



**DANIEL VEIGA SOARES**

**SENSORIAMENTO REMOTO PARA MAPEAR O  
POTENCIAL DE PRODUTIVIDADE DO CAFEIEIRO**

**LAVRAS - MG  
2021**

**DANIEL VEIGA SOARES**

**SENSORIAMENTO REMOTO PARA MAPEAR O POTENCIAL DE  
PRODUTIVIDADE DO CAFEIEIRO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós- Graduação em Engenharia Agrícola, na área de concentração em Máquinas e Mecanização Agrícola para a obtenção do título de Mestre.

Prof. Dr. Fabio Moreira da Silva  
Orientador

Prof. Dr. Marcelo de Carvalho Alves  
Coorientador

**LAVRAS - MG  
2021**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Soares, Daniel Veiga.

Sensoriamento remoto para mapear o potencial de  
produtividade do cafeeiro/ Daniel Veiga Soares. - 2020.

43 p.

Orientador(a): Fabio Moreira da Silva.

Coorientador(a): Marcelo de Carvalho Alves.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2020.

Bibliografia.

1. ndvi. 2. sentinel-2. 3. café. I. da Silva, Fabio Moreira. II.  
Alves, Marcelo de Carvalho. III. Título.

**DANIEL VEIGA SOARES**

**SENSORIAMENTO REMOTO PARA MAPEAR O POTENCIAL DE  
PRODUTIVIDADE DO CAFEIRO**

**REMOTE SENSING TO MENSURE THE COFFEE PRODUCTIVITY POTENTIAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós- Graduação em Engenharia Agrícola, na área de concentração em Máquinas e Mecanização Agrícola para a obtenção do título de Mestre.

APROVADA em 27 de novembro de 2020.

Dr. Marcelo de Carvalho Alves UFLA

Dr. Gladyston Rodrigues Carvalho EPAMIG

Prof. Dr. Fábio Moreira da Silva

Orientador

**LAVRAS - MG**

**2021**

## **AGRADECIMENTOS**

Agradeço ao meu orientador Fabio Moreira da Silva, meu co-orientador Marcelo de Carvalho Alves e meus colegas de pesquisa Rafael Oliveira Faria e Vinícius Teixeira Andrade pelo apoio na realização da pesquisa.

A minha esposa por me apoiar sempre, meu filho que muito me inspira, a minha família pela formação pessoal e profissional, aos meus amigos pela amizade, aos estagiários do Rehagro que contribuíram no trabalho, a UFLA pela oportunidade, a Fazenda Samambaia pela disponibilidade das lavouras e principalmente a Deus pela força e determinação de estudar sempre.

## RESUMO

A utilização de imagens de satélite na agricultura tem se tornado uma forte ferramenta no manejo e no comércio de produtos agrícolas, tanto para o produtor, quanto para instituições governamentais de fomento. Porém, mesmo com seu potencial de utilização, existem poucas pesquisas na área cafeeira que conseguiram, de forma satisfatória, estimar a produtividade com base em índices de vegetação. É com base nisso, que esse trabalho foi realizado com o objetivo de correlacionar o potencial de produtividade do cafeeiro com o índice de vegetação por diferença normalizada (NDVI) calculados a partir de imagens do satélite Sentinel-2. O trabalho foi realizado em três lavouras de mesma idade, cultivar e espaçamento, localizadas no município de Santo Antônio do Amparo, MG. As lavouras foram recepcadas no de 2015 e as colheitas realizadas nos anos de 2017 e 2018. Foram feitas malhas amostrais a cada 0,5 ha, onde foram derriçadas quatro plantas por ponto. A colheita foi realizada manualmente e o volume colhido foi medido por um recipiente graduado em litros ( $\text{litros. planta}^{-1}$ ). Para cálculo dos índices de vegetação, utilizou-se imagens multiespectrais do Satélite Sentinel-2, obtidas em diferentes meses nos anos de 2016 a 2018. As imagens foram importadas para o *software* R Studio, onde foi feito todo o processo para a obtenção do NDVI e suas correlações com a produtividade. Foram testadas quatro maneiras diferentes de correlacionar NDVI com produtividade em dois anos, sendo duas delas considerando resultados de cada ano, e outras duas considerando resultados de dois anos juntos, ambas considerando os dados ponto a ponto e agrupados por média. Como resultado, pode-se dizer que a melhor época para aquisição das imagens corresponde aos meses de agosto e setembro, e que as metodologias que utilizaram dados médios de cada uma das áreas, tanto para anos separados, quanto para dois anos juntos, foram as que apresentaram os maiores valores de  $R^2$ . Para metodologia de ponto a ponto para cada ano de avaliação, não se mostrou satisfatória, quando avaliada em dois anos apresentou ótimos valores de  $R^2$ . Sendo assim, pode-se concluir que a utilização de imagens Sentinel-2 para obtenção do NDVI demonstrou ser uma forte ferramenta para mapear o potencial de produtividade do cafeeiro.

**Palavras-chave:** NDVI, SENTINEL-2 e CAFÉ.

## ABSTRACT

The use of satellite images is becoming a powerful tool for the management and trade of agriculture products, both for the producer and government funding agencies. Even though the potential of use is high, there are no researches that estimate, with high accuracy, the productivity of coffee crops based on the vegetation index. The objective of this study was to correlate the potential of coffee crops productivity with normalized difference vegetation index (NDVI, calculated from Sentinel-2 satellite images). The trial was carried out in three crops of same age, cultivar and plants spacing located in Minas Gerais at the city of Santo Antônio do Amparo. The trees were cut at nearly 30 cm above the ground in 2015 and they were harvested in 2017 and 2018. The sample was defined at each 0,5 ha, and inside this area four trees were harvested. The harvest was performed manually, and the harvested volume was measured by a liter graduated bowl (liters.plant-1). The vegetation indexes were calculated using Sentinel-2 Satellite multispectral images obtained in different months from 2016 through 2018. The images were imported into software R Studio, where the whole process to calculate the NDVI and its productivity correlation were made. Four different ways to correlate NDVI and productivity in two years were tested, two of them considering the results of each year, and the other two considering the results of the two years together, both of them grouping the results point by point and by average. As a result, it can be said that the best timing for the image acquisition corresponds to the months of August and September, and the methodologies that used average results for each of the areas, as much for years apart, as for two years together, were the ones that presented the highest values of  $R^2$ . The point-to-point methodology for each year of evaluation was not satisfactory, but when evaluated in 2 years it presented excellent  $R^2$  values. Therefore, the use of Sentinel-2 Satellite images to get the NDVI is a powerful tool to estimate the productivity potential of coffee crops.

**Key words:** NDVI, SENTINEL-2 and Coffee.

## SUMÁRIO

<b>1.</b>	<b>INTRODUÇÃO.....</b>	<b>9</b>
<b>2.</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>10</b>
<b>2.1</b>	<b>Sensoriamento remoto aplicado à agricultura.....</b>	<b>10</b>
<b>2.1.1</b>	<b>Comportamento espectral da vegetação.....</b>	<b>11</b>
<b>2.1.2</b>	<b>Índices de vegetação .....</b>	<b>12</b>
<b>2.1.3</b>	<b>Sensor sentinel 2 .....</b>	<b>13</b>
<b>2.2</b>	<b>Aplicação dos índices de vegetação na agricultura .....</b>	<b>15</b>
<b>3.</b>	<b>MATERIAL E MÉTODOS .....</b>	<b>18</b>
<b>3.1</b>	<b>Caracterização da área e produtividade do café .....</b>	<b>18</b>
<b>3.2</b>	<b>Índices de vegetação .....</b>	<b>20</b>
<b>3.3</b>	<b>Análise de regressão e Matriz de correlação de Pearson .....</b>	<b>21</b>
<b>4.</b>	<b>RESULTADOS E DISCUSSÃO .....</b>	<b>23</b>
<b>4.1</b>	<b>Regressão linear anual por média.....</b>	<b>23</b>
<b>4.2</b>	<b>Regressão linear anual ponto a ponto.....</b>	<b>28</b>
<b>4.3</b>	<b>Regressão linear e matriz de correlação em 2 anos por média .....</b>	<b>30</b>
<b>4.4</b>	<b>Regressão linear e Matriz de correlação em 2 anos ponto a ponto .....</b>	<b>32</b>
<b>5.</b>	<b>CONCLUSÕES.....</b>	<b>39</b>
	<b>REFERÊNCIAS.....</b>	<b>40</b>



## 1. INTRODUÇÃO

O Brasil é o maior produtor e exportador de café. Em 2020, ano de bienalidade positiva, estima-se uma produção de 61,628 milhões de sacas beneficiadas, com crescimento de 25% com relação ano de 2019. Desse total, 47,4 milhões de sacas correspondem à espécie arábica (*Coffea arabica L.*) e 14,3 milhões de sacas à espécie Conilon (*Coffea canephora*). Especificamente em Minas Gerais, a produção foi de 33,5 milhões de sacas, cerca de 54,3 % da produção total brasileira (Companhia Nacional de Abastecimento, 2020).

Nos últimos anos, a utilização de imagens de satélites vem se estabelecendo como instrumento muito importante no monitoramento das culturas e na tomada de decisão, para melhores práticas de manejo. Segundo Li et al. (2010), os dados obtidos por sensoriamento remoto espectral fornecem a possibilidade de avaliação não-destrutiva, eficiente, precoce e objetiva das respostas das plantas a diferentes fatores de estresse do meio ambiente. Tais possibilidades podem auxiliar, não somente o manejo e planejamento dos produtores, mas também nas estimativas de produção para ações governamentais de fomento.

