14	2051	20	0
	SNV	8	2043	20	0
P	Orig	15	64	10	0
	SG	5	63	10	9
	CR	14	64	20	0
	Detrend	15	64	10	0
	SNV	6	63	10	5
K	Orig	14	64	20	0
	SG	7	2043	20	5
	CR	15	64	20	0
	Detrend	15	64	20	0
	SNV	10	2043	20	9
Cu	Orig	13	2051	10	0
	SG	5	63	20	5
	CR	15	64	10	0
	Detrend	15	64	20	5
	SNV	7	63	20	5
Mn	Orig	13	2051	20	0
	SG	7	2043	20	9
	CR	9	64	10	0
	Detrend	14	64	20	9
	SNV	6	63	20	9
Fe	Orig	15	64	20	0
	SG	13	63	10	9
	CR	11	2051	20	0
	Detrend	13	2	10	0
	SNV	8	2043	20	0

Orig: dados brutos; SNV: Variação normal padrão; CR: Remoção Contínua; SG: *Savitzky-Golay*; Det: Detendência.

Já entrando na predição dos micronutrientes, o elemento Cu apresentou melhores parâmetros com a modelagem CUB e a base SNV. Seus valores de R^2v foram os maiores vistos na predição dos micronutrientes. Em CUB, observa-se valores de RMSEv, R^2v e RPIQ de 5,41mg kg⁻¹, 0,27 e 1,45, respectivamente; já em PLSR, valores inferiores, porém próximos, são vistos com SNV e CR (RMSEv= 5,75 e 5,58; R^2v = 0,25, em ambos os pré-processamentos, e RPIQ= 1,37 e 1,41).

Em Mn, o uso de SNV, atrelado ao PLSR, apresentou maior R^2v (0,19) se comparado às demais combinações e modelagens. Dentro da base CUB, tem-se o reforço da capacidade de uso do pré-processamento SNV na base de dados (por seu menor RMSEv de 61,20 no modelo, mesmo que, de modo geral, ainda seja um valor alto que demande correções e maiores estudos). Já em relação à modelagem RF, um destaque para o pré-processamento mais viável ao seu uso seria o SG, o qual permitiu um coeficiente de correlação maior do que os demais, dentro do modelo.

Entre todos os elementos analisados, apenas o Fe apresentou capacidade de uso significativo do modelo RF que, por sua vez, ao utilizar o SG e o Det, apresentou maiores valores de R^2v de 0.2 e 0.16, respectivamente, seguidos de menores RMSEv (48,24 e 49,12), quando comparados aos demais processos de modelagem dentro do elemento de interesse. Em geral, os pré-processamentos SG e SNV foram mais bem ajustados em todos os modelos para previsões dos macros e micronutrientes. E dentro dos modelos preditivos, os mais expressivos foram o PLSR e CUB.

Nem todos os modelos apresentaram capacidade preditiva satisfatória, principalmente ao analisar parâmetros estatísticos de micronutrientes. De todos os modelos usados para a comparação de dados obtidos via digestão e com o uso dos espectros, a modelagem PLSR apresentou melhores relações de seus parâmetros estatísticos, tendo um dos melhores R^2v observados entre a predição de K. A validação dos modelos trouxe consigo uma predição que demanda maior número de amostras para melhor robustez do modelo, assim como maiores estudos, buscando incrementar o potencial preditivo em elementos como Fe e Mn.

5 DISCUSSÃO

5.1 Avaliação dos teores nutricionais

Os valores nutricionais de macronutrientes giraram em torno do teor adequado proposto pela Embrapa (2015) para a quantificação de P, Ca e Mg. Já os teores médios e as medianas de K e os micronutrientes Mn, Cu, Fe apresentaram uma quantificação inferior ao teor adequado. Esses teores abaixo da faixa adequada podem ser explicados por intermédio da época de coleta do tecido vegetal, efetuada logo após o período de safra de plantios cafeeiros do ano de 2020.

As afirmações anteriores reforçam a ideia de que, anualmente, os frutos de cafeeiros coletados funcionam como drenos e são a principal saída de micronutrientes do plantio. Tal afirmativa é corroborada pelo estudo de Árvay e colaboradores (2018) que, ao quantificarem o teor nutricional dos grãos de café e suas soluções, obtiveram valores expressivos de macro e micronutrientes, sendo eles K, Ca, Cu, Fe, Mg e Mn. As alterações químicas nos grãos de café, devido às densidades de plantio e diferentes épocas de colheita, podem estar associadas ao teor nutricional apresentado nas análises foliares, porém o estudo sobre a interação destes para a cultura cafeeira ainda é escasso (Silva et al., 2021).

