

UNIVERSIDADE FEDERAL DE MINAS GERAIS  
INSTITUTO DE GEOCIÊNCIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ANÁLISE E MODELAGEM DE SISTEMAS  
AMBIENTAIS

Paulo Victor Alves de Oliveira

**USO DE ÍNDICES DE VEGETAÇÃO (NDVI, SAVI E IAF) E DE SECA (PDSI) NO  
MONITORAMENTO PLUVIOMÉTRICO DO NORTE DE MINAS GERAIS**

Belo Horizonte

2024

Paulo Victor Alves de Oliveira

**USO DE ÍNDICES DE VEGETAÇÃO (NDVI, SAVI E IAF) E DE SECA (PDSI) NO  
MONITORAMENTO PLUVIOMÉTRICO DO NORTE DE MINAS GERAIS**

Versão Final

Dissertação apresentada ao programa de Pós-graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais como requisito parcial à obtenção do título de Mestre em Análise e Modelagem de Sistemas Ambientais.

Orientador: Marcos Antônio Timbó Elmiro

Belo Horizonte

2024

O48u  
2024

Oliveira, Paulo Victor Alves de.

Uso de índices de vegetação (NDVI, SAVI e IAF) e de seca (PDSI) no monitoramento pluviométrico do norte de Minas Gerais [manuscrito] / Paulo Victor Alves de Oliveira. – 2024.

142 f., enc. il. (principalmente color.)

Orientador: Marcos Antônio Timbó Elmiro.

Dissertação (mestrado) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2024.

Bibliografia: f. 52-58.

Inclui apêndices.

1. Modelagem de dados – Aspectos ambientais – Teses. 2. Mudanças climáticas – Teses. 3. Vegetação e clima – Minas Gerais – Teses. 4. Secas – Teses. 5. Sistemas de informação geográfica – Teses. I. Timbó Elmiro, Marcos Antônio. II. Universidade Federal de Minas Gerais. Instituto de Geociências. III. Título.

CDU: 911.2:519.6(815.1)



UNIVERSIDADE FEDERAL DE MINAS GERAIS  
INSTITUTO DE GEOCIÊNCIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS

### FOLHA DE APROVAÇÃO

#### "USO DE ÍNDICES DE VEGETAÇÃO (NDVI, SAVI E IAF) E DE SECA (PDSI) NO MONITORAMENTO PLUVIOMÉTRICO DO NORTE DE MINAS GERAIS"

**Paulo Victor Alves de Oliveira**

Dissertação de Mestrado defendida e aprovada, no dia **20 de dezembro de 2024**, pela Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais constituída pelos seguintes professores:

**Marcos Antônio Timbó Elmiro - Orientador**

Universidade Federal de Minas Gerais

**Marcelo Antônio Nero**

Universidade Federal de Minas Gerais

**Vagner Braga Nunes Coelho**

Universidade Federal de Minas Gerais

**Warlen Librelon de Oliveira**

Universidade Federal de Minas Gerais

Belo Horizonte, 20 de dezembro de 2024.



Documento assinado eletronicamente por **Vagner Braga Nunes Coelho, Chefe de departamento**, em 20/12/2024, às 09:48, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

Documento assinado eletronicamente por **Warlen Librelon de Oliveira, Usuário Externo**, em



20/12/2024, às 09:57, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcelo Antonio Nero, Professor do Magistério Superior**, em 20/12/2024, às 10:23, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcos Antonio Timbo Elmiro, Professor do Magistério Superior**, em 20/12/2024, às 12:54, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufmg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador 3843337 e o código CRC 0081A54B.

## AGRADECIMENTOS

A jornada até a conclusão desta dissertação foi repleta de desafios, aprendizados e crescimento pessoal e acadêmico. Por isso, gostaria de expressar minha gratidão a todos que, de alguma forma, contribuíram para a realização deste trabalho.

Ao meu orientador, Marcos Antônio Timbó Elmiro, por sua paciência, dedicação e orientação precisa ao longo de todo o processo. Seu conhecimento e incentivo foram fundamentais para o desenvolvimento desta pesquisa.

Aos membros da banca, Dr. Marcelo Nero, Dr. Wagner Coelho e Dr. Warley Librelon, pelas contribuições valiosas e sugestões enriquecedoras que ajudaram a aprimorar este trabalho.

À Universidade Federal de Minas Gerais e ao programa de pós-graduação em Análise e Modelagem de Sistemas Ambientais, pelo suporte acadêmico e institucional.

À minha família, por todo o amor, paciência e incentivo incondicional. Em especial, meus pais, Jaci e Claudio; e minhas irmãs Nayara e Lara, por sempre acreditarem em mim e me apoiarem em cada etapa deste percurso. Aos meus colegas e amigos, que tornaram essa caminhada mais leve, com apoio mútuo, discussões produtivas e inúmeros momentos de descontração que se tornaram indispensáveis nessa longa caminhada.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de mestrado nos últimos 24 meses que permitiu a realização do trabalho. A todos que, de alguma forma, contribuíram para a realização desta dissertação, meu mais sincero “OBRIGADO”.

## RESUMO

A Região Norte de Minas Gerais possui um clima semiárido, sendo afetada pela seca, o que impacta diretamente a produtividade das culturas e os recursos hídricos da região. A elevação das temperaturas e as possíveis mudanças nos padrões de precipitação, decorrentes das mudanças climáticas, podem agravar ainda mais esse cenário; portanto, compreender esses efeitos sobre os recursos naturais e as comunidades locais é fundamental. Com base nessa premissa, a presente pesquisa tem como objetivo avaliar o uso dos índices de vegetação NDVI, SAVI e IAF, em conjunto com o índice de severidade de seca PDSI, no monitoramento pluviométrico da região Norte de Minas Gerais. O trabalho se propôs a analisar uma série temporal de 10 anos por intermédio de ferramentas e recursos de sensoriamento remoto, o que inclui as imagens multiespectrais da região de estudo, obtidas a partir de distintos satélites e sensores. Para tanto, foram calculados os índices de vegetação NDVI, SAVI e IAF, juntamente com o PDSI, com base nos dados da TerraClimate; posteriormente foi realizada uma análise dos índices de vegetação e dos fenômenos climáticos usando o Coeficiente de Correlação de Pearson, GLM – Modelo Linear Generalizado e a Regressão Ridge no monitoramento da seca com base na correlação dos índices calculados. A metodologia proposta se provou válida em obter dados e no processamento, entretanto, não foi conclusiva na análise estatística. A Correlação de Pearson apresentou valores próximos de zero na maioria dos cenários. O maior valor positivo registrado foi 0,24918 na relação PDSI/IAF em fevereiro de 2022, enquanto o menor foi -0,19304 para na relação PDSI/NDVI e PDSI/SAVI em fevereiro de 2018. Já o modelo GLM teve um desempenho baixo, com o Pseudo  $R^2$  de McFadden variando de 0,00157 no pior período (fevereiro de 2020) a 0,99012 no melhor cenário (agosto de 2013). O  $R^2$  da Regressão Ridge semelhantemente ao resultado do GLM apresentou baixo desempenho, com valores variando entre 0,0804 em Ago/2013 no melhor período e -0,0358 em Fev/2019 no pior período. Para melhoria da metodologia em futuros estudos, recomenda-se integrar variáveis adicionais ou adotar modelos que incluam variáveis hidrológicas e climáticas, além de análises temporais mais detalhadas a fim de capturar melhor as interações entre vegetação e seca, ou a estratificação da área de estudo.

Palavras-chave: escassez hídrica; mudanças climáticas; semiárido brasileiro; análise de vegetação; SIG.

## ABSTRACT

The Northern Region of Minas Gerais has a semi-arid climate and is affected by drought, which directly impacts crop productivity and the region's water resources. Rising temperatures and potential changes in precipitation patterns, resulting from climate change, may further aggravate this scenario; therefore, understanding these effects on natural resources and local communities is essential. Based on this premise, this research aims to evaluate the use of NDVI, SAVI, and LAI vegetation indices, together with the PDSI drought severity index, in monitoring rainfall patterns in the northern region of Minas Gerais. The study analyzed a 10-year time series using remote sensing tools and resources, including multispectral images of the study area obtained from different satellites and sensors. To achieve this, the NDVI, SAVI, and LAI vegetation indices were calculated, along with the PDSI, based on TerraClimate data. Subsequently, an analysis of vegetation indices and climate phenomena was performed using Pearson's Correlation Coefficient, Generalized Linear Model (GLM), and Ridge Regression to monitor drought based on the correlation of the calculated indices. The proposed methodology proved valid for data acquisition and processing; however, it was inconclusive in the statistical analysis. Pearson's Correlation Coefficient showed values close to zero in most scenarios. The highest recorded positive value was 0.24918 in the PDSI/LAI relationship in February 2022, while the lowest was -0.19304 in the PDSI/NDVI and PDSI/SAVI relationships in February 2018. The GLM model showed low performance, with McFadden's Pseudo  $R^2$  ranging from 0.00157 in the worst period (February 2020) to 0.99012 in the best scenario (August 2013). Similarly, the  $R^2$  of Ridge Regression showed low performance, with values ranging from 0.0804 in August 2013 (best period) to -0.0358 in February 2019 (worst period). To improve the methodology in future studies, it is recommended to integrate additional variables or adopt models that include hydrological and climatic variables, as well as more detailed temporal analyses to better capture the interactions between vegetation and drought or the stratification of the study area.