O sensoriamento remoto é uma ferramenta que possibilita a obtenção de informações sobre alvos na superfície terrestre (objetos, áreas, fenômenos), através do registro da interação da radiação eletromagnética com a superfície, realizado por sensores, que estão presentes em plataformas orbitais ou satélites, aviões e no campo (PONZONI, 2001). O uso dessa ferramenta permite estudos de comportamento Espectral da Vegetação utilizando características de reflectância da resposta eletromagnética pelas plantas Johnson e Trout (2012). A combinação de dados espectrais de duas ou mais bandas criam os índices espectrais de vegetação. Esses índices de vegetação possibilitam, por exemplo, o acompanhamento e avaliação de rendimento de culturas (PONTES et al., 2005), além do monitoramento das modificações das propriedades ópticas da lavoura através de alterações nos padrões de reflectância dos dosséis e controle de pragas e doenças (YANG et al., 2005).

Segundo Moreira e Shimabukuro (2004), existem mais de cinquenta índices de vegetação (IVs) sendo quase todos obtidos de medidas de reflectância nas faixas

espectrais do vermelho e infravermelho próximo. No entanto, o mais utilizado é o Índice de Vegetação por Diferença Normalizada (NDVI).

Em alguns trabalhos, os índices de vegetação mostraram-se confiáveis para avaliar condições do cafeeiro. Santos et al. (2014), utilizando o sensor MODIS, encontraram coeficiente de determinação de 0,81, entre a umidade no perfil do solo até 100 cm de profundidade e o vigor do cafeeiro. De forma semelhante, Bernardes et al. (2012) evidenciaram as variações provocadas pela bienalidade na produção de café, em lavoura no sul do Estado de Minas Gerais, entre 2002 e 2009, utilizando os índices de vegetação EVI e NDVI, derivados de imagens MODIS. No entanto, é preciso ressaltar que esses estudos não avaliaram o potencial dos índices de vegetação obtidos a partir de imagens Sentinel-2, para prever o potencial de produtividade do cafeeiro, evidenciando a importância de novos estudos para estimar de forma satisfatória a produtividade do cafeeiro por meio de sensoriamento remoto.

Sendo assim, com base no potencial de utilização de imagens de satélites e na carência de estudos, este trabalho tem por objetivo buscar correlacionar o potencial de produtividade do cafeeiro utilizando imagens de satélite Sentinel-2. e de forma específica, avaliar a melhor época de coleta de imagens multiespectrais para obtenção do NDVI.

## **2. REFERENCIAL TEÓRICO**

### **2.1 Sensoriamento remoto aplicado à agricultura**

O Sensoriamento Remoto (SR) consiste na obtenção de informações sobre alvos na superfície terrestre (objetos, áreas, fenômenos), através do registro da interação da radiação eletromagnética com a superfície, realizado por dois tipos de sensores, os ativos e os passivos. Segundo Schowengerdt (2007), os sensores ativos são aqueles que emitem radiação eletromagnética e capta aquela que é refletida pelos objetos, como o radar, sonar e o LIDAR, enquanto que os sensores passivos são aqueles que não possuem fonte de radiação e captam apenas aquela que é refletida e/ou emitida pelos alvos na superfície.

De modo geral, os dados provenientes de sensoriamento remoto apresentam grande potencial de utilização na agricultura ao permitirem o acompanhamento de extensas áreas de forma remota, podendo ser utilizado para estimar área plantada, produção e produtividade

agrícola, vigor vegetativa, além de auxiliar no manejo agrícola (MOREIRA; RUDORFF, 2002).

### **2.1.1 Comportamento espectral da vegetação**

A radiação solar, ao incidir sobre o topo da atmosfera, tem parte espalhada pelas partículas atmosféricas e outra parte atravessa a atmosfera até interagir com os alvos terrestres. Nesta interação com os objetos, parte da energia é absorvida, transmitida e refletida. A porção de energia refletida pelo alvo chegará até o sensor que pode estar posicionado a poucos metros do objeto ou dentro de plataformas aéreas e orbitais.

Cada objeto apresenta propriedades físico-químicas diferentes, portanto, apresenta um comportamento espectral diferente diante da incidência da radiação que nele incide (PONZONI, 2001). No caso da vegetação, o comportamento espectral é baseado na quantidade de energia eletromagnética refletida pelas folhas, sendo essa quantidade de energia influenciada por alguns fatores, tais como: Pigmentos, quantidade de água e estrutura celular do vegetal.

As câmeras a bordo de satélites ou aeronaves são sensíveis a diferentes intervalos de radiação do espectro eletromagnético e a cada diferente intervalo dá-se o nome de banda espectral. Um satélite pode possuir inúmeras bandas sendo cada uma responsável por imagens da mesma área em diferentes regiões do espectro eletromagnético (região azul, verde, vermelho etc.) (INPE).

Com comprimentos de ondas variando da região do visível até o infravermelho termal, uma infinidade de imagens, com diferentes informações podem ser obtidas, cabendo ao especialista à escolha do espectro de interesse. No caso deste trabalho, as assinaturas espectrais pertinentes serão observadas nos espectros de luz visível e infravermelho próximo.

É na faixa do visível onde ocorre a absorção de energia devido à presença dos pigmentos de clorofila “a e b”, sobretudo nas faixas dos comprimentos de onda vermelho e azul, sendo que na faixa do vermelho, haverá maior absorção se houver a presença de antocianina e  $\beta$ -caroteno. Na faixa espectral do infravermelho próximo, o comportamento da radiação eletromagnética quanto à reflexão, transmissão e absorção é dominado pelas

propriedades ópticas da folha, que dependem das estruturas celulares internas. Estas estruturas, localizadas na parte mais interna da folha, chamada de mesófilo, possuem células com vacúolo e paredes hidratadas onde aumentam a reflexão propiciando melhor absorção da radiação pelos pigmentos (MOREIRA, 2007).

### 2.1.2 Índices de vegetação

Devido à ação dos pigmentos fotossintetizantes que absorvem a radiação eletromagnética para a realização da fotossíntese, o dossel vegetal apresenta valores de reflectância relativamente baixos na região do visível. Sendo assim, a combinação de dados de duas ou mais bandas espectrais, ou seja, os índices espectrais de vegetação podem auxiliar na interpretação de imagens no processo de classificação, eliminando ou minimizando as limitações apresentadas pelo sensoriamento remoto na distinção de alvos na superfície terrestre (PONZONI, 2001).

Em termos gerais, Índices de vegetação são medidas radiométricas adimensionais que indicam a abundância relativa e a atividade da vegetação verde. Um índice de vegetação ideal deve elevar ao máximo a sensibilidade aos parâmetros biofísicos das plantas, para que esta sensibilidade seja autêntica para uma grande amplitude de condições de vegetação; deve normalizar efeitos externos e internos em relação ao dossel; deve ser acoplável a algum parâmetro biofísico mensurável, como biomassa e índice de área foliar, para fins de validação e controle de qualidade (JENSEN, 2009).

São exemplos de índices de vegetação: o NDVI (Normalized Difference Vegetation Index) proposto por Rouse et al. (1973) (equação 1) que minimiza os efeitos causados pelo relevo e a interferência do solo na resposta da vegetação, EVI (Enhanced Vegetation Index) (equação 2) proposto por Huete et al. (1997) para otimizar o sinal da vegetação, melhorando a sensibilidade em regiões com maiores densidades de biomassa, além do monitoramento da vegetação através de uma ligação do sinal de fundo do dossel e a redução das influências atmosféricas, GNDVI: que é o cálculo do comportamento da radiação eletromagnética no verde e infravermelho próximo (equação 3) e SAVI: que é o índice de vegetação ajustado ao solo, é o NDVI com uma constante L que varia de acordo com a densidade da vegetação (equação 4) (JUSTICE et al., 1998).

$$\text{NDVI} = \frac{\text{IV} - \text{Vm}}{\text{IV} + \text{Vm}} \quad (1)$$

$$\text{EVI} = \frac{G(\rho_{\text{ivp}} - \rho_{\text{v}})}{(L + \rho_{\text{ivp}} + C1\rho_{\text{v}} + C2\rho_{\text{a}})} \quad (2)$$

$$\text{GNDVI} = \frac{\text{IV} - \text{Vd}}{\text{IV} + \text{Vd}} \quad (3)$$

$$\text{SAVI} = \frac{\text{IV} - \text{Vm}}{\text{IV} + \text{Vm} + L} (1 + L) \quad (4)$$

Índices espectrais derivados dos comprimentos de onda do visível e do infravermelho próximo têm sido muito usados para caracterização de culturas, estimativa de biomassa e monitoramento de previsão de safra (ROJAS, 2007). Um dos índices mais utilizados e com maior número de aplicações, que analisa a condição da vegetação no campo através de sensoriamento remoto é o NDVI, proposto por Rouse et al. (1973). Devido às propriedades da vegetação verde, o NDVI é um indicador direto da atividade fotossintética da planta. Dessa forma, parâmetros como estresse hídrico podem ser monitorados com êxito através da análise dos valores de tal índice (ROJAS, 2007). A importância do NDVI se encontra na possibilidade de monitoramento das mudanças sazonais no desenvolvimento e na atividade da vegetação, além da redução de ruídos, como diferenças de iluminação solar, sombra de nuvens, atenuações atmosféricas e variações topográficas, presentes em múltiplas bandas de imagens multitemporais (HUETE et al., 2002; JENSEN, 2009).

### 2.1.3 Sensor Sentinel 2

O satélite Sentinel-2 (S-2) apresenta um sensor multiespectral de resolução espacial média produzido pela Agência Espacial Europeia (ESA). O Sensor *MultiSpectral Instrument* (MSI) apresenta uma larga faixa observada (290 km), boa resolução temporal (cinco dias, com dois satélites), resolução espacial alta e média (10, 20 e 60 m), 13 bandas espectrais, e o

tamanho da cena disponibilizada é de 100 por 100 km (ESA, 2017). No Quadro 1, é apresentado as características do sistema satélite Sentinel-2.