Dentro das avaliações dos teores nutricionais dos elementos P, K, Ca, Mg, observou-se que Ca e K foram os elementos mais expressivos no tecido vegetal, mesmo que o último ainda não apresente um teor adequado para tecidos vegetais de café. Isso confirma que, dentro da quantificação dos macronutrientes, Ca e K são os elementos mais abundantes na matéria seca da planta (Embrapa, 2015; Borges et al., 2020).

A deficiência do Mn pode ser ocasionada pela aplicação excessiva de calcário que tende a impactar na queda das folhas mais velhas, também podendo ocasionar em perda dos frutos na fase cereja em épocas de perspectiva de produção elevada (Martinez et al., 2003; Embrapa, 2015). A adubação de Zn em excesso pode proporcionar deficiência desse elemento, assim como a adubação em excesso de Mn pode provocar deficiência de Fe. O Mn atua como ativador de diferentes enzimas, e é constituinte de barreiras para patógenos (Pérez et al., 2020), ressaltando, assim, a importância, inclusive, da manutenção de micronutrientes em plantios.

Desse modo, a diagnose nutricional, após as safras, são responsáveis pela diagnose nutricional mais próxima da real necessidade da cultura. Quando não há a adubação adequada das áreas produtoras, nem o conhecimento dos solos onde o mesmo se encontra, tem-se, então, o comprometimento da produtividade futura.

A ausência de práticas de adubação e calagem em pequenas propriedades também pode interferir nas respostas de micronutrientes em concentrações inferiores no tecido foliar que, quando em níveis inferiores aos teores adequados, podem aumentar a susceptibilidade a danos causados por patógenos, diretamente ou indiretamente, ao se observar o enfraquecimento estrutural e fisiológico da planta (Embrapa, 2015; Pérez et al., 2020).

Os micronutrientes catalisam e servem como cofator de enzimas envolvidas em diferentes reações metabólicas (Pérez et al., 2020). Os teores de Mn, Cu e Fe, considerados abaixo do nível adequado, podem ser explicados pela baixa disponibilidade de água nas áreas produtoras (Embrapa, 2015). Como a maioria das propriedades amostradas fazem seu cultivo em sequeiro, o baixo teor de água também contribui para uma menor captação de nutrientes minerais absorvíveis na água, tendo como principal consequência uma menor fração apresentada em tecidos vegetais como na cultura do café (Salles et al., 2021).

O P é um componente relativamente pequeno do peso seco da folha, com concentração inferior a 1% nos tecidos, o que permite reforçar que as concentrações observadas seguem uma distribuição proporcional. Mesmo que se comparada aos demais macronutrientes, essa concentração pareça extremamente pequena, esta segue padrões ideais, não extrapolando o teor adequado para a cultura, evitando efeitos negativos de sua ocorrência em excesso (Embrapa, 2015; Mandelmilch et al., 2021).

Pérez e colaboradores (2020), ao avaliarem a susceptibilidade de plantas de café à ferrugem, obtiveram valores de Mn foliar girando em torno de 60,0 a 340,0 mg kg⁻¹ para Mn, com aumento de 0,05 a 4,00 mg⁻¹ do micronutriente correspondente às soluções nutritivas usadas no experimento, sendo o menor teor muito próximo aos valores observados durante as coletas do tecido cafeeiro.

5.2 Avaliação dos diferentes tipos de modelagem

No que se refere aos modelos de predição nutricional, como cada laboratório usa um fluxo de trabalho específico para avaliação, processamento e manuseio de dados, tem-se dados individualmente válidos, mas difíceis de se realizar uma comparação mais minuciosa com os demais materiais (Paulus e Mahlein, 2020). Tais afirmativas evidenciam também a necessidade de estudos futuros, buscando a padronização dos dados obtidos por diferentes sensores ao redor do mundo.

Fatores externos podem ter influenciado na eficácia dos espectros medidos, mesmo após o processo de suavização dos espectros médios, juntamente com os pré-processamentos (Wadoux et al., 2021). A configuração óptica, características do sensor, seu possível deslocamento, ruídos, efeitos de distorção, efeitos da iluminação ativa, assim como as diferentes propriedades do tecido vegetal em análise sobre a variabilidade espectral dos teores nutricionais das amostras, segundo Pérez e colaboradores (2020) e Paulus e Mahlein (2020), podem estar relacionados pela diferença em genótipos, variação temporal, às condições específicas de cultivo, crescimento e até mesmo aos órgãos vegetais que tendem a apresentar variações em seus espectros devido às diferentes propriedades de cada tecido vegetal, demandando estudos posteriores sobre as variedades de cultivares de café da região.