**Keywords:** water scarcity; climate change; brazilian semiarid; vegetation analysis; GIS.



## Lista de Ilustrações

|                                                                                         |    |
|-----------------------------------------------------------------------------------------|----|
| Figura 1 – Mapa de localização das 89 cidades que compõem o Norte de Minas Gerais ..... | 26 |
| Figura 2 – Biomas inseridos na Região Norte de Minas Gerais .....                       | 28 |
| Figura 3 – Fluxograma da metodologia do estudo.....                                     | 29 |
| Figura 4 - Índice de Severidade de Seca de Palmer (PDSI)   2013 – 2023.....             | 33 |
| Figura 5 - Índice de Vegetação da Diferença Normalizada (NDVI) - FEV   2014 – 2023..... | 37 |
| Figura 6 - Índice de Vegetação Ajustado ao Solo (SAVI) - FEV   2014 – 2023 .....        | 37 |
| Figura 7 - Índice de Área Foliar (IAF) - FEV   2014 – 2023 .....                        | 38 |
| Figura 8 - Índice de Vegetação da Diferença Normalizada (NDVI) - AGO   2013 – 2023..... | 38 |
| Figura 9 - Índice de Vegetação Ajustado ao Solo (SAVI) - AGO   2013 – 2023 .....        | 39 |
| Figura 10 - Índice de Área Foliar (IAF) - AGO   2013 – 2023.....                        | 39 |
| Figura 11 - QQ-Plots - Períodos de exceção da transformação logarítmica .....           | 45 |

## Lista de Tabelas

|                                                                                                                    |    |
|--------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1 - Classificação do Índice de Severidade de Seca de Palmer (PDSI) .....                                    | 21 |
| Tabela 2 – Classificação do VIF. ....                                                                              | 23 |
| Tabela 3 – Relação dos Municípios do Norte de Minas Gerais .....                                                   | 27 |
| Tabela 4 – Resultados PDSI .....                                                                                   | 34 |
| Tabela 5 – Resultados dos Índices – NDVI, SAVI e IAF .....                                                         | 35 |
| Tabela 6 – Coeficiente de Correlação de Pearson .....                                                              | 41 |
| Tabela 7 – Resultados de Shapiro Wilk e do Pseudo R <sup>2</sup> do GML .....                                      | 42 |
| Tabela 8 – Resultados da Regressão Linear Regularizada Ridge .....                                                 | 46 |
| Tabela 9 – Resultados da Transformação logarítmica na Multicolineariedade das Variáveis através do Teste VIF ..... | 47 |

## **Lista de Abreviaturas e Siglas**

CAST - *China Association for Science and Technology*

DEC - Déficit Extremo de Chuva

GEE – *Google Earth Engine*

GLM - General Linear Model

IAF - Índice de Área Foliar

INPE – Instituto Nacional de Pesquisas Espaciais

IV – Índice de Vegetação

NASA - *National Aeronautics and Space Administration*

NDVI – *Normalized Difference Vegetation Index*

MS Excel – Microsoft Excel

PDSI - Índice de Severidade de Seca de Palmer (PDSI)

SAVI – *Soil-adjusted vegetation Index*

SR - Sensoriamento Remoto

VIT - *Variance Inflation Factor*

## SUMÁRIO

|            |                                                              |           |
|------------|--------------------------------------------------------------|-----------|
| <b>1</b>   | <b>INTRODUÇÃO.....</b>                                       | <b>13</b> |
| <b>2</b>   | <b>OBJETIVOS .....</b>                                       | <b>14</b> |
| <b>2.1</b> | <b>Objetivo Geral.....</b>                                   | <b>14</b> |
| <b>2.2</b> | <b>Objetivos Específicos .....</b>                           | <b>14</b> |
| <b>3</b>   | <b>REVISÃO DE LITERATURA.....</b>                            | <b>15</b> |
| <b>3.1</b> | <b>Sensoriamento Remoto.....</b>                             | <b>15</b> |
| 3.1.1      | Breve Histórico .....                                        | 15        |
| 3.1.2      | Sensoriamento Remoto na Análise de Seca.....                 | 15        |
| <b>3.2</b> | <b>Índices de Vegetação.....</b>                             | <b>16</b> |
| 3.2.1      | Índice de Vegetação da Diferença Normalizada – NDVI .....    | 17        |
| 3.2.2      | Índice de Vegetação Ajustado ao Solo – SAVI.....             | 17        |
| 3.2.3      | Índice de Área Foliar (IAF) .....                            | 18        |
| <b>3.3</b> | <b>Seca e seus efeitos.....</b>                              | <b>19</b> |
| <b>3.4</b> | <b>Índice de Severidade de Seca de Palmer (PDSI).....</b>    | <b>19</b> |
| <b>3.5</b> | <b>Google Earth Engine (GEE) .....</b>                       | <b>21</b> |
| 3.5.1      | TerraClimate .....                                           | 22        |
| <b>3.6</b> | <b>Ferramentas e indicadores para análise de dados .....</b> | <b>22</b> |
| 3.6.1      | Teste de Shapiro-Wilk .....                                  | 22        |
| 3.6.2      | Teste VIF – Variance Inflation Factor .....                  | 23        |
| <b>3.7</b> | <b>GML - Modelo Linear Generalizado .....</b>                | <b>24</b> |
| <b>3.8</b> | <b>Regressão Linear Regularizada - Ridge .....</b>           | <b>24</b> |
| <b>4</b>   | <b>MATERIAIS E MÉTODOS .....</b>                             | <b>26</b> |
| <b>4.1</b> | <b>Área de estudo.....</b>                                   | <b>26</b> |
| <b>4.2</b> | <b>Base de dados .....</b>                                   | <b>28</b> |
| <b>4.3</b> | <b>Processamento de dados.....</b>                           | <b>30</b> |
| <b>4.4</b> | <b>Análise estatística dos dados .....</b>                   | <b>31</b> |
| <b>5</b>   | <b>RESULTADOS E DISCUSSÃO.....</b>                           | <b>33</b> |
| <b>5.1</b> | <b>Índice de Severidade de Seca - PDSI.....</b>              | <b>33</b> |
| <b>5.2</b> | <b>Índice de Vegetação NDVI, SAVI e IAF.....</b>             | <b>35</b> |
| <b>5.3</b> | <b>Coeficiente de Correlação de Pearson .....</b>            | <b>40</b> |
| <b>5.4</b> | <b>GLM – Modelo Linear Generalizado. ....</b>                | <b>42</b> |
| <b>5.5</b> | <b>Regressão Linear Regularizada - Ridge .....</b>           | <b>46</b> |

|          |                                                                       |            |
|----------|-----------------------------------------------------------------------|------------|
| <b>6</b> | <b>CONSIDERAÇÕES FINAIS .....</b>                                     | <b>50</b>  |
|          | <b>REFERÊNCIAS .....</b>                                              | <b>52</b>  |
|          | <b>APÊNDICE A – SCRIPT DO ÍNDICES DE VEGETAÇÃO.....</b>               | <b>59</b>  |
|          | <b>APÊNDICE B – SCRIPT DO ÍNDICE PDSI .....</b>                       | <b>66</b>  |
|          | <b>APÊNDICE C – SCRIPT R DO GLM – MODELO LINEAR GENERALIZADO.....</b> | <b>69</b>  |
|          | <b>APÊNDICE D – RESULTADOS DO GLM – MODELO LINEAR GENERALIZADO</b>    | <b>74</b>  |
|          | <b>APÊNDICE E – SCRIPT DE PROCESSAMENTO DA REGRESSÃO RIDGE .....</b>  | <b>110</b> |
|          | <b>APÊNDICE F – RESULTADOS DA REGRESSÃO RIDGE E RMSE.....</b>         | <b>112</b> |
|          | <b>APÊNDICE G – RESULTADOS Q-Q PLOTS .....</b>                        | <b>135</b> |

## 1 INTRODUÇÃO

A Região do Norte de Minas Gerais, situada na parte mais setentrional do estado, é caracterizada por um clima tropical semiárido, marcado por uma escassez hídrica significativa. A seca, característica mais expressiva dessa região, afeta profundamente as dinâmicas ambientais e socioeconômicas, impactando diretamente a produtividade agrícola e os ecossistemas locais (LIMA; ALVES, 2008). Essa condição é agravada por sua natureza relativamente imprevisível, uma vez que ainda são limitados os recursos que permitam prever com precisão como as secas influenciarão o comportamento das vegetações nativas e exóticas (TEIXEIRA, 2022).