Quadro 1- Características do sistema satélite Sentinel-2.

Satélite	Sentinel-2
Data Lançamento	2A - 23/06/2015 2B - 07/03/2017
Instrumentos Sensores	MSI
Bandas Espectrais	13 bandas
Resolução Temporal	5 dias
Resolução Radiométrica	12 bits (4096 níveis de cinza).
Resolução Espacial	10 m (Bandas 2 - 4 e 8)
	20 m (Banda 5 - 8A, 11 e 12)
	60 m (Bandas 1, 9 e 10)
Sistema Geodésico de Referência	WGS84
Sistema de projeção	UTM

Fonte: Adaptado de ESA (2017).

As bandas do Sentinel-2 cobrem as regiões espectrais do visível (VIS) e do infravermelho próximo (NIR), com resolução espacial de 10 metros (2, 3, 4 e 8), foram definidas para manter a compatibilidade com os produtos SPOT, enquanto as bandas de 20 metros de resolução espacial foram arquitetadas para observar principalmente as características da vegetação (borda vermelha da vegetação e a banda de absorção da lignina). As bandas de resolução espacial de 60 metros são destinadas a correção atmosférica (ESA, 2017). No Quadro 2 é possível observar as faixas espectrais das bandas disponíveis no satélite Sentinel-2.

Quadro 2- Comprimento de onda das bandas espectrais do satélite Sentinel-2

Banda	Comprimento de onda ( $\mu\text{m}$ )	Banda Espectral
Banda 1	0,43 – 0,45	Aerossol
Banda 2	0,46 – 0,52	Blue
Banda 3	0,54 – 0,58	Green
Banda 4	0,65 – 0,68	Red
Banda 5	0,7 – 0,71	Red-edge-1
Banda 6	0,73 – 0,75	Red-edge-2
Banda 7	0,76 – 0,78	Red-edge-3
Banda 8	0,78 – 0,90	Near Infrared
Banda 8A	0,85 – 0,87	Near Infrared plateau
Banda 9	0,93 – 0,95	Water vapor
Banda 10	1,36 – 1,39	Cirrus
Banda 11	1,56 – 1,65	Shortwave Infrared -1
Banda 12	2,10 – 2,28	Shortwave Infrared -2

Fonte: Adaptado de ESA (2017).

Segundo Bezerra (2019), antes mesmo do lançamento do primeiro satélite Sentinel-2, autores testaram suas características no mapeamento de propriedades químicas e físicas da vegetação. Nestes estudos e em outros trabalhos que simularam dados do Sentinel-2, foi encontrada boa correlação com a reflectância ao se estimar diversos atributos biofísicos e bioquímicos, como a clorofila (FRAMPTON et al., 2013); a radiação fotossinteticamente ativa (DONG et al., 2015); a biomassa acima do solo (SIBANDA; MUTANGA; ROUGET, 2015).

## 2.2 Aplicação dos índices de vegetação na agricultura

Os primeiros trabalhos realizados com imagens do sensor MSS (Multispectral Scanner Subsystem) do Landsat para estimativas de áreas e de identificação do café não obtiveram êxito na discriminação do café com os alvos subjacentes, devido à inadequabilidade do sensor em questão (VELOSO, 1974).

Foi somente após o lançamento do sensor Landsat/TM que as pesquisas envolvendo sensoriamento remoto em áreas de café começaram a obter êxito. Um dos primeiros trabalhos com resultados satisfatórios foi o de Tardin et al. (1992), utilizando em sua

pesquisa imagens do sensor TM do Landsat aplicando a técnica do algoritmo máxima verossimilhança, em uma área de testes em Alfenas, no Sul de Minas Gerais. Apesar dos resultados satisfatórios, autores não apresentaram estudos no aspecto multitemporal das imagens, não definindo épocas mais favoráveis na identificação das lavouras de café e sua discriminação nos demais alvos da imagem de satélite.

Dois anos após, foi publicado outro estudo, de autoria de Epiphanyo et al. (1994), no qual utilizou imagens de Landsat/TM para avaliar as relações entre os parâmetros culturais e a resposta espectral de cafezais, no sul de Minas Gerais, na região entre os municípios de Alfenas e Campo do Meio.

Com o objetivo de avaliar o potencial das imagens da série Landsat (TM e ETM+), Moreira et al. (2004) analisaram a resposta espectral e temporal das lavouras de café em produção e formação na região centro-sul do estado de Minas Gerais. Os autores acrescentam que características como espaçamento, idade, cultivar, face dos relevos e tratamento culturais, podem ter grande influência no comportamento espectral dos alvos. Segundo a classificação visual feita através do processo de vetorização e utilizando as bandas 3, 4 e 5 dos sensores TM e ETM+, verificou-se que a banda 4, correspondente à região do infravermelho próximo do espectro, foi a ideal para distinguir as lavouras de café em formação e em produção dos alvos pastagem e mata. Em contrapartida, a separação das classes de café em formação e pastagem nas bandas 3 e 5 não foi possível, dada à similaridade da resposta espectral. Outra constatação deste estudo foi de que o sistema convencional de plantio de café com 3 metros entre as linhas e 1,5 metros entre as covas, acaba por gerar a resposta espectral muito influenciada pelo solo. Ou seja, lavouras com maiores espaçamentos apresentaram maiores valores de refletância na banda 3 e menores valores na banda 4, por causa da maior influência do solo na resposta espectral.

Vieira et al. (2006) objetivando estabelecer correlação entre as variáveis do plantio de café as respostas espectrais, realizaram um estudo também em Minas Gerais. Os autores levaram em consideração diversas variáveis, tais como: espaçamento, área do plantio, idade, altura das plantas, vigor vegetativo, cultivares, produção média, tipo de solo e declividade. Como conclusão, os autores relataram que a banda, que corresponde, à região do infravermelho próximo com intervalo de 0.76 a 0.90  $\mu\text{m}$ , é a mais recomendada para o estudo da resposta espectral de áreas cobertas por vegetação, e que as correlações foram maiores em áreas de café com relevo inferior a 15% de declividade.



Analisando a correlação entre dados de sensoriamento remoto e produtividade do café, Brunsell et al. (2009) afirmam que umas das maiores dificuldades na aplicação da técnica é devido às interações microclimáticas complexas dentro do ciclo fenológico bianual do café, além do fato deste ser cultivado geralmente em pequenas áreas, o que exigiria melhor resolução espacial dos satélites de sensoriamento remoto. No entanto, em seus estudos, os autores constaram que é válida a utilização de dados MODIS para monitorar e realizar previsão de produtividade, apesar de sua baixa resolução espacial para análise em áreas pequenas de café.

Sendo assim, a escolha da época das imagens para mapeamento de lavouras de café é um ponto muito importante para o sucesso das interpretações das imagens. No período entre setembro a dezembro, o café passa pelas fases fenológicas de florada, chumbinho e expansão dos frutos. De janeiro a março ocorre a granação dos frutos, é nesse período que o café se encontra em máxima atividade fotossintética, portanto com maior vigor vegetativo, desta forma, teoricamente essa seria a melhor época para a aquisição das imagens. Entretanto de novembro a março há plantio de outras culturas agrícolas, que pode acabar dificultando a discriminação das áreas de café (MOREIRA et al., 2007).

Moreira et al. (2004) comentam que é importante a obtenção de imagens correspondentes ao período mais seco, ou seja, entre os meses de junho e outubro, pois nessa época não há presença de culturas anuais e o contraste espectral do café com outros alvos de ocupação do solo é bastante realçado.