A afirmativa de que o algoritmo de suavização de SG é o mais estabelecido para dados hiperespectrais foi corroborada no atual experimento, acrescentando agora a potencial aplicabilidade do SNV correlacionado ao mesmo nas análises de dados (Paulus e Mahlein, 2020). O SNV apresenta bom desempenho nos mais diversos métodos de modelagem, possivelmente, devido à influência do espalhamento na coleta de dados de refletância espectral (Jin et al., 2022).

Estudos sobre outros sensores convencionais se fazem necessários para a observação de níveis de detecção menores de micronutrientes, viabilizando, assim, a comparação com a quantificação de sensores proximais. O Zn não foi modelado, devido ao nível de detecção do aparelho, porém, estudos recentes, como o de Pérez e colaboradores (2020), evidenciam a importância de se quantificar e manter o estado dos micronutrientes em cafeeiros, visto que o B, Zn e Mn influenciam individualmente a severidade da ferrugem, sendo a aplicação de Zn a responsável pela maior redução da curva de progresso da doença.

Para a modelagem RF, estudos a apresentam como uma metodologia adequada, ao combinar a representação de relações não lineares e as interações entre variáveis de forma mais usual. Seu pré-processamento melhora seu desempenho e seus valores paramétricos robustos, em alguns casos, são vantajosos para dados de sensoriamento remoto hiperespectral e sua relação com o estado fisiológico da planta (Doktor et al., 2014; Hershberger et al., 2021). Mesmo diante de tais afirmativas, o atual estudo apresenta a modelagem RF como a que menos apresentou variáveis paramétricas satisfatórias para a substituição da modelagem CUB ou PLSR.

A modelagem CUB é robusta, a ponto de conseguir cobrir vários anos de análise, caso necessário, funciona para classificações mais simples, além de ser capaz de fornecer comprimentos de onda utilizados juntamente com uma porcentagem de utilidade para a previsão (Smith et al., 2020; Tavares et al., 2020). No presente estudo, a mesma se apresentou promissora, além do PLSR, que possui capacidade de lidar com um número grande de variáveis preditoras, reforçando a ideia de seu amplo uso com espectros NIR e melhorando o desempenho de previsões (Dangal et al., 2019; Hershberger et al., 2021).

Num estudo de espectroscopia atrelada à cultura da beterraba, observou-se que o CUB fornece uma melhor previsão em valores de intervalo baixo e médio, enquanto PLSR tende a dar uma melhor previsão em valores de intervalos maiores (Yi et al., 2020). Tal afirmativa endossa o observado durante o procedimento de modelagem das amostras de café, em que o modelo CUB melhor se ajusta aos elementos Ca, Mg e Cu, por apresentarem em sua tabela de análise descritiva intervalos menores sob sua quantificação. Em contrapartida, os elementos P, K e Mn melhor se ajustam ao PLSR e apresentam um maior intervalo na observação de dados quantificados.

Axelsson e colaboradores (2013), ao estudarem modelagens, observaram que a PLSR era o método de maior precisão e eficiência ao utilizar todas as bandas na supressão de ruído no mapa de nitrogênio para tecidos vegetais. Tais afirmativas são corroboradas para os elementos Ca, Mg, P, no presente estudo, possivelmente por intermédio das maiores concentrações quantificadas nos materiais vegetais, o que permite maiores inferências sobre a comparação da digestão convencional, gerando validações cruzadas mais relevantes (Hershberger et al., 2021).

A modelagem PLSR é adversamente afetada por *outliers* (Smith et al., 2020), de modo que, ao se efetuar a retirada dos *outliers*, observou-se a melhoria nas variáveis preditoras dentro do modelo. Os incrementos de RPIQ impactam diretamente nos valores de R^2 que, por sua vez, diminuem os valores de RPIQ. Em média, as estimativas das concentrações de Mg, Zn e Fe, e seus respectivos índices, apresentaram menores relações lineares, mudanças na cor do tecido foliar e podem resultar em mudanças na refletância foliar, principalmente na região do visível (Oliveira et al., 2019).