Diante desse cenário, torna-se essencial a investigação das mudanças climáticas no Norte de Minas Gerais, com o objetivo de compreender seus impactos sobre os recursos naturais, a agricultura e as comunidades. De acordo ao IPCC (2014), projeta-se um aumento de 1,5 a 2 °C na temperatura média global até o final do século em cenários intermediários, podendo chegar a 4 ou 5 °C em contextos de maior emissão de gases de efeito estufa.

Embora pareça uma elevação pequena, essas variações de temperatura têm efeitos sistêmicos, especialmente nas áreas semiáridas, onde a redução nas precipitações pode agravar ainda mais o estresse hídrico, afetando diretamente os recursos hídricos e a segurança alimentar regional (IPCC, 2014; FREITAS; CALHEIROS; DOS REIS, 2019).

A relevância deste estudo está na necessidade urgente de entender como a seca afeta o clima e a vegetação do Norte de Minas Gerais, fornecendo subsídios para decisões estratégicas em setores como agricultura, gestão hídrica e planejamento urbano. Com as atuais projeções climáticas, estima-se que as precipitações no semiárido brasileiro possam ser reduzidas em até 40% até o final do século XXI. Esse cenário impõe o risco de transformação de regiões semiáridas, expostas ao calor e à baixa umidade, em áreas áridas, com sérias implicações para a biodiversidade e para a subsistência das comunidades locais (MARENGO, 2008).

A partir de uma abordagem de índices espectrais e pluviométricos, esta pesquisa pretende oferecer uma análise dos eventos climáticos e das mudanças nestes padrões para a região. Ao fazê-lo, espera-se contribuir para o entendimento das especificidades climáticas do Norte de Minas Gerais, fornecendo informações que possam ser utilizadas para mitigar os impactos das mudanças climáticas e planejar estratégias de adaptação sustentável, garantindo a resiliência dos ecossistemas e das populações locais.

## **2 OBJETIVOS**

### **2.1 Objetivo Geral**

Avaliar o uso efetivo dos índices de vegetação NDVI, SAVI e IAF, em conjunto com o PDSI (Índice de Severidade de Seca de Palmer), no monitoramento pluviométrico da região Norte de Minas Gerais, entre os anos de 2013 e 2023.

### **2.2 Objetivos Específicos**

- Verificar se existem anomalias de vegetação atreladas a possíveis mudanças nos padrões hídricos na região Norte de Minas Gerais.
- Avaliar a efetividade da metodologia proposta na análise da seca.
- Avaliar possíveis ganhos proporcionados pelo uso de recursos avançados do GEE – Google Earth Engine baseados no armazenamento e processamento em nuvem em um cenário de comparação com processos tradicionais.

### 3 REVISÃO DE LITERATURA

#### 3.1 Sensoriamento Remoto

##### 3.1.1 Breve Histórico

O sensoriamento remoto (SR) é definido como a técnica que se utiliza de sensores para a captação da energia eletromagnética refletida ou absorvida e posteriormente emitida pela superfície terrestre, sendo esta energia captada a distância (FITZ, 2008). Tais sensores podem estar acoplados a satélites, a plataformas terrestres, ou até mesmo aviões e/ou veículos aéreos não tripulados VANTs (BRAGA, 2014; SOUSA, 2017, RADEMANN *et al.*, 2024).

O uso de satélites com a finalidade de se observar a superfície terrestre teve início com o lançamento do Landsat 1, em 1972 pela NASA (National Aeronautics and Space Administration), e revolucionou por permitir a coleta contínua de dados espaciais do planeta (FEITOSA, 2005). Desde então mais oito lançamentos foram realizados e o programa atualmente está em sua nona missão com o Landsat 9, lançado em setembro de 2021 (USGS, 2024).

O lançamento de um satélite nacional, através da parceria Sino-Brasileira entre o INPE (Instituto Nacional de Pesquisas Espaciais) e a CAST (Chinese Academy of Space Technology), ocorreu em outubro de 1999. O lançamento do CBERS-1 veio como uma forma de cooperação bilateral entre os dois países na busca por dados de SR, o que facilitaria o desenvolvimento e quebraria a dependência dos dois países por imagens orbitais cedidas por outros países (INPE, 2018). Atualmente o programa CBERS está em sua sexta versão com o lançamento do CBERS 4A em dezembro de 2019 (INPE, 2020).

Em fevereiro de 2021, um projeto de autoria inteiramente nacional foi lançado, o Amazonia-1 (AMZ-1), projetado e operado pelo INPE, o satélite representa uma evolução do setor no país, com um ativo tecnológico estratégico fundamental para o planejamento e ordenamento territorial indispensável na gestão dos recursos naturais (DE OLIVEIRA, 2024).

As imagens obtidas por sensoriamento remoto são processadas e distribuídas na forma de matrizes, cujo o valor da menor unidade da imagem, o pixel, indica a resposta espectral que caracteriza o aspecto ou atributos da superfície naquele local específico (LUIZ *et al.*, 2012).

##### 3.1.2 Sensoriamento Remoto na Análise de Seca



Os dados de sensoriamento remoto possuem duas aplicações principais: por um lado, permitem a coleta de informações atmosféricas, como precipitação e umidade relativa; por outro, são usados para analisar a superfície terrestre, especialmente por meio de variáveis críticas no monitoramento de secas, como os índices de vegetação. Além disso, destacam-se pela capacidade de analisar extensas áreas de forma simultânea, o que amplia a eficiência e o alcance de estudos ambientais e climáticos. (DECHANT; MORADKHANI, 2014, 2015; GOUVEIA *et al.*, 2017; DA SILVA *et.al.*, 2020, ULIANA *et al.*, 2024).

O uso do Sensoriamento Remoto já é muito difundido nos estudos da seca, uma vez que as tecnologias permitem análises da superfície terrestre em diferentes escalas espaciais e temporais; o SR age justamente nas limitações intrínsecas de alguns estudos como o acesso aos bancos de dados históricos das medições de campo (SAUSEN; LACRUZ, 2015), ou até mesmo como a influência da seca afeta a escassez de recursos hídricos (MARENGO *et al.*, 2015; COELHO; CARDOSO; FIRPO, 2016, ULIANA *et al.*, 2024).

Mesmo com o avanço tecnológico das ferramentas de SR, um dos grandes desafios continua sendo a criação de algoritmos que consigam estimar variáveis biofísicas da superfície em diferentes localidades; uma vez que, mesmo tendo vários trabalhos em torno de índices de seca, sendo a maioria para fins de produção agropecuária, a aplicação destes em ambientes florestais continua sendo limitada em decorrência da grande variabilidade da vegetação, o que dificulta a utilização de um único índice (RAO *et al.*, 2017; DA SILVA *et.al.*, 2020).

### 3.2 Índices de Vegetação

Os Índices de Vegetação (IVs) são produtos derivados da Reflectância de Superfície e podem ser obtidos a partir de combinações específicas entre duas ou mais bandas de comprimentos de onda distintos do espectro eletromagnético, geralmente utilizando bandas do espectro visível e do infravermelho próximo (DA SILVA *et al.*, 2020). Esses índices destacam características fundamentais da vegetação, como o índice de área foliar (IAF), a radiação fotossinteticamente ativa, índices de biomassa e o percentual de cobertura vegetal, entre outros aspectos (JENSEN, 2009; DA SILVA *et al.*, 2020, FADL *et al.*, 2024).

Devido à sua capacidade de realçar atributos biofísicos específicos, os IVs desempenham um papel central em estudos ecológicos e modelagens ambientais. São amplamente utilizados para a criação e estimativa de parâmetros biofísicos da vegetação e para o monitoramento contínuo da superfície terrestre, contribuindo para análises detalhadas de dinâmica de uso e cobertura do solo, bem como para a avaliação de mudanças ambientais e de práticas de conservação (ROBINSON *et al.*, 2017; DA SILVA *et al.*, 2020).

### 3.2.1 Índice de Vegetação da Diferença Normalizada – NDVI

O *Normalized Difference Vegetation Index* (NDVI) é um dos índices de vegetação mais conhecidos nos estudos de sensoriamento remoto e tem se provado muito eficiente na correlação de variáveis climáticas em diferentes condições ambientais; o NDVI pode ser calculado pela diferença entre a reflectância no espectro do infravermelho e do vermelho, dividida pela soma de ambos (GURGEL, 2000; VANI; MANDLA, 2017; DE LA IGLESIA MARTINEZ; LABIB, 2023, CAI et al., 2025).

A escala de análise do NDVI varia entre -1 e +1, sendo que os valores mais baixos, próximos a -1, indicam superfícies como água ou neve, os valores próximos a 0 indicam áreas sem vegetação significativa, como solos expostos ou áreas urbanizadas e valores entre 0 e +1 indicam a densidade e a saúde da vegetação (VANI; MANDLA, 2017; SHIBANI *et al.* 2023).

O NDVI pode ser definido pela Equação 1.

(1)

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

Onde:

NIR: Reflectância no comprimento de onda do espectro Infravermelho próximo.

RED: Reflectância no comprimento de onda do espectro Vermelho.