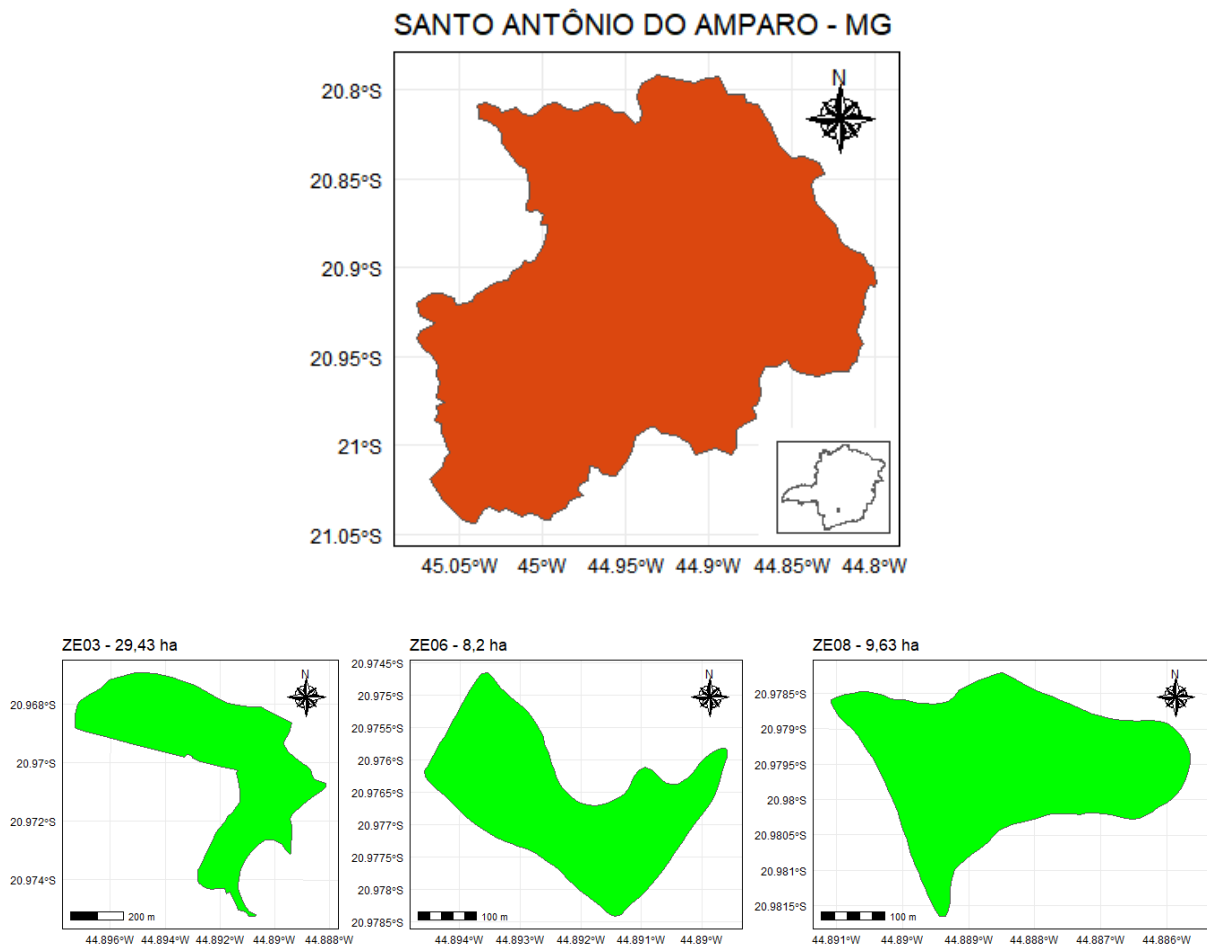
Em resumo, pode-se inferir que além de variáveis, como tipo de solo, relevo, face de plantio, espaçamento, idade da lavoura, cultivar, dentre outros, a determinação do período mais adequado de obtenção das imagens, visando o monitoramento da produtividade do cafeeiro, através do sensoriamento remoto, pode ser de importância para o desenvolvimento dos protocolos e técnicas específicas denominada de "Cafeicultura de Precisão".

### 3. MATERIAL E MÉTODOS

#### 3.1 Caracterização da área e produtividade do café

O estudo foi realizado na Fazenda Samambaia, no município de Santo Antônio do Amparo, sul de Minas Gerais, região do Campo das Vertentes, nas lavouras denominadas ZE03 (29,43 ha), ZE06 (8,2 ha), ZE08 (9,63 ha), totalizando 47,27 ha de lavoura de café (*Coffea arabica L.*) da cultivar Acaiaí IAC 474/19, no espaçamento de 3,60 m entre linhas e 0,80 m entre plantas, totalizando 3472 plantas ha<sup>-1</sup> e altitude média de 1020 metros.

Figura 1 - Mapa de Santo Antônio do Amparo e Mapas das áreas de estudo: ZE03, ZE06 e ZE08.




Fonte: Do autor (2020).

A malha amostral foi composta por 99 pontos, ou seja, foram feitas grades de 0,5 ha, onde foram derriçadas manualmente 4 plantas por ponto, sendo duas plantas localizadas a direita do ponto georreferenciado e as outras duas localizadas à esquerda, conforme ilustrado na Figura 2, totalizando 396 plantas amostradas.

A densidade da malha amostral foi definida com base no trabalho realizado por Figueiredo et al. (2018), que aprimorando a metodologia de Ferraz (2012), desenvolveu indicador de malha ótima padronizado (IMOP) para áreas de até 100 ha. Segundo os mesmos autores, para a maior acurácia de mapas para a Cafeicultura de Precisão, a malha amostral mais recomendada é a de 2 pontos por hectare, ou seja, grades a cada 0,5 ha.

Figura 2 - A amostragem de produtividade de ponto amostral utilizando 4 trabalhadores rurais experientes na colheita do café e um técnico para anotação de campo.



Fonte: Faria (2019)

Todas as três lavouras (ZE03, ZE06 e ZE08) foram recepdadas em 2015 e a 1ª colheita foi realizada em junho de 2017 e a 2ª colheita em junho de 2018. As lavouras receberam adubações de nitrogênio e potássio em iguais quantidades.

A produtividade dos cafeeiros foi obtida por meio da colheita manual sobre panos, das quatro plantas consideradas, utilizando quatro trabalhadores rurais com experiência na colheita do café, acompanhados de um técnico de campo para anotações.











A metodologia seguida por (SANTINATO et al., 2015; SILVA et al., 2010) para a derrça manual foi executada conforme a prática de cada trabalhador com seus devidos equipamentos de proteção individual (EPI) e o pano com posterior abanação manual, utilizando peneiras. Em seguida o volume colhido foi medido por um recipiente graduado em litros ( $L. planta^{-1}$ ) e seco a 11% de umidade. Por fim, foi possível quantificar o peso e a realização da conversão da produtividade por hectare.











### 3.2 Índices de vegetação

Para cálculo dos índices de vegetação, utilizaram-se imagens multiespectrais do Satélite Sentinel-2. Foi calculado índices de diferentes meses, com intuito de comprovar qual a melhor época de aquisição das imagens.

Devido à presença de nuvens, durante o período de estudo, agosto de 2016 a maio de 2018, só foi possível coletar imagens multiespectrais de qualidade em alguns meses do ano, conforme é apresentado na Figura 3.

Figura 3 - Representação dos meses com presença e ausência de nuvens nos anos de 2016, 2017 e 2018.

MÊS / ANOS	2016	2017
AGO		
SET		
OUT		
NOV		
DEZ		

MÊS / ANOS	2017	2018
JAN		
FEV		
MAR		
ABR		
MAI		

Fonte: Do autor (2020).

As imagens referentes aos diferentes meses do ano foram obtidas gratuitamente do United States Geological Survey (USGS), no endereço: <http://earthexplorer.usgs.gov> e importadas para o *software* Qgis para realizar a conversão dos valores da reflectância do topo da superfície (TOA) para valores de reflectância da base da superfície (BOA).

Em seguida os contornos, pontos e imagens foram importadas para o *software* R Studio, onde foram feitas as máscaras das bandas de acordo com o contorno das áreas. Posteriormente, foi realizado o cálculo do NDVI para cada área e extração dos dados para manipulação.

O índice de vegetação (NVDI) foi calculado em cada *pixel* das imagens referentes a cada um dos 99 pontos amostrais e de todos os *pixels* de cada área, baseando-se na combinação dos valores de reflectância nas bandas espectrais das imagens. O NDVI foi calculado pela equação:

$$\text{NDVI} = \frac{\text{IV} - \text{Vm}}{\text{IV} + \text{Vm}}$$

Em que: IV é a banda de reflectância do infravermelho próximo e Vm é a banda de reflectância do vermelho (ROUSE et al., 1973).

### 3.3 Análise de regressão e Matriz de correlação de Pearson

Os dados médios de produtividade do cafeeiro em torno do ponto amostral e os valores dos índices de vegetação foram correlacionados por quatro métodos diferentes em diferentes momentos do ano/safra, sendo eles:

- 1- Os pontos amostrados de cada uma das três áreas (ZE03, ZE06 e ZE08) foram agrupados por área e posteriormente foi feita a média de produtividade dos pontos e do NDVI de todos os *pixels* da área, anualmente, com análise no *software* R Studio.
- 2- Nesse modo, levou-se em consideração o valor de produtividade média de cada ponto amostral e NDVI de cada *pixel* referente a cada um dos 99 pontos amostrais anualmente, com análise no *software* R Studio.

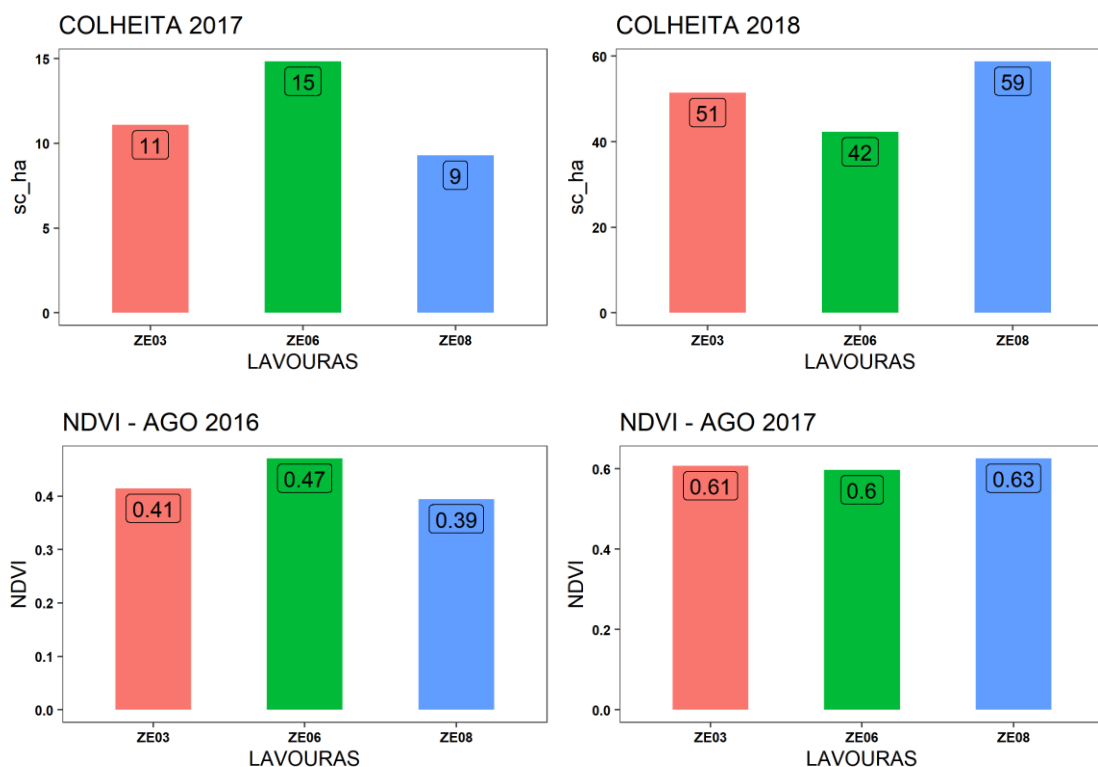
- 3- Diferente do método 1, os pontos amostrados de cada uma das três áreas (ZE03, ZE06 e ZE08) foram agrupados por área e posteriormente foi feita a média dos pontos de produtividade e do NDVI de todos os *pixels* da área para dois anos/safra, com análise no *software* R Studio.
- 4- Diferente do modo 2, levou-se em consideração o valor de produtividade de cada ponto e NDVI de cada pixel referente a cada um dos 99 pontos para dois anos/safra, com análise no *software* R Studio.