Os espectros do azevém perene são altamente variáveis, podendo essa variação vir das mais diversas diferenças da planta, seja em estrutura como em parâmetros biofísicos que contribuem para a assinatura espectral das mudanças nas condições ambientais, durante a

estação de crescimento, entre outros (Smith et al., 2020). Tormena e colaboradores (2019) reforçam que as folhas de café arábica, associadas à espectroscopia e aos modelos matemáticos, possuem potencial considerável de se tornar um sistema de biomonitoramento, demandando, desse modo, maiores estudos sobre a modelagem em cafeeiro, visando maior robustez e capacidade preditiva dos elementos contidos no tecido vegetal seco.

6 CONCLUSÕES

Pode-se observar a capacidade promissora do uso da espectroscopia de reflectância difusa na quantificação nutricional em plantios da região do Sudoeste da Bahia. O conjunto de dados com os pré-processamentos *Savitsky-Golay* e *Standard Normal Variate* apresentou melhores ajustes em grande parte dos modelos testados, comprovando a necessidade dos pré-processamentos.

As modelagens de aprendizado de máquina PLSR e Cubist são as mais recomendadas para a predição dos elementos nutricionais avaliados, podendo ser sugeridos para a avaliação dos teores nutricionais da cultura cafeeira. Para o elemento K, verificou-se a capacidade preditiva mais alta, entre os outros nutrientes com o modelo Cubist e pré-processamento *Detrend*.

O sensoriamento hiperespectral ainda possui muitos desafios a romper, seja em relação às configurações e leituras do sensor, na delimitação de unidades amostrais expressivas para áreas maiores do estado, como em possíveis adaptações para os diferentes zoneamentos agrícolas, alvos de estudo, fazendo com que essas análises se tornem mais consistentes e robustas.

REFERENCIAL BIBLIOGRÁFICO

Agência de Notícias do Café. AGNOCAFÉ. Bahia faz história em concurso mundial de café. 2018. Disponível em: <http://www.agnocafe.com.br/noticia?id=12604&acesso=0&titulo=Bahia-faz-hist%C3%B3ria-em-concurso-mundial-de-caf%C3%A9>. Acesso em: jul. 2020.

Agência de Notícias do Café. AGNOCAFÉ. Pela quarta vez, Café da Bahia é eleito melhor em concurso nacional. 2020. Disponível em: <http://www.agnocafe.com.br/noticia?id=23216&acesso=0&titulo=Pela-quarta-vez,-caf%C3%A9-da-Bahia-%C3%A9-eleito-o-melhor-em-concurso-nacional>. Acesso em: jul. 2020.

Alvares, C. A.; Stape, J. L.; Sentelhas, P. C.; Gonçalves, J. L. M.; Sparovek, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013. <https://doi.org/10.1127/0941-2948/2013/0507>

Arriel, T. G.; Ramalho, F. M. G.; Lima, R. A. B.; Sousa, K. I. R. de; Hein, P. R. G.; Trugilho, P. F. Developing near infrared spectroscopic models for predicting density of Eucalyptus wood based on indirect measurement. **Cerne**, v. 25, n. 3, p.294-300, 2019. <https://doi.org/10.1590/01047760201925032646>

Árvay, J., Šnirc, M., Hauptvogel, M., Bilčíková, J., Bobková, A., Demková, L., M Hudáček, M.; Hrstková, M.; Lošák, T.; Král, M.; Kováčik, A. Štefániková, J. Concentration of micro-and macro-elements in green and roasted coffee: influence of roasting degree and risk assessment for the consumers. **Biological trace element research**, v. 190, n. 1, p. 226-233, 2019. <https://doi.org/10.1007/s12011-018-1519-3>

Axelsson, C.; Skidmore, A. K.; Schlerf, M.; Fauzi, A.; Verhoef, W. Hyperspectral analysis of mangrove foliar chemistry using PLSR and support vector regression. **International Journal of Remote Sensing**, v. 34, n. 5, p. 1724 - 1743, 2013. <https://doi.org/10.1080/01431161.2012.725958>

Borges, C. S.; Weindorf, D. C.; Carvalho, G. S.; Guilherme, L. R. G.; Takayama, T.; Curi, N.; Lima, G. J. E. O.; Ribeiro, B. T. Foliar elemental analysis of brazilian crops via Portable X-ray Fluorescence Spectrometry. **Sensors**, v.20, p. 2509-2525, 2020. <https://doi.org/10.3390/s20092509>

Breiman, L. Random forests. **Machine Learning**, 45, p. 5-32, 2001. <https://doi.org/10.1023/A:1010933404324>

Café Point. Agrocafé 2015 reúne lideranças da cafeicultura da Bahia do Brasil. 2015. Disponível em: <https://www.cafepoint.com.br/noticias/agenda-do-produtor/agnocafe-2015-reune-liderancas-da-cafeicultura-da-bahia-e-do-brasil-94678n.aspx>. Acesso em: out. 2021. Campo e Negócios. **Anuário do café 2020**. Ed. 11. fev., 2020.