### 3.2.2 Índice de Vegetação Ajustado ao Solo – SAVI

O *Soil-adjusted vegetation Index* (SAVI) é um índice que leva em conta o efeito do solo exposto nas imagens avaliadas, ele é muito utilizado como índice complementar ao NDVI, pois permite a análise do uso e ocupação do solo, tornando a observação da área de estudo mais eficiente (HUETE, 1988; DE BORATTO; GOMIDE, 2013; SHIBANI *et al.* 2023).

A escala do SAVI, assim como o NDVI varia de -1 a +1, onde valores próximos a -1 podem indicar presença de água ou ausência de vegetação, os valores próximos a 0 indicam solo exposto ou áreas urbanizadas e valores entre 0 e +1 indicam a vegetação, com maior precisão em áreas de baixa densidade de vegetação (RAHNAMA et al. 2024).

O SAVI pode ser definido pela Equação 2.

(2)

$$SAVI = \frac{(1 + Ls) * (NIR - RED)}{(Ls + NIR + RED)}$$

Onde:

Ls: Constante de ajuste do índice (SAVI), é definida como 0,25 para vegetação densa, 0,50 para vegetação intermediária e 1 para vegetação baixa (HUETE, 1988).

NIR: Reflectância no comprimento de onda do espectro Infravermelho próximo.

RED: Reflectância no comprimento de onda do espectro Vermelho.

Segundo Shibani et al. 2023, o SAVI se torna importante pois, as condições do solo têm uma grande influência na resposta espectral do dossel e nos índices de vegetação. No presente trabalho o valor de 0,50 foi escolhido por conta de uma abrangência maior na descrição de cobertura do solo.

### 3.2.3 Índice de Área Foliar (IAF)

O Índice de Área Foliar (IAF) é um indicador biofísico que representa a área total das folhas (considerando apenas a face superior) por unidade de área do solo; em termos práticos, ele é calculado pela razão entre a área foliar de uma amostra de vegetação e a área do terreno que essa vegetação ocupa, ou seja, cada pixel em imagens de satélite corresponde a um valor de IAF, obtido por meio da Equação 3. Esse índice, adimensional, é essencial para entender a densidade e a estrutura da vegetação (ALLEN *et al.* 2002 ; DE MORAIS DANELICHEN, 2014).

Os valores de IAF para diversas culturas variam bastante ao longo das estações do ano e normalmente atinge seu valor máximo antes ou durante a floração; o IAF também depende da densidade da vegetação (ALLEN *et al.* 1998).

(3)

$$IAF = - \frac{\ln\left(\frac{0,69 - SAVI}{0,59}\right)}{0,91}$$

Neste trabalho estão sendo utilizados os valores empíricos da equação proposta por Allen. 2002, onde o SAVI (Índice de Vegetação Ajustado para os Efeitos do Solo) é o índice utilizado que busca amenizar os efeitos do “background” do solo e é um indicador da biomassa

que pode ser obtido por equações empíricas com bons resultados (DE MORAIS DANELICHEN, 2014).

### 3.3 Seca e seus efeitos

A seca é um fenômeno que atua em uma determinada região e é caracterizada pela ausência total ou parcial de precipitação ou pela má distribuição de chuvas durante o período chuvoso junto à baixa umidade em uma determinada área (FERRARI, 2011).

Segundo Fernandes et al. (2009), a seca pode ser separada em quatro tipos, seca meteorológica, seca hidrológica, seca agrícola e seca socioeconômica:

- Seca Meteorológica: Se caracteriza pela queda de precipitação em comparação aos valores normais da área considerada, em um determinado período de tempo observado; vale salientar que a seca meteorológica pode ocorrer em qualquer região climática do planeta e seus fenômenos variam de acordo com a localidade e região (FERNANDES *et al.* 2009; SAUSEN; LACRUZ, 2015; DUTRA *et al.* 2021).
- Seca Hidrológica: Se caracteriza pela redução dos níveis de água nos cursos d'água, lagoas e lagos, lençóis e reservatórios. Ou seja, ela se refere ao déficit nos níveis de água tanto subterrânea quanto superficial. (FERNANDES *et al.* 2009; SAUSEN; LACRUZ, 2015; DUTRA *et al.* 2021).
- Seca Agrícola: Se caracteriza pela falta de disponibilidade hídrica para o desenvolvimento de culturas, está intrinsicamente ligada as secas meteorológicas e hidrológicas; a soma destas impacta na disponibilidade hídrica do solo, logo, com uma umidade deficiente as culturas podem ter dificuldade para germinar, crescer e se desenvolver de forma correta. Por via de regra normalmente a seca agrícola ocorre após a seca meteorológica, mas antes da seca hidrológica (FERNANDES *et al.* 2009; SAUSEN; LACRUZ, 2015; DUTRA *et al.* 2021).
- Seca Socioeconômica: Se caracteriza pelo impacto das secas nas atividades humanas, geralmente se manifesta de forma direta ou indireta na produção de bens de consumo, ou seja, é a caracterização monetária do resultado, baseada em atividades econômicas (FERNANDES *et al.* 2009; SAUSEN; LACRUZ, 2015; DUTRA *et al.* 2021).

### 3.4 Índice de Severidade de Seca de Palmer (PDSI)

O Índice de Severidade de Seca de Palmer (PDSI) é uma ferramenta fundamental para a quantificação e monitoramento da severidade das secas. Desenvolvido por Wayne Palmer em 1965, o PDSI utiliza dados de precipitação e evapotranspiração para avaliar a disponibilidade hídrica em uma região ao longo do tempo. Este tópico aborda a metodologia do PDSI, suas limitações, adaptações recentes e sua comparação com outros índices de seca (GUTTMAN, 1998; BLAIN, 2007; FERNANDES, 2009).

Segundo Lemenkova (2021), o PDSI é vastamente utilizado na climatologia para quantificar a intensidade e a duração de secas, sendo aplicado na análise global de secas de longo prazo, monitoramento ecológico, avaliação de mudanças climáticas e ambientais, além de delimitar secas severas ou extremas.

A metodologia para calcular o PDSI envolve várias etapas, incluindo a determinação da precipitação necessária e a análise do balanço hídrico (ALLEY, 1984).

O PDSI pode ser calculado através das Equações 4 e 5 descritas abaixo

(4)

$$PDSI_i = 0.897 \times PDSI_{i-1} + \frac{(Z_i)}{3}$$

Onde:

$PDSI_i$ : é o valor do índice para o mês atual,

$PDSI_{i-1}$ : é o valor do índice do mês anterior,

$Z_i$ : é um índice de anomalia de umidade, calculado pela fórmula.

(5)

$$Z_i = (P - P_i) - K_i$$

Onde:

$P$  : é a precipitação observada,

$P_i$ : é a precipitação climatologicamente apropriada,

$K_i$ : é uma constante de padronização que considera as condições climáticas específicas.

O índice Z reflete a diferença entre a precipitação observada e a necessária, ajustada por fatores climáticos. O cálculo da precipitação climatologicamente apropriada ( $P_i$ ) envolve dados históricos de evapotranspiração e outros fatores hídricos, como recarga do solo e runoff.

O PDSI é um modelo simples e padronizado para calcular secas com base em precipitação e temperatura, conforme indicado na Tabela 1, variando de -10 (seca extrema) a +10 (umidade extrema), com 0 indicando condições neutras (DAI; TRENBERTH; QIAN, 2004). Esta padronização permite análises espaciais da variabilidade de secas em muitas áreas

de estudo, sendo amplamente utilizado em estudos climáticos e ambientais (TESFAMARIAM; GESSESSE; MELGANI, 2019).

Tabela 1. Classificação do Índice de Severidade de Seca de Palmer (PDSI).

| PDSI          | Classificação      |
|---------------|--------------------|
| $\geq 4,00$   | Extremamente Úmido |
| 3,00 a 3,99   | Umidade Alta       |
| 2,00 a 2,99   | Umidade Moderada   |
| 1,00 a 1,99   | Umidade Leve       |
| 0,99 a -0,99  | Próximo ao normal  |
| -1,00 a -1,99 | Seca Leve          |
| -2,00 a -2,99 | Seca Moderada      |
| -3,00 a -3,99 | Seca Severa        |
| $\leq -4,00$  | Extremamente Seco  |

Fonte: Fernandes (2009)

### 3.5 Google Earth Engine (GEE)

O Google Earth Engine (GEE) é uma plataforma online de análise geoespacial que utiliza a infraestrutura de computação em nuvem do Google para processar dados complexos. Oferece duas ferramentas principais: o Code Editor, onde é possível criar scripts em JavaScript para análises avançadas, e o Explorer, uma interface simplificada para explorar dados e realizar tarefas básicas sem necessidade de programação. Ideal para pesquisas e monitoramento ambiental, o GEE combina eficiência técnica e acessibilidade; além disso, a ferramenta Client Libraries funciona como uma biblioteca que fornece funções em Python e JavaScript e permitem desenvolver aplicativos personalizados e executar códigos localmente (GOOGLE EARTH ENGINE, 2024).