## 4. RESULTADOS E DISCUSSÃO

### 4.1 Regressão linear anual por média

Nessa metodologia, o coeficiente de determinação do NDVI com a produtividade de café foi realizado a partir das médias anuais obtidas em cada uma das lavouras (ZE03, ZE06 e ZE08). Os gráficos de média de produtividade apresentaram correspondência com os gráficos de média dos índices de vegetação, para os meses de agosto (2016 e 2017) (GRÁFICO 1). Foi possível observar a correspondência direta, uma vez, que as lavouras que apresentaram as maiores produtividades nos anos de 2017 e 2018, foram também as que obtiveram os maiores índices de NDVI nos anos de 2016 e 2017 (GRÁFICO 1).


Gráfico 1 - Representação gráfica da produtividade e NDVI médio anual de cada área de estudo.



Onde: Sc\_ha – Sacas de café (60 Kg) por hectare, NDVI – Índice de Vegetação por Diferença normalizada. Fonte: Do autor (2020).

O cálculo do potencial de safra por NDVI foi realizado no ano anterior a safra, seguindo procedimento semelhante ao que é feito para previsão de safra em condições de campo, ou seja, no ano anterior a safra. Além disso, visando a confirmação da melhor época de coleta das imagens multiespectrais, e apresentando a seguir a representação gráfica de regressão linear anual da produtividade e NDVI para diferentes meses. Lembrando que a escolha dos meses se deu com base na ausência de nuvens, conforme demonstrado anteriormente na Figura 3.

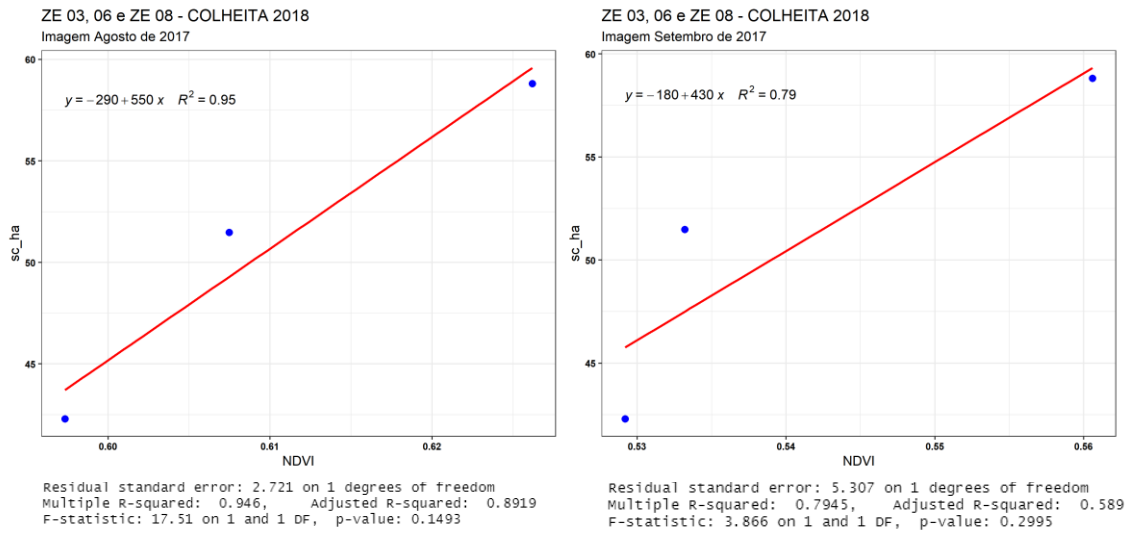
Gráfico 2 - Representação gráfica de regressão linear anual da produtividade e NDVI médio, para as três áreas de estudo no ano de colheita de 2017 e NDVI de agosto e setembro de 2016.



Fonte: Do autor (2020).




Gráfico 3 - Representação gráfica de regressão linear anual da produtividade e NDVI médio, para as três áreas de estudo no ano de colheita de 2018 e NDVI de agosto e setembro de 2017.



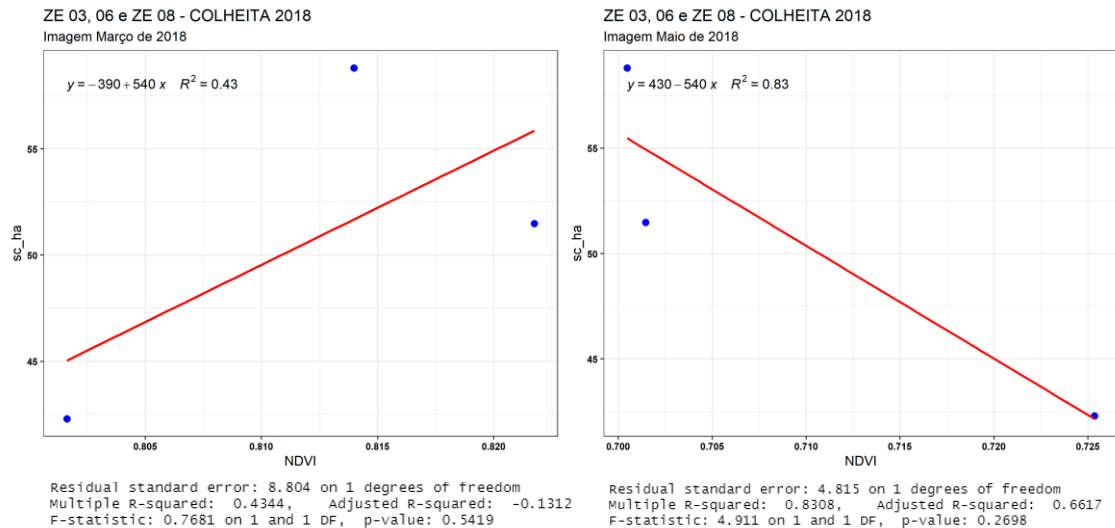
Fonte: Do autor (2020).

Gráfico 4 - Representação gráfica de regressão linear anual da produtividade e NDVI médio, para as três áreas de estudo no ano de colheita de 2018 e NDVI de outubro e novembro de 2017.



Fonte: Do autor (2020).

Gráfico 5 - Representação gráfica de regressão linear anual da produtividade e NDVI médio, para as três áreas de estudo no ano de colheita de 2018 e NDVI de março e maio de 2018.



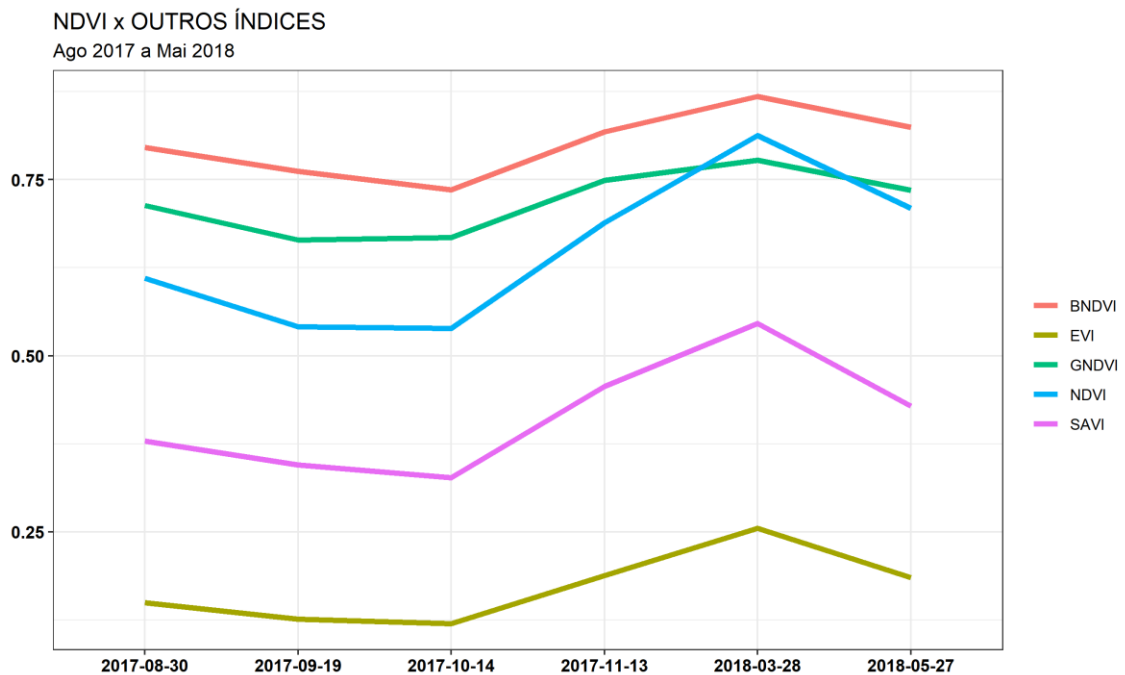
Fonte: Do autor (2020).