Carmo, C. A. F. de S. do; Araújo, W. S. de; Bernardi, A. C. de C.; Saldanha, M. F. C. S. **Métodos de análise de tecidos vegetais utilizados na Embrapa Solos**. Circular Técnica; v. 6, Rio de Janeiro, Embrapa Solos, 2000.

Carvalho, F. G.; Sera, G. H.; Andreazi, E.; Sera, T.; Fonseca, I. C. de B.; Carducci, F. C.; Shigueoka, L. H.; Holderbaum, M. M.; Costa, K. C. Tolerância ao déficit hídrico em mudas de genótipos de café portadores de genes de diferentes espécies. **Coffee Science**, v. 12, n. 2, p. 156 – 163, 2017.

Cezar, E.; Nanni, M. R.; Demattê, J. A. M.; Chicati, M. L.; Oliveira, R. B. D. Estimativa de atributos do solo por meio de espectrorradiometria difusa. **Revista Brasileira de Ciência do Solo**, v. 37, p. 858-868, 2013.

Companhia Nacional de Abastecimento - CONAB. Acompanhamento da safra brasileira de café. **Primeiro Levantamento**, v.6, n. 1, 2020.

Couto, C. de C.; Freitas-Silva, O.; Oliveira, E. M. M.; Sousa, C.; Casal, S. Near-Infrared Spectroscopy Applied to the Detection of Multiple Adulterants in Roasted and Ground Arabica Coffee. **Foods**, v. 11, n. 61, 2022. <https://doi.org/10.3390/foods11010061>
Cran.r-project.org. 2021. The Comprehensive R Archive Network. Disponível em: <https://cran.r-project.org>. Acesso em janeiro de 2022.

Dangal, S. R.; Sanderman, J.; Wills, S.; Ramirez-Lopez, L. Accurate and precise prediction of soil properties from a large mid-infrared spectral library. **Soil Systems**, v. 3, n. 1, p. 11, 2019. <https://doi.org/10.3390/soilsystems3010011>

Doktor, D.; Lausch, A.; Spengler, D.; Thurner, M. Extraction of plant physiological status from hyperspectral signatures using machine learning methods. **Remote Sensing**, v. 6, n. 12, p. 12247-12274, 2014. <https://doi.org/10.3390/rs61212247>

Dubberstein, D.; Partelli, F. L.; Espíndula, M. C.; Dias, J. R. M. Concentration and accumulation of micronutrients in robust coffee. **Acta Scientiarum Agronomy**, v. 41, 2019. <https://doi.org/10.4025/actasciagron.v41i1.42685>

EMBRAPA. **Café na Amazônia**. Brasília, DF, 474 p., 2015.

EMBRAPA. **Cultivares de café**. Carvalho, C. H. S.de. Brasília: EMBRAPA, 2007.

Ferrão, R. G.; Fonseca, A. F. A. da; Ferrão, M. A. G.; Muner, L. H. de. **Cafe Conilon**. INCAPER, 2017. 784 p.

Ferraresi, T. M.; Silva, W. T. L. da; Martin-Neto, L.; Silveira, P. M. da; Madari, B. E. Espectroscopia de infravermelho na determinação da textura do solo. **Revista Brasileira de Ciência do Solo**, v.36, p.: 1769- 1777, 2012.

Flores-Valdez, M., Meza-Márquez, O. G., Osorio-Revilla, G., & Gallardo-Velázquez, T. Identification and Quantification of Adulterants in Coffee (*Coffea arabica* L.) Using FT-MIR

Spectroscopy Coupled with Chemometrics. **Foods**, v. 9, n. 7, p. 851, 2020.
<https://doi.org/10.3390/foods9070851>

Hernández, C.M.; Faye, A.; Ly, M.O.; Stewart, Z.P.; Vara Prasad, P.V.; Bastos, L.M.; Nieto, L.; Carcedo, A.J.P.; Ciampitti, I.A. Soil and Climate Characterization to Define Environments for Summer Crops in Senegal. **Sustainability**, v. 13, n. 21, p. 11739, 2021.
<https://doi.org/10.3390/su132111739>

Hershberger, J.; Mbanjo, E. G. N.; Peteti, P.; Ikpan, A. S.; Ogunpaimo, K.; Nafiu, K.; Rabbi, I. Y.; Gore, M. A. Low-cost, handheld near-infrared spectroscopy for root dry matter content prediction in cassava. **bioRxiv**, 2021. <https://doi.org/10.1101/2021.04.30.441802>

Instituto Brasileiro De Geografia E Estatística - IBGE. **Censo Agropecuário 2017: Resultados Definitivos**. Rio de Janeiro, v. 8, p.1-105, 2019.