A utilização do GEE se torna necessária para processar dados geoespaciais em escalas até então nunca antes vistas, cobrindo grandes extensões territoriais e longos períodos temporais ao mesmo tempo em que reduz significativamente o tempo de processamento, pois ele é realizado nos servidores do GEE. Os recursos avançados do GEE melhoram não apenas a eficiência e a precisão no tratamento dos dados, mas também facilitam a modelagem dinâmica e a visualização, tornando a ferramenta poderosa para abordar desafios geográficos e ambientais complexos (RAVANELLI *et al.*, 2018; ZHANG *et al.*, 2022).

### 3.5.1 TerraClimate

O repositório de dados TerraClimate pode ser acessado através do GEE, e é composto por um banco de dados mensal em grade que combina informações climáticas e de balanço hídrico para superfícies terrestres globais. Esses dados climáticos são provenientes da integração de duas fontes principais: os dados do CRU (Climate Research Unit TS 4.0) e do JRA-55 (Japanese 55-year Reanalysis). Para garantir a precisão, este conjunto foi validado utilizando dados de estações da Global Historical Climatology Network (GHCN), resultando em dados espaciais de alta resolução, com 4 km de detalhamento (ABATZOGLOU *et al.*, 2018; BERLIANA *et al.*, 2021).

Apesar de robusto, o método utilizado pela TerraClimate apresenta algumas limitações, como o fato de que o modelo de balanço hídrico é simplificado e utiliza uma cobertura de vegetação estática, não refletindo a heterogeneidade dos tipos de vegetação variadas; além disso, o modelo da TerraClimate não captura a variabilidade temporal em escalas mais finas do que aquelas dos conjuntos de dados parentais, o que limita sua capacidade de representar variações em padrões de precipitação orográfica e inversões térmicas (CLIMATOLOGY LAB, 2024).

## 3.6 Ferramentas e indicadores para análise de dados

### 3.6.1 Teste de Shapiro-Wilk

O teste de Shapiro-Wilk é uma das abordagens mais difundidas para verificar se um conjunto de dados segue uma distribuição normal, foi desenvolvido em 1965 por Shapiro e Wilk, e é amplamente reconhecido pela sua sensibilidade e eficácia em detectar desvios da normalidade, mesmo em experimentos com tamanhos de amostra relativamente pequenos. Ele calcula um coeficiente com base na correlação entre os valores dos dados observados e os esperados para uma distribuição normal e um valor de  $p$  (0,05) associado ao teste, o  $p$ -value indica se a hipótese nula de normalidade pode ser aceita ou rejeitada (RAZALI *et al.*, 2011; HANUSZ; TARASINSKA; ZIELINSKI, 2016).

Apesar de sua eficiência, o teste de Shapiro-Wilk pode apresentar em conjuntos de dados maiores, detecção de desvios mínimos da normalidade, mesmo quando esses desvios são irrelevantes para a análise. Além disso, em amostras muito pequenas, a sensibilidade do teste

pode ser insuficiente para identificar variações significativas. Outro ponto negativo do teste, é que ele não fornece informações detalhadas sobre a natureza do desvio da normalidade dos dados, sendo necessário complementar a análise com gráficos, como histogramas ou QQ-plots, para uma interpretação mais abrangente, uma vez que esta variação pode ser proveniente da origem dos dados (RAZALI *et al.*, 2011; GHASEMI; ZAHEDIASL, 2012; DE SOUZA *et al.*, 2023). O Teste de Shapiro-Wilk está sendo utilizado nesta metodologia para verificar se os dados das amostras apresentam distribuição normal, caso contrário, deve-se utilizar algum tipo de transformação matemática na matriz dos dados, como a transformação logarítmica para normalizar o conjunto numérico.

### 3.6.2 Teste VIF – Variance Inflation Factor

O VIF (*Variance Inflation Factor*) é uma técnica utilizada para diagnosticar multicolinearidade em modelos de regressão. A multicolinearidade ocorre quando duas ou mais variáveis independentes estão altamente correlacionadas, o que pode dificultar a interpretação dos coeficientes estimados pelo modelo. O VIF mede o grau de inflação da variância de um coeficiente devido à correlação com outras variáveis preditoras, sendo calculado individualmente para cada variável do modelo. (DAOUD, 2017; JANIZADEH *et al.*, 2023). O VIF pode ser calculado pela Equação 6.

(6)

$$VIF = \frac{1}{1 - R_i^2}$$

Uma das principais características do VIF é sua simplicidade de interpretação. Valores de VIF geralmente variam a partir de 1, com o valor mínimo indicando ausência de multicolinearidade. Por via de regra valores acima de 5 ou 10 são indicativos que os coeficientes associados a regressão não são bem estimados devido a multicolinearidade. Nestas situações as alternativas indicadas são a remoção da variável causadora da multicolinearidade, além da utilização de modelos de Regressão Ridge que minimizam este efeito (PAUL, 2006; SINAN; GENÇ, 2012). Para interpretar os resultados de VIF, utiliza-se a regra da Tabela 2.

Tabela 2 – Classificação do VIF

| VIF-value | Conclusão |
|-----------|-----------|
|-----------|-----------|



|                         |                              |
|-------------------------|------------------------------|
| VIF = 1                 | Não correlacionado           |
| $1 < \text{VIF} \leq 5$ | Moderadamente correlacionado |
| VIF > 5                 | Altamente correlacionado     |

Fonte: Daoud, 2017

O Teste VIF está sendo usado na metodologia do presente trabalho para constatar se há multicolinearidade entre as variáveis dos modelos para assim, neste caso, utilizar o modelo de regressão mais adequado, a Regressão Ridge.

### 3.7 GML - Modelo Linear Generalizado

Os *General Linear Models* (GLM) são extensões dos modelos lineares tradicionais, são projetados para situações onde os dados não atendem aos pressupostos dos modelos lineares clássicos. Eles utilizam uma função de ligação para relacionar a média da variável resposta aos preditores lineares e emprega distribuições da família exponencial, como normal, binomial e Poisson, para modelar a variável dependente. A flexibilidade destes modelos permite sua aplicação em diversos tipos de dados e contextos, ampliando as possibilidades de análise em relação aos modelos lineares clássicos (TADANO; UGAYA; FRANCO, 2009; JANIZADEH *et al.*, 2023). O  $R^2$  de McFadden é um dos índices pseudo  $R^2$  mais simples para avaliar a qualidade do ajuste de um modelo de regressão, especialmente em regressões logísticas e outros modelos não lineares. Ele compara a verossimilhança do modelo ajustado com a do modelo nulo, fornecendo uma medida relativa da qualidade do ajuste (SMITH; MCKENNA, 2013). O GML está sendo usado na metodologia deste trabalho como alternativa ao modelo clássico de regressão, visto que variáveis não atenderam aos pressupostos de normalidade e multicolinearidade.

### 3.8 Regressão Linear Regularizada - Ridge

A Ridge Regression é um modelo de regressão proposto por Hoel e Kennard (1970) que utiliza uma penalização baseada na soma dos quadrados dos coeficientes. A utilização do Ridge se torna útil quando todas as variáveis preditoras contribuem para o modelo e há necessidade de reduzir os efeitos da multicolinearidade, generalizando o modelo e lidando com dados de alta dimensionalidade. A regressão Ridge, oferece uma forma de lidar com o problema de

colinearidade sem remover variáveis do conjunto original de variáveis independentes. (MCDONALD, 2009; SINAN; GENÇ, 2012).

A avaliação do ajuste em modelos regularizados como Lasso e Ridge geralmente envolve métricas como erro médio quadrático (RMSE) e  $R^2$  ajustado, que indicam a qualidade do modelo em prever novos dados. Além disso, a validação cruzada é amplamente utilizada para determinar o valor ideal do parâmetro de regularização (Lambda  $\lambda$ ), balanceando o ajuste do modelo e sua capacidade preditiva. Essas ferramentas ajudam a garantir que o modelo atenda aos objetivos do estudo com alta eficiência e precisão (PAUL, 2006; EL-DERENY; RASHWAN, 2011; SINAN; GENÇ, 2012).

A Regressão Rigde está sendo utilizada nesta metodologia como alternativa do modelo clássico de regressão e do GML, visto que variáveis não atenderam aos pressupostos de normalidade e multicolinearidade destes dois modelos.


## 4 MATERIAIS E MÉTODOS

### 4.1 Área de estudo

A Região Norte do Estado de Minas Gerais é uma das doze mesorregiões estaduais, como o nome já indica é a região mais setentrional do estado, composta por 89 municípios que podem ser visualizados na Figura 1 e conferidos na Tabela 3, dispostos em uma área de 127.816,15km<sup>2</sup>, com uma população aproximada de 1.610.413 habitantes em 2010 (AMMESF, 2023; IBGE, 2018).