Com base nos Gráficos 2, 3, 4 e 5, observa-se que apenas os NDVI's dos meses de agosto e setembro (GRÁFICOS 2 e 3) demonstraram relação direta com a produtividade, apresentando coeficiente de determinação alto, com erro máximo de 0,26 sacas para o mês de agosto e 1,25 sacas para o mês de setembro de 2017, cuja produção máxima foi de 15 sacas por hectare. Para a colheita de 2018, o erro máximo foi de 2,72 sacas para agosto e 5,30 sacas para setembro, com produção máxima de 59 sacas por hectare.

Observa-se ainda, que além de agosto e setembro, o mês de maio também apresentou coeficiente de determinação alto ( $R^2 = 0,83$ ), no entanto, de forma inversa, mostrando que, diferente do que se espera, nem sempre as plantas com maior vigor vegetativo, nesse período, são as mais produtivas. Em geral as plantas mais enfolhadas são as que apresentam mais folhas e menos frutos.

A Gráfico 6 apresentado a seguir, pode ser usado na compreensão da ideia descrita acima, pois ele mostra o comportamento de diversos índices de vegetação no período de agosto de 2017 a maio de 2018.

Gráfico 6 - Comportamento dos índices de vegetação no período agosto de 2017 a maio de 2018.



Fonte: Do autor (2020).

De acordo com o Gráfico 6, nota-se que ocorre um aumento nos valores dos índices de vegetação no período de agosto a maio, período com elevado desenvolvimento vegetativo das plantas. No entanto, diferente do que se esperava para o mês de maio foi relatado coeficiente de determinação alto e inverso (GRÁFICO 5), ou seja, de menor produção, evidenciando que nem sempre as plantas mais enfolhadas em maio, serão as mais produtivas.

Sendo assim, pode-se inferir que os resultados obtidos por essa metodologia confirmam a hipótese inicial de que os melhores meses para coleta das imagens são o de agosto e setembro, que apesar de não ser a época de maior vigor vegetativo das plantas, é o período com menor probabilidade de nuvens e de plantas daninhas nas entrelinhas das lavouras, de fácil interpretação do vigor das plantas no pós colheita.

Tais resultados concordam com o trabalho realizado por Moreira et al (2007), onde os autores utilizaram imagens Landsat/TM 5 na composição 3(B), 4(R), TM5(G) para fazer mapeamento de áreas de café em Minas Gerais, nos meses de julho e agosto. Segundo os autores, a resposta espectral da cultura do café foi favorecida nessa época do ano, pois o solo está exposto ou com cobertura de palhada, gerando bom contraste espectral entre as áreas em

produção de café. De acordo com Machado et al (2010) as imagens do período mais seco do ano são mais eficientes para mapeamento de café em produção.

## 4.2 Regressão linear anual ponto a ponto

A seguir no Gráfico 7, para as três áreas de estudo, é apresentado a regressão linear ponto a ponto da produtividade (ano 2017 e 2018) e NDVI correspondente no mês de agosto (ano 2016 e 2017). Pode-se observar que, diferente do que ocorreu na avaliação por média anual.

Gráfico 7 – Representação gráfica de regressão linear anual da produtividade e NDVI ponto a ponto, para as três áreas de estudo no ano de colheita de 2017 e 2018 e NDVI de agosto de 2016 e 2017. (Continua)

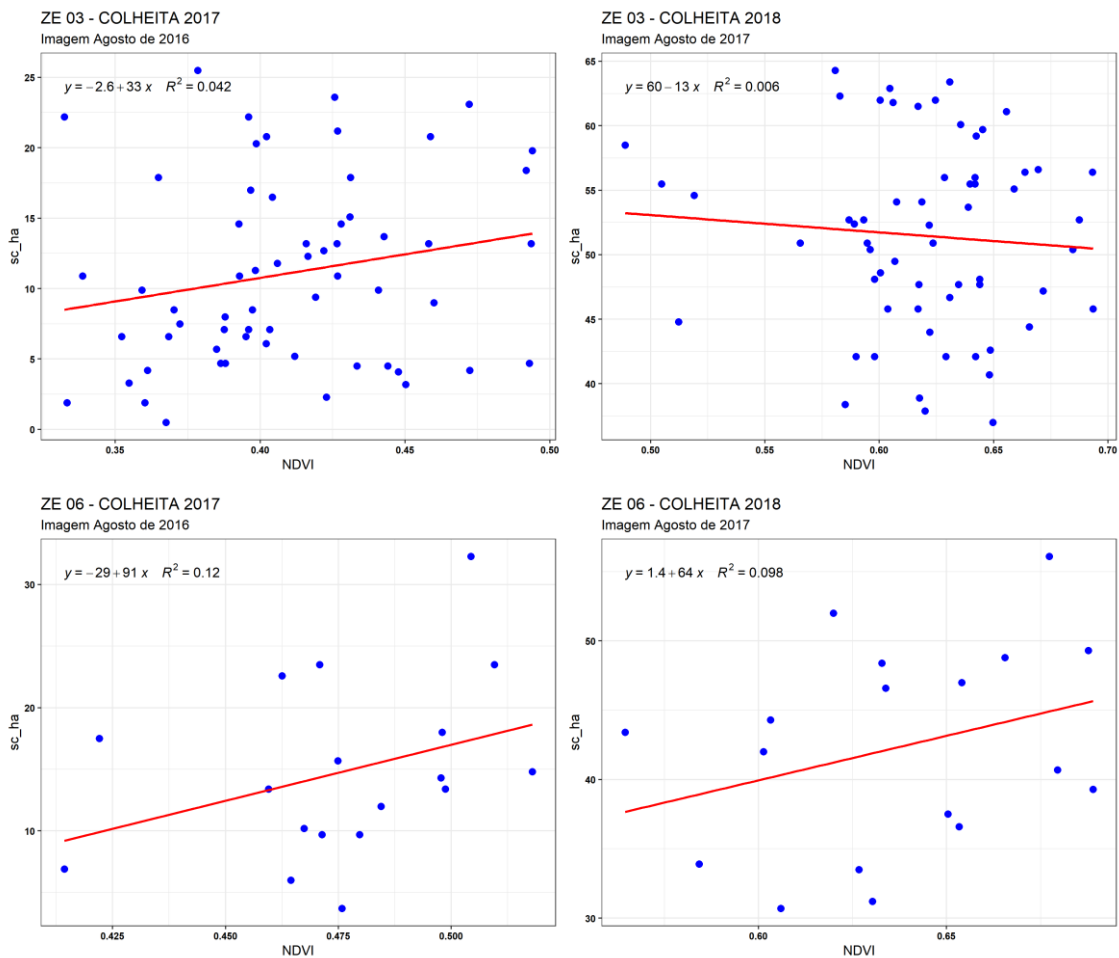
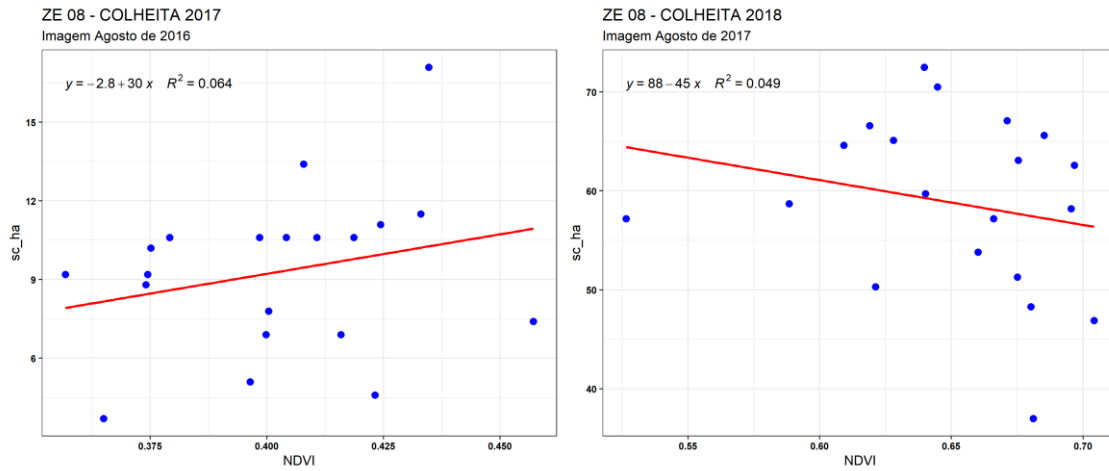


Gráfico 7 – Representação gráfica de regressão linear anual da produtividade e NDVI ponto a ponto, para as três áreas de estudo no ano de colheita de 2017 e 2018 e NDVI de agosto de 2016 e 2017. (Conclusão)



Fonte: Do autor (2020).

Assim como na primeira metodologia, também foi feita a regressão linear para os demais meses do ano que apresentaram ausência de nuvens. Conforme pode ser visto na Figura 4 os demais meses também apresentaram coeficiente de determinação fraco para as áreas de estudo, evidenciando que esse método não é satisfatório para a estimativa do potencial de produtividade do cafeeiro por NDVI.