International Coffee Organization - OIC. **Daily Coffee Prices**. 2022. Disponível em: https://www.ico.org/coffee_prices.asp. Acesso em: jan. 2022.

International Coffee Organization- OIC. **Imports of coffee by select importing countries: September 2019 - February 2020**. 2020. Disponível em: <http://www.ico.org/prices/m4-imports.pdf>. Acesso em: jun. 2021.

Jin, X.; Wang, L.; Zheng, W.; Zhang, X. D.; Liu, L.; Li, S.; Rao, Y.; Xuan, J. Predicting the nutrition deficiency of fresh pear leaves with a miniature near-infrared spectrometer in the laboratory. **Measurement**, v. 188, 2022. <https://doi.org/10.1016/j.measurement.2021.110553>

Johnson, J. M.; Sila, A.; Senthilkumar, K.; Shepherd, K. D.; Saito, K. Application of infrared spectroscopy for estimation of concentrations of macro-and micronutrients in rice in sub-Saharan Africa. **Field Crops Research**, v. 270, 2021.
<https://doi.org/10.1016/j.fcr.2021.108222>

Kuhn, M.; Weston, S.; Keefer, C.; Coulter, N.; Quinlan, R. **Cubist**: rule-and instance-based regression modeling. R package version 0.3.0, 2021. Disponível em: <https://cran.r-project.org/web/packages/Cubist/index.html>. Acesso em novembro de 2021.

Kurihara, C. H.; Maeda, S.; Alvarez, V. H. **Interpretação de resultados de análise foliar**. Dourados: Embrapa Agropecuária Oeste; Colombo; Embrapa Florestas, 2005. 42 p.

Lawrence, I.; Lin, K. A concordance correlation coefficient to evaluate reproducibility. **Biometrics**, p. 255-268, 1989. <https://doi.org/2532051>

Luna, A. S.; Gois, J. S. de. Application of chemometric methods coupled with vibrational spectroscopy for the discrimination of plant cultivars and to predict physicochemical properties using R. **Comprehensive Analytical Chemistry**. Elsevier, 2018. p. 165-194.

Malavolta, E.; Favarin, J. L.; Malavolta, M.; Cabral, C. P.; Heinrichs, R.; Silveira, J. S. M. Repartição de nutrientes nos Ramos folhas e flores do cafeeiro. **Pesquisa Agropecuária Brasileira**, v. 37, n. 7, p. 1017-1022, 2002.

Mandelmilch, M.; Livne, I., Ben-Dor, E.; Sheffer, E. Mapping phosphorus concentration in Mediterranean forests using different remote-sensing methods. **International Journal of Remote Sensing**, v. 42, n. 15, p. 5698-5718, 2021.
<https://doi.org/10.1080/01431161.2021.1929543>

Mandić-Rajčević, S.; Colosio, C. Methods for the identification of outliers and their influence on exposure assessment in agricultural pesticide applicators: A proposed approach and validation using biological monitoring. **Toxics**, v. 7, n. 3, p. 37, 2019.
<https://doi.org/10.3390/toxics7030037>

Marin, D. B.; Alves, M. de C.; Pozza, E. A.; Gandia, R. M.; Cortez, M. L. J.; Mattioli, M. C. Sensoriamento remoto multiespectral na identificação e mapeamento das variáveis bióticas e abióticas do cafeeiro. **Revista Ceres**, v. 66, n. 2, p. 142-153, 2019.
<https://doi.org/10.1590/0034-737X201966020009>

Martinez, H. E. P.; Menezes, J. F. S.; Souza, R. B. D.; Alvarez Venegas, V. H.; Guimarães, P. T. G. Faixas críticas de concentrações de nutrientes e avaliação do estado nutricional de cafeeiros em quatro regiões de Minas Gerais. **Pesquisa Agropecuária Brasileira**, v. 38, p. 703-713, 2003. <https://doi.org/10.1590/S0100-204X2003000600006>

Melo, L. C. A.; Silva, C. A. Influência de métodos de digestão e massa de amostra na recuperação de nutrientes em resíduos orgânicos. **Química Nova**, v. 31, n. 3, p. 556-561, 2008.