A região possui um clima predominantemente semiárido e sub úmido, com precipitações pluviométricas variando entre 700 e 1.500 mm/ano; conta com particularidades geológicas, hidrogeológicas, hidroclimatológicas e de ocupação da terra singulares, que somadas as áreas com déficits hídricos históricos, geram um mosaico complexo que deve ser qualificado e quantificado para uma gestão dos recursos hídricos mais eficiente (BEATO; CÂNDIDO; PAIXÃO, 2012).

Figura 1 – Mapa de localização das 89 cidades que compõem o Norte de Minas Gerais.



Fonte: Do Autor. 2023

Tabela 3 – Relação dos Municípios do Norte de Minas Gerais.


| ID | Município          | ID | Município        | ID | Município                  |
|----|--------------------|----|------------------|----|----------------------------|
| 1  | Águas Vermelhas    | 31 | Itacambira       | 61 | Patis                      |
| 2  | Berizal            | 32 | Itacarambi       | 62 | Pedras de Maria da Cruz    |
| 3  | Bocaiúva           | 33 | Jaíba            | 63 | Pintópolis                 |
| 4  | Bonito de Minas    | 34 | Janaúba          | 64 | Pirapora                   |
| 5  | Botumirim          | 35 | Januária         | 65 | Ponto Chique               |
| 6  | Brasília de Minas  | 36 | Japonvar         | 66 | Porteirinha                |
| 7  | Buritzeiro         | 37 | Jequitaiá        | 67 | Riachinho                  |
| 8  | Campo Azul         | 38 | Josenópolis      | 68 | Riacho dos Machados        |
| 9  | Capitão Enéas      | 39 | Juramento        | 69 | Rio Pardo de Minas         |
| 10 | Catuti             | 40 | Juvenília        | 70 | Rubelita                   |
| 11 | Chapada Gaúcha     | 41 | Lagoa dos Patos  | 71 | Salinas                    |
| 12 | Claro dos Poções   | 42 | Lassance         | 72 | Santa Cruz de Salinas      |
| 13 | Cônego Marinho     | 43 | Lontra           | 73 | Santa Fé de Minas          |
| 14 | Coração de Jesus   | 44 | Luislândia       | 74 | Santo Antônio do Retiro    |
| 15 | Cristália          | 45 | Mamonas          | 75 | São Francisco              |
| 16 | Curral de Dentro   | 46 | Manga            | 76 | São João da Lagoa          |
| 17 | Divisa Alegre      | 47 | Matias Cardoso   | 77 | São João da Ponte          |
| 18 | Engenheiro Navarro | 48 | Mato Verde       | 78 | São João das Missões       |
| 19 | Espinosa           | 49 | Mirabela         | 79 | São João do Pacuí          |
| 20 | Francisco Dumont   | 50 | Miravânia        | 80 | São João do Paraíso        |
| 21 | Francisco Sá       | 51 | Montalvânia      | 81 | São Romão                  |
| 22 | Fruta de Leite     | 52 | Monte Azul       | 82 | Serranópolis de Minas      |
| 23 | Gameleiras         | 53 | Montes Claros    | 83 | Taiobeiras                 |
| 24 | Glaucilândia       | 54 | Montezuma        | 84 | Ubaí                       |
| 25 | Grão Mogol         | 55 | Ninheira         | 85 | Urucuaia                   |
| 26 | Guaraciama         | 56 | Nova Porteirinha | 86 | Vargem Grande do Rio Pardo |
| 27 | Ibiaí              | 57 | Novorizonte      | 87 | Várzea da Palma            |
| 28 | Ibiracatu          | 58 | Olhos-d'água     | 88 | Varzelândia                |
| 29 | Icaraí de Minas    | 59 | Padre Carvalho   | 89 | Verdelândia                |
| 30 | Indaiabira         | 60 | Pai Pedro        |    |                            |

Fonte: Do autor, 2024.

O clima norte mineiro é caracterizado por ser seco, possuir temperaturas elevadas e pouca disponibilidade hídrica. Estes fatos somados a problemas econômicos e sociais como municípios com economias pouco diversas, populações pequenas e baixa renda, tornam a região um alvo da vulnerabilidade ocasionada pelas mudanças climáticas (FREITAS; CALHEIROS; DOS REIS, 2019).

A vegetação local é um entroncamento de três grandes biomas brasileiros: o Cerrado, a Caatinga e a Mata Atlântica (Figura 2), logo caracterizá-la se torna um processo difícil, pois a vegetação como um todo é muito variada contendo inúmeras fitofisionomias destes três biomas o que propicia a formação de um mosaico vegetal complexo e rico em biodiversidade (BELEM, 2008).

Figura 2 – Biomas inseridos na Região Norte de Minas Gerais.




Fonte: Do Autor. 2023

## 4.2 Base de dados

Para atingir os objetivos propostos nesta pesquisa, foi estabelecida uma metodologia para orientar os procedimentos de coleta, análise e interpretação dos dados. O fluxograma de

metodologia pode ser visualizado na Figura 3 e representa a abordagem proposta; vale salientar que cada procedimento metodológico foi planejado para maximizar a precisão e a relevância dos resultados, permitindo uma compreensão abrangente do problema em função dos resultados esperados.

Figura 3 – Fluxograma da metodologia do estudo.



Fonte: Do Autor. 2024

Trata-se de uma extensa área geográfica que requer uma grande quantidade de imagens Landsat OLI com revisitas de 16 dias em longo período temporal de 10 anos. Portanto, o processo de obtenção de dados foi realizado utilizando a Infraestrutura de Dados Espaciais (IDE) GEE a qual requer o desenvolvimento e submissão de vários *scripts*. O Apêndice A apresenta o código em javascript para carregar os dados das imagens multiespectrais utilizados, assim como o resultado nas análises. As cenas usadas são provenientes originalmente do USGS Landsat 8 Level 2, Collection 2, Tier 1 (USGS, 2024) que já fornece cenas ortorretificadas, com correções atmosféricas e prontas para utilização disponíveis na Coleção GEE ('LANDSAT/LC08/C02/T1\_L2').

Continuando a obtenção de dados em ambiente GEE foi gerado um novo script em java (Apêndice B) para carregar a base de dados do TerraClimate que é um repositório bem consolidado e confiável que fornece informações mensais sobre o clima e o balanço hídrico climático para superfícies terrestres globais; neste script também foi realizado o cálculo do PDSI. A base TerraClimate utiliza ferramentas de interpolação auxiliadas por dados climáticos,

combinando normais climatológicas de alta resolução espacial a partir do conjunto de dados WorldClimate (ABATZOGLOU, 2018). Trata-se também de um enorme volume de dados necessários para cobrir a extensa área geográfica correspondente aos 89 municípios da região Norte de Minas Gerais durante o longo período temporal de 10 anos, portanto os recursos avançados do ambiente GEE são indispensáveis para viabilizar o trabalho.

### 4.3 Processamento de dados

Por trata-se de grandes volumes de dados que demandam processamentos de informações espaciais muito intensivos e recursos computacionais otimizados do estado da arte, o ambiente de computação em nuvem oferecido pela plataforma GEE torna-se indispensável para viabilização do presente estudo.

No ambiente do Google Earth Engine (GEE), imagens multiespectrais do satélite Landsat 8 (sensor OLI) foram importadas e processadas. Para delimitar a área de estudo, utilizou-se um polígono vetorial (shapefile) da Região Norte de Minas Gerais, definindo assim a Região de Interesse (ROI). Em seguida, aplicou-se um recorte (clip) espacial para restringir as análises à área selecionada. Além disso, estabeleceu-se a faixa temporal do período analisado (2013 a 2023), garantindo a consistência temporal dos dados. Os detalhes técnicos desses processamentos – como a programação em JavaScript e a configuração de parâmetros – estão descritos nos Anexos 1 e 2, que incluem scripts comentados para maior clareza metodológica.

Para assegurar resultados consistentes, precisos e minimizar a interferência causada por nuvens e sombras, foi utilizada a função disponível no GEE *maskLandsatClouds(image)*, que aplica uma máscara para remover pixels cobertos por essas obstruções. Essa função se baseia nas informações disponibilizadas na banda de qualidade *QA\_PIXEL* que acompanha as imagens espectrais do Landsat, permitindo uma filtragem refinada dos dados, onde cada pixel é analisado e rotulado quanto à presença de nuvens e de sombras de nuvens permitindo sua exclusão nos processamentos.

Além do filtro de nuvens, foi aplicado também um filtro de mediana para aprimorar a qualidade das imagens. A função disponível no GEE *composicaoMelhoresPixels(collection)* utiliza o procedimento *collection.median()*, que gera uma imagem composta com os valores de mediana de todos os pixels multitemporais em um período específico (como fevereiro ou agosto). Essa técnica permite que a imagem resultante represente um valor central ou uma média temporal de todas as imagens disponíveis no intervalo selecionado, minimizando a influência de ruídos, como a presença residual de nuvens e sombras não contempladas na banda

de qualidade *QA\_PIXEL*. Ruídos temporais de diferentes naturezas são corrigidos ou minimizados por este filtro de mediana (detalhes específicos podem ser vistos no script do Apêndice A).