Figura 4 - Representação dos coeficientes de determinação para os meses com ausência de nuvens, nos anos de 2016, 2017 e 2018, para as áreas ZE03, ZE06 e ZE08. (Continua)



OUTROS MESES – ZE03:




MÊS / ANOS	2016	2017
AGO	R <sup>2</sup> = 0,042	R <sup>2</sup> = 0,006
SET	R <sup>2</sup> = 0,059	R <sup>2</sup> = 0,003
OUT		R <sup>2</sup> = 0,055
NOV		R <sup>2</sup> = 0,000
DEZ		

MÊS / ANOS	2017	2018
JAN		
FEV		
MAR		R <sup>2</sup> = 0,000
ABR		
MAI		R <sup>2</sup> = 0,006





Figura 4 - Representação dos coeficientes de determinação para os meses com ausência de nuvens, nos anos de 2016, 2017 e 2018, para as áreas ZE03, ZE06 e ZE08. (Conclusão)




#### OUTROS MESES – ZE06:

MÊS / ANOS	2016	2017
AGO	$R^2 = 0,120$	$R^2 = 0,098$
SET	$R^2 = 0,000$	$R^2 = 0,210$
OUT		$R^2 = 0,053$
NOV		$R^2 = 0,004$
DEZ		

MÊS / ANOS	2017	2018
JAN		
FEV		
MAR		$R^2 = 0,000$
ABR		
MAI		$R^2 = 0,003$

#### OUTROS MESES – ZE08:

MÊS / ANOS	2016	2017
AGO	$R^2 = 0,064$	$R^2 = 0,049$
SET	$R^2 = 0,033$	$R^2 = 0,018$
OUT		$R^2 = 0,001$
NOV		$R^2 = 0,005$
DEZ		

MÊS / ANOS	2017	2018
JAN		
FEV		
MAR		$R^2 = 0,008$
ABR		
MAI		$R^2 = 0,240$

Fonte: Do autor (2020)


### 4.3 Regressão linear e matriz de correlação em 2 anos por média

Nessa metodologia, a correlação do NDVI com a produtividade das lavouras foi realizada a partir das médias de cada uma das 3 áreas (ZE03, ZE06 e ZE08) considerando os dois anos.

No Gráfico 8 é apresentada a regressão da média de produtividade e NDVI de agosto e setembro, dos dois anos de estudo. Observa-se que, tanto para o mês de agosto, quanto para o mês de setembro, os coeficientes de determinação foram altos ( $R^2 > 0,95$ ), com erro máximo

de 5,4 sacas por hectare para o mês de agosto, e 5,0 sacas por hectare para o mês de setembro, indicando que existe uma correspondência direta entre a produtividade e o NDVI, quando se faz a média de cada lavoura para os dois anos/safra seguidos.

Gráfico 8 – Representação gráfica de regressão linear em 2 anos da produtividade e NDVI médio, para as três áreas de estudo no ano de colheita de 2017 e 2018 e NDVI de 2016 e 2017.




Fonte: Do autor (2020)

Assim como nas demais metodologias apresentadas acima, tentou-se fazer a correlação em dois anos por média das áreas, no entanto, tal procedimento não foi possível devido a presença de nuvens no restante dos meses, em pelo menos um dos anos, 2016 ou 2017, conforme foi apresentado na Figura 3.

Diante do alto coeficiente de determinação para sacas por hectare com NDVI, foi realizada a matriz de correlação de Pearson com o intuito de melhorar a visualização da produtividade (sacas/ha), correlacionada com diversas variáveis (GRÁFICO 9).

Gráfico 9 – Representação gráfica da correlação de Pearson dos dados de 2 anos de produtividade e NDVI, para as médias das três áreas de estudo.



Fonte: Do autor (2020)


De acordo com o Gráfico 9, observa-se que existe uma correlação direta e forte entre o número de sacas por hectare, banda 8 e todos os índices de vegetação. Correlação inversa e forte entre o número de sacas por hectare e as bandas 2, 3 e 4, uma vez que, quanto mais próximo de 1 e -1, mais forte a correlação.

#### 4.4 Regressão linear e Matriz de correlação em 2 anos ponto a ponto

A correlação de produtividade e NDVI ponto a ponto para dois anos seguidos das áreas analisadas em separado (GRÁFICO 10, 11 e 12), e a correlação de produtividade e NDVI ponto a ponto para dois anos seguidos das áreas analisadas agrupadas, se mostraram alta, onde os valores R<sup>2</sup> variaram de 0,77 a 0,74.




Gráfico 10 - Representação gráfica de regressão linear em 2 anos ponto a ponto da produtividade e NDVI dos meses de agosto e setembro, para a área ZE03, no ano de colheita de 2.017 e 2.018 e NDVI de 2.016 e 2.017.



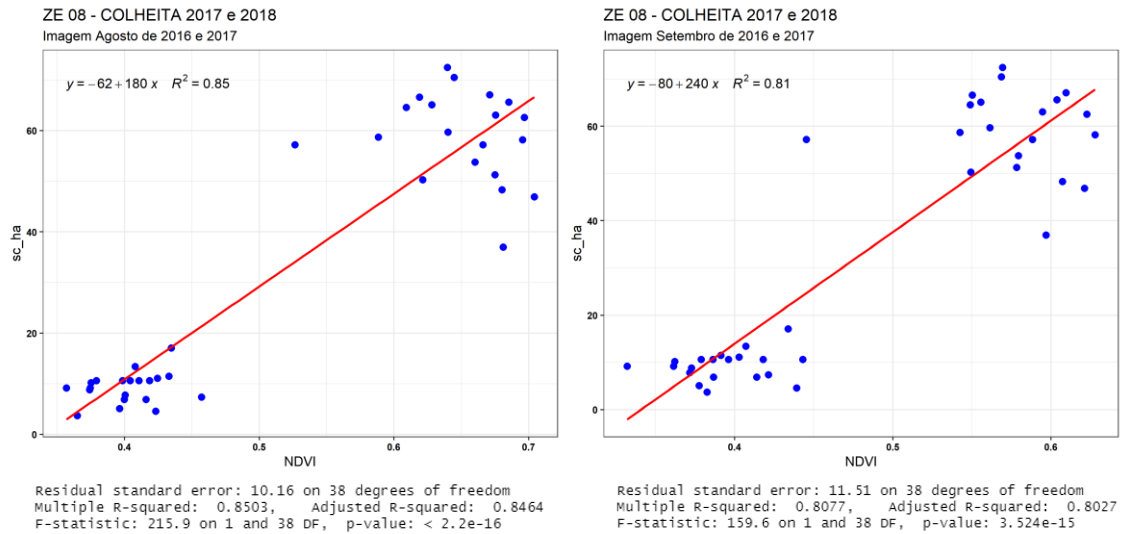
Fonte: Do autor (2020)

Gráfico 11 - Representação gráfica de regressão linear em 2 anos ponto a ponto da produtividade e NDVI dos meses de agosto e setembro, para a área ZE06, no ano de colheita de 2017 e 2018 e NDVI de 2016 e 2017.



Fonte: Do autor (2020)


Gráfico 12 - Representação gráfica de regressão linear em 2 anos ponto a ponto da produtividade e NDVI dos meses de agosto e setembro, para a área ZE08, no ano de colheita de 2017 e 2018 e NDVI de 2016 e 2017.



Fonte: Do autor (2020)

Assim como a avaliação em 2 anos ponto a ponto, a avaliação da correlação de produtividade e NDVI ponto a ponto para dois anos seguidos também se mostrou alta.

Gráfico 13 - Representação gráfica de regressão linear em 2 anos ponto a ponto da produtividade e NDVI dos meses de agosto e setembro, para a área ZE03, ZE06 e ZE08 agrupadas, no ano de colheita de 2017 e 2018 e NDVI de 2016 e 2017



Fonte: Do autor (2020)

Pode-se inferir que quando se considerou dois anos consecutivos, a relação entre NDVI e produtividade tende a ser alta, tanto para o método ponto a ponto, quanto para o método de média das áreas. Tal resultado pode estar relacionado com a bienalidade de produção do caféiro.

Segundo Carvalho et al. (2004), a bienalidade da produção cafeeira é caracterizada pela variação de anos com alta e baixa produção. Silva et al. (2010) constataram correspondência direta da variabilidade espacial de plantas com maior produtividade e maior desfolha no mesmo ano, bem como correspondência inversa em anos distintos, caracterizando a bienalidade da produtividade da cultura ao longo do espaço e do tempo.


Com a desfolha, a planta produzirá menos no ano seguinte, uma vez que utilizará suas reservas para a recomposição da vegetação e, por conseguinte, terá uma menor frutificação. Sendo assim, de acordo com Rena et al. (1996), as plantas muito produtivas ficam debilitadas em função do dreno de nutrientes das folhas para os frutos em anos de alta produtividade, pois o caféiro não regula a carga de frutos, provocando distúrbios fisiológicos na planta, culminando em queda de folhas, redução da fotossíntese e baixa produtividade no ano subsequente.

Portanto, tais informações evidenciam a importância de se considerar a bienalidade do café em estudos envolvendo NDVI e produtividade.

Diante dos elevados coeficientes de determinação de produtividade, através do NDVI, foi realizada a matriz de correlação de Pearson com o intuito de melhorar a visualização dos resultados (sacas/ha), correlacionada com diversas variáveis estudadas. Gráficos 14, 15, 16 e 17.




Gráfico 16 - Representação gráfica da correlação de Pearson dos dados de 2 anos de produtividade e NDVI, avaliados ponto a ponto, para área ZE08.



Fonte: Do autor (2020)

Gráfico 17 - Representação gráfica da correlação de Pearson dos dados de 2 anos de produtividade e NDVI, avaliados ponto a ponto, para as áreas ZE03, ZE06 e ZE08 agrupadas.



Fonte: Do autor (2020)

De acordo com os Gráficos 14, 15, 16 e 17, observa-se que existe uma correlação direta entre o número de sacas por hectare, banda 8 e todos os índices de vegetação.