Mendes, W. S.; Boechat, C.L.; Gualberto, A. V. S.; Barbosa, R. S.; Silva, Y. J. A. B.; Saraiva, P. C.; Sena, A. F. S.; Duarte, L. S. L. Soil spectral library of Piauí State using machine learning for laboratory analysis in Northeastern Brazil. **Revista Brasileira de Ciência do Solo**, v. 45, 2021. <https://doi.org/10.36783/18069657rbcs20200115>

Meneghetti, A. M. **Manual de procedimentos de amostragem e análise química de plantas, solo e fertilizantes**. Curitiba: EDUTFPR, 2018.

Mesquita, C. M. de; Melo, E. M. de; Rezende, J. E. de; Carvalho, J. S.; Fabri Júnior, M. A.; Moraes, C.; Dias, P. T.; Carvalho, R. M. de; Araújo, W. G. de. **Manual do café: implantação de cafezais Coffea arábica L.** Belo Horizonte: EMATER-MG, 2016b.

Mesquita, C. M. de; Rezende, J. E. de; Carvalho, J. S.; Fabri Júnior, M. A.; Moraes, N. C.; Dias, P. T.; Carvalho, R. M. de; Araújo, W. G. de. **Manual do café: manejo de cafezais em produção**. Belo Horizonte: EMATER-MG, 2016a.

Ministério da Agricultura, Pecuária e Abastecimento - MAPA. **Sumário Executivo Café**. 2020.

Paiva, D.; Lampman, G.; Kriz, G.; Vyvyan, J. **Introdução à espectroscopia**. 4. ed. 2010.

Paulus, S.; Mahlein, A. K. Technical workflows for hyperspectral plant image assessment and processing on the greenhouse and laboratory scale. **GigaScience**, v. 9, n. 8, 2020. <https://doi.org/10.1093/gigascience/giaa090>

Pérez, C. D. P.; Pozza, E. A.; Pozza, A. A. A.; Elmer, W. H.; Pereira, A. B.; Guimarães, D. da S. G.; Monteiro, A. C. A.; Rezende, M. L. V. de. Boron, zinc and manganese suppress rust on coffee plants grown in a nutrient solution. **European Journal of Plant Pathology**, v. 156, n. 3, p. 727-738, 2020. <https://doi.org/10.1007/s10658-019-01922-9>.

Poppiel, R. R.; Lacerda, M. P.; Demattê, J. A.; Oliveira Jr, M. P.; Gallo, B. C.; Safanelli, J. L. Pedology and soil class mapping from proximal and remote sensed data. **Geoderma**, v. 348, p. 189-206, 2019.

Sala, O. **Fundamentos da espectroscopia Raman e no infravermelho**. 2. ed. São Paulo. UNESP, 2008.

Salles, R. A. D.; Jordaim, R. B.; Colodetti, T. V.; Rodrigues, W. N.; Amaral, J. F. T. D.; Tomaz, M. A. Nutritional characteristics of conilon coffee genotypes grown in transition altitude with water management in soil. **Ciência e Agrotecnologia**, v. 45, 2021. <https://doi.org/10.1590/1413-7054202145013721>

Secretaria Da Agricultura, Irrigação e Reforma Agrária - SEAGRI. **Diagnóstico e propostas para a cadeia produtiva do café da Bahia**. Disponível em: http://www.seagri.ba.gov.br/sites/default/files/Diagnostico_e_propostas_cafe_da_Bahia.pdf. Acesso em: nov. 2020.

Silva, C. S. **Espectroscopia no Infravermelho para Aplicações Forenses: documentoscopia e identificação de sêmen em tecidos**. 2017. 139p. Tese (Doutorado). Universidade Federal de Pernambuco, Recife, PE, 2017.