Posteriormente, os índices de vegetação NDVI, SAVI e IAF e de seca PDSI, foram processados no GEE e exportados para máquina local, onde foram carregados no software QGIS 3.28 (QGIS, 2024) para elaboração dos mapas temáticos e exportados ao ArcMap 10.8 (ESRI, 2019) para coleta dos valores dos quatro índices em pontos distribuídos por toda a superfície de estudo (Norte de Minas Gerais), este processo foi realizado através de uma amostragem sistemática com ferramenta *Create Fishnet* utilizando o parâmetro empírico de 50 linhas e 50 colunas, totalizando 2500 pontos em toda a extensão do Norte de Minas Gerais; a extração dos valores dos pontos foi feita por meio da ferramenta *Extract Multi Values to Points* e em seguida os pontos que não apresentavam valores válidos nos dois períodos da análise (Fevereiro e Agosto) nos quatro índices trabalhados (NDVI, SAVI, IAF e PDSI) foram retirados para manter a integridade do processamento estatístico.

#### 4.4 Análise estatística dos dados

Os dados dos pontos pré-processados no ArcMap foram inicialmente exportados para o MS Excel (MICROSOFT, 2019), onde foram organizados e onde foi calculado o Coeficiente de Correlação de Pearson para avaliar a relação entre as variáveis de interesse (PDSI, NDVI, SAVI e IAF). Em seguida, os dados foram transferidos para o software RStudio 2024.09.1 (POSIT SOFTWARE) para o processamento com o Modelo Linear Generalizado (GLM - General linear model) por meio de um script em R (Apêndice C). A escolha do GLM como modelo regressivo foi motivada pela heterogeneidade dos dados, que não seguem a distribuição normal, um pressuposto essencial para a aplicação da regressão linear múltipla tradicional. Para constatar essa heterogeneidade foi realizado o teste de Shapiro-Wilk (Apêndice C).

Dada essa falta de normalidade constatada pelo teste de Shapiro-Wilk, o GLM oferece uma alternativa mais adequada ao permitir o uso de distribuições diferentes, como Poisson ou binomial, adaptando-se melhor às características dos dados. Além disso, uma transformação logarítmica foi aplicada aos valores dos Índices trabalhados (PDSI, NDVI, SAVI e IAF), para estabilizar a variabilidade e aproximar a distribuição da normalidade. Essa transformação ajuda a reduzir a influência de valores extremos, proporcionando um modelo mais robusto e melhorando a precisão da relação entre o PDSI e as variáveis independentes.



Outro pressuposto a ser atingido era a ausência de multicolinearidade entre as variáveis do modelo, para tal, foi realizado o teste VIF – *Variance Inflation Factor*, onde foi constatada a multicolinearidade; em decorrência disto, foi feito o processamento da Regressão Ridge para minimizar os efeitos da multicolinearidade. Os scripts do processamento da Regressão Ridge e do Teste VIF podem ser verificados nos Apêndice E, e seus resultados completos podem ser visualizados no Apêndice F.


Para analisar os resultados do GLM foi utilizado o Pseudo  $R^2$  de McFadden para avaliar a qualidade do ajuste deste modelo e para a análise dos resultados da Regressão Ridge foi utilizado o erro médio quadrático (RMSE) e  $R^2$  ajustado para indicar a qualidade do modelo.

## 5 RESULTADOS E DISCUSSÃO

### 5.1 Índice de Severidade de Seca - PDSI

O Índice de Severidade de Seca de Palmer (PDSI) apresentou uma mudança expressiva durante o período analisado, apresentando os maiores valores nos anos de 2020, 2021 e 2022, enquanto que os menores valores foram verificados nos anos de 2016 e 2017 (Figura 4); de forma geral o PDSI apresenta situação de seca durante o todo o período de estudo, variando entre Seca Leve e Extremamente Seco (Tabela 4).

Figura 4 – Índice de Severidade de Seca de Palmer (PDSI) | 2013 – 2023



Fonte: Do Autor. 2024

De acordo com Petrucci, De Oliveira e Silva (2022), entre os anos de 2015 e 2017 foram reportados eventos de déficit extremo de chuva (DEC) em diversas regiões do Norte de Minas Gerais, a região também lidera com maior número de meses consecutivos de DECs durante este período. Em 2020, 2021 e 2022, o estado de Minas Gerais, assim como a região sudeste e o extremo sul da Bahia presenciaram eventos de precipitação atípica, que ocasionaram um grande número de inundações e enxurradas durante o verão (DALAGNOL *et al.* 2022).

Isto corrobora com os resultados obtidos de PDSI, na região Norte de Minas Gerais pois, até mesmo em situações onde os valores médios do índice indiquem eventos Extremamente Secos na região entre os anos de 2015 e 2019, os valores mínimos e máximos obtidos sugerem um comportamento mais proeminente da seca nos anos de 2015, 2016 e 2017. O contrário também ocorre no período mais úmido do índice, onde mesmo em valores médios que indicam uma seca leve entre 2020 e 2022, os valores mínimos e máximos do PDSI indicam comportamento menos marcante da seca (Tabela 4).

Tabela 4 – Resultados PDSI

| ANO  | PDSI (Min) | PDSI (Max) | PDSI (Média) | Classificação (Média) |
|------|------------|------------|--------------|-----------------------|
| 2013 | -4,412500  | -1,626667  | -3,369428    | Seca Severa           |
| 2014 | -4,630833  | -1,475000  | -3,742689    | Seca Severa           |
| 2015 | -7,325833  | -0,111667  | -5,120421    | Extremamente Seco     |
| 2016 | -8,883333  | -4,583333  | -6,650051    | Extremamente Seco     |
| 2017 | -9,241667  | -3,741667  | -7,045735    | Extremamente Seco     |
| 2018 | -6,691667  | -1,233333  | -4,324946    | Extremamente Seco     |
| 2019 | -7,275000  | 0,083333   | -4,455817    | Extremamente Seco     |
| 2020 | -4,727500  | 1,804127   | -1,144728    | Seca Leve             |
| 2021 | -4,246667  | 2,150000   | -1,791064    | Seca Leve             |
| 2022 | -4,682500  | 2,308333   | -1,434967    | Seca Leve             |
| 2023 | -7,079167  | -0,648333  | -3,798838    | Seca Severa           |

Fonte: Do Autor. 2024.

Vale salientar que devido ao tamanho da área de estudo, a amplitude dos valores mínimos e máximos é maior; portanto, mesmo em áreas onde os valores máximos indiquem que existe uma umidade leve e moderada local, como pode ser verificado em 2020, 2021 e 2022; quando se contrasta com os valores de mínimos, alocam os valores médios em uma classificação mais “Seca”.

De acordo com Rahnema *et al.* (2024), o uso do PDSI em conjunto a índices de vegetação como NDVI e SAVI se demonstram como uma ferramenta adequada na gestão e, posteriormente, como abordagem no controle do fenômeno das secas meteorológicas e agrícolas.

## 5.2 Índice de Vegetação NDVI, SAVI e IAF.

A análise dos índices de vegetação revela comportamentos mais complexos durante o período do estudo, apresentando algumas variações dos índices a nível de estação do ano (seca e chuvosa). Não ocorreram padrões nos índices ao longo dos anos, mas foi verificado um padrão dentro dos anos, onde os índices de vegetação NDVI, SAVI e IAF se comportaram melhor nos meses de chuva quando comparados aos meses de seca, o que é um comportamento esperado, visto a maior disponibilidade hídrica no período (Tabela 5).

No geral as médias do NDVI variaram entre 0,17637 e 0,21860 no período de seca (Agosto) e entre 0,28607 e 0,32933 no período de chuva (Fevereiro); o SAVI apresentou uma variação entre 0,26455 e 0,32790 no período de estiagem (Agosto) e valores entre 0,42910 e 0,49399 no período chuvoso; já o IAF apresentou valores de biomassa entre 0,38971 e 0,59586 no período de menor disponibilidade hídrica (Agosto) e entre 1,06741 e 1,50426 no período de maior disponibilidade hídrica (Fevereiro); como pode ser visto na Tabela 5.