Correlação inversa e forte entre o número de sacas por hectare e as bandas 2, 3 e 4, uma vez que, quanto mais próximo de 1 e -1 maior a correlação.

De forma geral, pode-se concluir que a estimativa do potencial de produção com base no NDVI, mostrou-se uma ferramenta muito importante para auxiliar o produtor na sua tomada de decisão, uma vez que, 8 meses antes da colheita é possível prever o potencial de produtividade das lavouras, e com base nessas informações, aplicar tratamentos culturais específicos e diferenciados, atendendo ao protocolo da “Cafecultura de Precisão”.

## 5. CONCLUSÕES

Os resultados obtidos permitiram concluir que, o NDVI obtido por meio de imagens Sentinel-2, apresentou boa correlação com a produtividade.

As imagens do Sentinel-2 demonstraram bons resultados para realizar trabalhos com índices de vegetação e produtividade.

Os meses de agosto e setembro mostraram ser as melhores épocas para aquisição das imagens multiespectrais, devido a ser período seco, com maior ausência de nuvens.

O melhor método de tratamento de dados foi quando utilizou dados médios de cada safra para safras separadas, quanto para as duas safras, assim como quando se avaliou conjuntamente os resultados das duas safras, alcançando correlações altas entre a produtividade e o NDVI.

Com o NDVI foi possível prever o potencial de produtividade do cafeeiro, com antecedência de 8 meses e acerto de até 90%, tratando-se de possível e relevante ferramenta no manejo da lavoura cafeeira.

## REFERÊNCIAS

- AHAMED, T. et al. A review of remote sensing methods for biomass feedstock production. **Biomass and Bioenergy**, [S.l.], v. 35, p. 2455-2469, July, 2011.
- BERNARDES, T. et al. Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **Remote Sensing**, Munich, v.04, p. 2492-2509, July, 2012.
- BEZERRA, U. A. **Índices espectrais utilizando os sensores OLI/Landsat-8 e MSI/Sentinel-2, na bacia hidrográfica do rio Moxotó-PE**. 2019. 112p. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação), Universidade Federal de Pernambuco, Recife, 2019.
- BISPO, R. C. **Uso a estabilidade temporal para estimativas de produtividade do café**. 2018. 114p. Tese (Doutorado em Engenharia Agrícola), Universidade Estadual de Campinas, Campinas, 2018.
- BRUNSELL, N.A.; PONTES, P.P.B.; LAMPARELLI, R.A.C. Remotely Sensed Phenology of Coffee and its Relationship to Yield. **GIScience & Remote Sensing**, [London], v. 46, n. 3, p. 289-304, May, 2009.
- CARVALHO, L.G.; SEDIYAMA, G.C.; CECOM, P.R.; ALVES, H.M.R. A regression model to predict coffee productivity in Southern Minas Gerais, Brazil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 8, n. 2/3, p. 204-211, 2004.
- COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). Acompanhamento da safra brasileira: café. v. 6 - Safra 2020, n. 3, terceiro levantamento. Brasília: Conab, 2020. Disponível em: <<http://www.conab.gov.br>> Acesso em: 27 set. 2020.
- DONG, T. et al. Modified vegetation indices for estimating crop fraction of absorbed photosynthetically active radiation. **International Journal of Remote Sensing**, [S.l.], v. 36, n. 12, p. 3097-3113, 2015.
- EUROPEAN SPACE AGENCY (ESA). 2013. "Sentinel-1 User Handbook". Disponível em: <[https://sentinel.esa.int/documents/247904/685163/Sentinel1\\_User\\_Handbook/06fa0b55-9eca-47ff-a45f-242012951564](https://sentinel.esa.int/documents/247904/685163/Sentinel1_User_Handbook/06fa0b55-9eca-47ff-a45f-242012951564)>. Acesso em: 18 nov. 2017.
- EPIPHANIO, J.C.N.; LEONARDI, L.; FORMAGGIO, A.R. Relações entre parâmetros culturais e resposta espectral de cafezais. **Pesquisa Agropecuária Brasileira**, Brasília, v. 29, n. 3, p. 439-447, março, 1994.
- FERRAZ, G. A. S. **Cafeicultura de precisão: Malhas amostrais para o mapeamento de atributos do solo, da planta e recomendações**. 2012. 133p. Tese (Doutorado em Engenharia Agrícola), Universidade Federal de Lavras, Lavras, 2012.
- FIGUEIREDO, V. C. et al. Development of a methodology to determine the best grid sampling in precision coffee growing. **Coffee Science**, Lavras, v. 13, n. 3, p. 312-323, jul./sep. 2018.



FRAMPTON, W. J. et al. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, England, v. 82, p. 83-92, Aug, 2013.

HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, New York, v. 59, n. 3, p. 440-451, March, 1997.

JENSEN, J.R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. 2ª ed. São José dos Campos - SP: Ed. Parênteses, 2009.

JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 36, n. 4, p. 1228-1249, Aug, 1998.

JOHNSON, L. F.; TROUT, T. J. Satellite NDVI assisted monitoring of vegetable crop evapotranspiration in California's San Joaquin Valley. **Remote Sensing**, [S.l.], v. 4, n. 02, p. 439-455, Feb, 2012.

LI, G. et al. Leaf chlorophyll fluorescence, hyperspectral reflectance, pigments content, malondialdehyde and proline accumulation responses of castor bean (*Ricinus communis* L.) seedlings to salt stress levels. **Industrial Crops and Products**, v. 31, n. 01, p. 13-19, jan. 2010.

MACHADO, M. L. et al. Mapeamento de áreas cafeeiras (*Coffea arabica* L.) da zona da mata mineira usando sensoriamento remoto. **Coffee Science**, Lavras, v. 5, n. 2, p. 113-122, maio/ago. 2010.

MOREIRA, M.A.; RUDORFF, B.F.T. **Sensoriamento Remoto Aplicado à Agricultura**. São José dos Campos - SP: Ed. Inpe, 2002.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 3ª ed. Viçosa - MG: Ed. UFV, 2007.

MOREIRA, M. A.; SHIMABUKURO, Y. E. Cálculo do índice de vegetação a partir do sensor AVHRR. In: FERREIRA, N. J. **Aplicações ambientais brasileiras dos satélites NOAA e TIROS-N**. 1ª Ed. São Paulo: Oficina de Textos, 2004. cap. 4, p. 79- 101.

MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Spectral and temporal behavior analysis of coffee crop in Landsat images. **Pesquisa Agropecuária Brasileira**, Brasília, v. 39, n.3, p. 223-23, mar. 2004.

PONTES, P. P. B.; ROCHA, J. V.; LAMPARELLI, R. A. C. Análise temporal de índices de vegetação como subsídio à previsão de safras de cana-de-açúcar. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7, 2005, Goiânia-GO. **Anais...** Goiânia: INPE, 2005.

PONZONI, F.J. Comportamento espectral da vegetação. In: MENESES, P. R.; MADEIRA NETTO, J. S. (Orgs.). **Sensoriamento remoto: reflectância de alvos naturais**. 1º Ed. Brasília - DF: Editora UNB, 2001, p. 157-199.

- FARIA, R. O. de. **Malha amostral para cafeicultura de precisão**. 2019. 118p. Tese (Doutorado em Engenharia Agrícola), Universidade Federal de Lavras, 2019.
- RENA, A.B. et al. Fisiologia do cafeeiro em plantios adensados. In: SIMPÓSIO INTERNACIONAL SOBRE CAFÉ ADENSADO, 1, 1994, Londrina. **Anais...** Londrina: Instituto Agronômico do Paraná, 1996.
- ROJAS, O. Operational maize yield model development and validation based on remote sensing and agro-meteorological data in Kenya. **International Journal of Remote Sensing**, , Italy, v. 28, n. 17-18, p. 3775-3793, sept. 2007.
- ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: EARTH RESOURCES PROGRAM SYMPOSIUM, 3, 1973, Washington. **Proceedings...** Washington: ERTS, 1973.
- SANTOS, W. J. R. et al. Soil moisture in the root zone and its relation to plant vigor assessed by remote sensing at management scale. **Geoderma**, [S. l], v. 221 - 222, p. 91-95, jun. 2014.
- SCHOWENGERDT, R. A. **Remote sensing models and methods for image processing**. 3ª Ed. San Diego: Academic Press, 2007.
- SIBANDA, M.; MUTANGA, O.; ROUGET, M. Examining the potential of Sentinel-2 MSI spectral resolution in quantifying above ground biomass across different fertilizer treatments. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S.l], v. 110, p. 55-65, dez. 2015.
- SILVA, F. M. et al. Efeitos da colheita manual na bienalidade do cafeeiro em Ijaci, Minas Gerais. **Ciencia e Agrotecnologia**, Lavras, v. 34, n. 3, p. 625–632, maio/jun.2010.
- TARDIN, A.T.I.; ASSUNÇÃO, G.V.; SOARES, J.V. Análise preliminar de imagens TM visando a discriminação de café, citrus e cana-de-açúcar na região de Furnas - MG. **Pesquisa Agropecuária Brasileira**, Brasília, v. 27, n. 09, p. 1355-1361, set. 1992.
- VELOSO, M.H. **Coffe inventory through orbital imagery**. Rio de Janeiro: Instituto Brasileiro do Café, 1974.
- VIEIRA, T.G.C. et al. Crop parameters and spectral response of coffee (*Coffea arabica* L.) areas within the state of Minas Gerais, Brazil. **Coffee Science**, Lavras, v. 1, n. 2, p. 111-118, jul./dez. 2006.
- YANG, J.; DING, Y.; CHEN, R. NDVI reflection of alpine vegetation changes in the source regions of the Yangtze and Yellow rivers. **Acta Geographica Sinica**, [S.l], v. 60, n.3, p. 467 - 478, 2005.