Silva, F. B.; Tormena, C. D.; Pauli, E. D.; Almeida, A. G. de; Berg, A. B. C.; Rakocevic, M.; Bruns, R. E.; Scarminio, I. S.; Marcheafave, G. G. Time dependent berry maturation for planting density levels in *Coffea arabica* L. beans: Mixture design-fingerprinting using near-infrared transmittance spectroscopy. **Journal of Food Composition and Analysis**, v. 97, 2021. <https://doi.org/10.1016/j.jfca.2020.103795>

Silva, F. B.; Tormena, C. D.; Pauli, E. D.; Almeida, A. G. de; Berg, A. B. C., Rakocevic, M.; Bruns, R. E.; Scarminio, I. S.; Marcheafave, G. G. Time dependent berry maturation for planting density levels in *Coffea arabica* L. beans: Mixture design-fingerprinting using near-infrared transmittance spectroscopy. **Journal of Food Composition and Analysis**, v. 97, p. 103795, 2021. <https://doi.org/10.1016/j.jfca.2020.103795>

Silva, F. C. da. **Manual de análises químicas de solos, plantas e fertilizantes**. 2. ed. rev. ampl. Brasília, DF: Embrapa Informação Tecnológica, 2009. 627 p.

Skoog, D. A. **Fundamentos de química analítica**. V. 2. Reverté, 2020.

Smith, C.; Karunaratne, S.; Badenhorst, P.; Cogan, N.; Spangenberg, G.; Smith, K. Machine learning algorithms to predict forage nutritive value of in situ perennial ryegrass plants using

hyperspectral canopy reflectance data. **Remote Sensing**, v. 12, n. 6, p. 928, 2020. <https://doi.org/10.3390/rs12060928>

Sousa, M.; Trapp, T.; Junges, D. L.; Lima, A. P.; Brunetto, G.; Kazama, D. C. da S.; Arcângelo, P.; Santos, T. S. dos; Lourenzi, C. R.; Comin, J. J. Discrimination of soils managed with different sources of fertilization and plant species in organic and conventional farming through near-infrared spectroscopy and chemometrics. **Journal of the Science of Food and Agriculture**, v.101, p.: 5938-5947, 2021. <https://doi.org/10.1002/jsfa.11246>

Stevens, A.; Ramirez-Lopez, L. An introduction to the prospectr package. **R Package Vignette, Report No.:** R Package Version 0.1, v. 3, 2014.

Tavares, T. R.; Fiorio, P. R.; Seixas, H. T.; Garcia, A. C.; Barros, P. P. D. S. Effects of storage on vis-NIR-SWIR reflectance spectra of Mombasa grass leaf samples. **Ciência Rural**, v. 50, 2020. <https://doi.org/10.1590/0103-8478cr20190587>

Tormena, C. D.; Marcheafave, G. G.; Pauli, E. D.; Bruns, R. E.; Scarminio, I. S. Potential biomonitoring of atmospheric carbon dioxide in Coffea arabica leaves using near-infrared spectroscopy and partial least squares discriminant analysis. **Environmental Science and Pollution Research**, v. 26, n. 29, p. 30356-30364, 2019. <https://doi.org/10.1007/s11356-019-06163-1>

Universidade de Lisboa. Natureza dualística da radiação electromagnética (Química). e-escola. 2022. Disponível em: <http://e-escola.tecnico.ulisboa.pt/topico.asp?id=437>. Acesso em janeiro de 2022.

USDA, United States Department of Agriculture. Foreign Agricultural Service. Coffee: World Markets and Trade. Decembrer, 2021. Disponível em: <https://apps.fas.usda.gov/psdonline/app/index.html#/app/downloads>. Acesso em janeiro 2022.

Wadoux, A. M. J.-C., Malone, B., Minasny, B., Fajardo, M., & McBratney, A. B. **Soil Spectral Inference With R: Analysing digital soil spectra with the R programming environment**. Progress in Soil Science, Springer. 2021.

Whittier, W. A., Hodge, G. R., Lopez, J., Saravitz, C., & Acosta, J. J. The use of near infrared spectroscopy to predict foliar nutrient levels of hydroponically grown teak seedlings. **Journal of Near Infrared Spectroscopy**, v. 29, n. 5, p. 301-310, 2021. DOI: 10.1177/09670335211025649

Yi, J., Krusenbaum; L., Unger, P.; Hüging, H.; Seidel, S. J.; Schaaf, G.; Gall, J. Deep learning for non-invasive diagnosis of nutrient deficiencies in sugar beet using RGB images. **Sensors**, v. 20, n. 20, p. 5893, 2020. <https://doi.org/10.3390/s20205893>

Zabini, A. V. **Diagnóstico nutricional do cafeeiro por meio da análise de flores, folhas e extrato foliar**. 2010. 88p. Tese (Doutorado em Fitotecnia). Universidade Federal de Viçosa, Viçosa, MG, 2010.