Tabela 5 – Resultados dos Índices – NDVI, SAVI e IAF

| PERÍODO | NDVI<br>(Mín) | NDVI<br>( $\bar{x}$ ) | NDVI<br>(Máx) | SAVI<br>(Mín) | SAVI<br>( $\bar{x}$ ) | SAVI<br>(Máx) | IAF<br>(Mín) | IAF ( $\bar{x}$ ) | IAF<br>(Máx) |
|---------|---------------|-----------------------|---------------|---------------|-----------------------|---------------|--------------|-------------------|--------------|
| ago/13  | -0,09640      | 0,19457               | 0,45928       | -0,14459      | 0,29186               | 0,68891       | -0,38112     | 0,47354           | 6,92088      |
| fev/14  | -0,17889      | 0,31329               | 0,45955       | -0,26833      | 0,46993               | 0,68932       | -0,53304     | 1,29215           | 7,43024      |
| ago/14  | -0,06472      | 0,19552               | 0,43956       | -0,09708      | 0,29327               | 0,65933       | -0,31671     | 0,47390           | 3,24910      |
| fev/15  | -0,02639      | 0,28608               | 0,45691       | -0,03958      | 0,42911               | 0,68535       | -0,23335     | 1,06741           | 5,32140      |
| ago/15  | 0,00206       | 0,18674               | 0,45052       | 0,00309       | 0,28010               | 0,67577       | -0,16713     | 0,44357           | 4,09293      |
| fev/16  | -0,08636      | 0,32084               | 0,46000       | -0,12954      | 0,48126               | 0,68999       | -0,36112     | 1,37012           | 12,27531     |
| ago/16  | -0,12365      | 0,20111               | 0,45665       | -0,18548      | 0,30166               | 0,68496       | -0,43368     | 0,50097           | 5,23457      |
| fev/17  | -0,14144      | 0,30069               | 0,45911       | -0,21215      | 0,45102               | 0,68865       | -0,46666     | 1,17785           | 6,68264      |
| ago/17  | -0,05338      | 0,17637               | 0,41276       | -0,08007      | 0,26455               | 0,61913       | -0,29270     | 0,38972           | 2,32892      |
| fev/18  | -0,13394      | 0,31999               | 0,45955       | -0,20090      | 0,47997               | 0,68931       | -0,45287     | 1,38168           | 7,42450      |
| ago/18  | 0,00687       | 0,19675               | 0,44105       | 0,01030       | 0,29512               | 0,66156       | -0,15552     | 0,47082           | 3,33217      |
| fev/19  | -0,12669      | 0,31732               | 0,45739       | -0,19003      | 0,47598               | 0,68608       | -0,43938     | 1,27917           | 5,50992      |
| ago/19  | -0,11840      | 0,19606               | 0,42401       | -0,17760      | 0,29409               | 0,63601       | -0,42375     | 0,46826           | 2,62781      |
| fev/20  | 0,06098       | 0,32785               | 0,45994       | 0,09146       | 0,49177               | 0,68990       | -0,01579     | 1,43921           | 9,50116      |
| ago/20  | -0,09086      | 0,21861               | 0,44886       | -0,13629      | 0,32790               | 0,67328       | -0,37013     | 0,59587           | 3,91585      |

|        |          |         |         |          |         |         |          |         |         |
|--------|----------|---------|---------|----------|---------|---------|----------|---------|---------|
| fev/21 | -0,07163 | 0,30973 | 0,45951 | -0,10745 | 0,46458 | 0,68925 | -0,33109 | 1,28299 | 7,32410 |
| ago/21 | -0,10870 | 0,18984 | 0,40545 | -0,16305 | 0,28475 | 0,60816 | -0,40516 | 0,43344 | 2,17074 |
| fev/22 | -0,09004 | 0,32767 | 0,45967 | -0,13505 | 0,49150 | 0,68950 | -0,36849 | 1,50427 | 7,76083 |
| ago/22 | -0,10332 | 0,19982 | 0,45424 | -0,15497 | 0,29972 | 0,68134 | -0,39471 | 0,48963 | 4,63932 |
| fev/23 | -0,13723 | 0,32934 | 0,45988 | -0,20585 | 0,49400 | 0,68980 | -0,45895 | 1,44736 | 8,78924 |
| ago/23 | -0,12946 | 0,19514 | 0,45427 | -0,19419 | 0,29271 | 0,68140 | -0,44456 | 0,46743 | 4,64603 |

---


Fonte: Do Autor. 2024

Não foram obtidos dados anômalos nos índices de vegetação, o NDVI, SAVI e IAF apresentam valores médios consistentes durante todo os anos analisados; com uma ligeira exceção para Fevereiro de 2016 e 2019, estes apresentaram valores mais altos (principalmente de IAF) do que os outros períodos, mas podem se tratar de *outliers* provenientes das cenas, pois os segundos maiores valores para Fev/2016 e Fev/2019 se encontram dentro dos intervalos dos outros pontos destas amostras. Este efeito não necessariamente afeta a qualidade dos processamentos destes períodos devido a robustez das amostras, que por serem grandes diminuem consideravelmente o efeito deste 1 ponto individual que apresenta valores mais altos que o demais (JENNINGS; ZUMBO; JOULA, 2002; CHAMBERS; HENTGES; ZHAO, 2004).

Vale ressaltar que a área de estudo possui uma grande extensão territorial e que por estar inserida em uma região de transição de grandes domínios fitoecológicos, apresenta uma variedade maior de condições climáticas entre os diferentes locais do Norte de Minas Gerais, o que torna o gradiente de observação da vegetação mais complexo e fragmentando (MOURA, 2012; CERQUEIRA *et al.* 2021).


Os índices NDVI, SAVI e IAF para os meses de fevereiro no período 2014 - 2023 podem ser visualizados nas Figuras 5, 6 e 7.

Figura 5 – Índice de Vegetação da Diferença Normalizada (NDVI) - FEV | 2014 – 2023




Fonte: Do Autor. 2024

Figura 6 – Índice de Vegetação Ajustado ao Solo (SAVI) - FEV | 2014 – 2023



Fonte: Do Autor. 2024


Figura 7 – Índice de Área Foliar (IAF) - FEV | 2014 – 2023



Fonte: Do Autor. 2024

Os índices NDVI, SAVI e IAF para os meses de agosto no período 2013 - 2023 podem ser visualizados nas Figuras 8, 9 e 10.


Figura 8 – Índice de Vegetação da Diferença Normalizada (NDVI) - AGO | 2013 – 2023



Fonte: Do Autor. 2024




Figura 9 – Índice de Vegetação Ajustado ao Solo (SAVI) - AGO | 2013 – 2023



Fonte: Do Autor. 2024

Figura 10 – Índice de Área Foliar (IAF) - AGO | 2013 – 2023



Fonte: Do Autor. 2024



Em ambos os períodos (fevereiro e agosto), observaram-se lacunas nos índices de vegetação, mesmo com a utilização de filtros para minimizar este efeito, essa característica é mais proeminente na estação chuvosa (Meses de Fevereiro) e esse fenômeno ocorre em decorrência de uma presença maior de nuvens e outros fatores externos como a falta de imagens viáveis para o período analisado devido à cobertura de nuvens nos períodos chuvosos e a resolução temporal dos dados do Landsat 8 OLI que é 16 dias. (WEBER, 1999; JU; ROY, 2008; QUESADA *et.al*, 2017).

Estas lacunas nos índices de vegetação comprometem a precisão das análises ambientais, dificultando o monitoramento temporal de mudanças na cobertura vegetal e sanidade da vegetação. Essas falhas podem introduzir incertezas em modelos preditivos, impactando decisões estratégicas em agricultura, manejo florestal e conservação. Além disso, a perda de dados em áreas críticas pode limitar o planejamento e a resposta a eventos como desmatamento, queimadas e secas (JUNIOR; RIBEIRO, 2012; SANTOS, 2013).

Uma alternativa que pode ser explorada no processamento, para possivelmente reduzir a proporção e influência das lacunas causadas pela resolução temporal do Landsat 8 é utilização de composições com outros satélites, como o Sentinel 2 ou MODIS, que possuem uma temporalidade maior, que podem suprir estes espaços causados por nuvens na estação chuvosa e outros fatores atmosféricos que gerem estas lacunas (SHAO *et al.* 2019; ROßBERG; SCHMITT, 2024).

### 5.3 Coeficiente de Correlação de Pearson

As correlações entre o PDSI e os índices NDVI/SAVI mantiveram-se semelhantes em todos os períodos analisados. Esse padrão é estatisticamente coerente, uma vez que NDVI e SAVI são índices de vegetação com fundamentos comparáveis: o SAVI, por exemplo, é uma adaptação do NDVI que incorpora um ajuste para reduzir a influência do solo exposto. Apesar dessa diferença metodológica, os resultados indicam que ambos reagem de maneira muito próxima às variações do PDSI, reforçando a consistência entre as métricas.

As correlações do PDSI e NDVI/SAVI apresentam um padrão, sendo ligeiramente maiores nos períodos chuvosos (fevereiro), nos anos de 2014, 2015, 2017, 2018, 2019 e 2020; isto se inverte em 2016, 2021, 2022 e 2023 que apresentam correlações maiores nos períodos de estiagem, ou seja, os meses de agosto (Tabela 6).

Os resultados das correlações entre o PDSI e o IAF (Tabela 6) revelam um padrão ligeiramente mais consistente: os valores são maiores durante os períodos chuvosos (fevereiro)

entre 2014 e 2020. No entanto, entre 2021 e 2023, essa tendência se inverte, com correlações mais expressivas nos períodos de estiagem (agosto). De modo geral, o comportamento do IAF acompanha o observado nos índices NDVI e SAVI, mas com uma exceção: em 2016, não há inversão entre as estações seca e chuvosa, divergindo do padrão identificado nos demais índices.

Tabela 6 – Coeficiente de Correlação de Pearson (R)

| PERÍODO | PDSI/NDVI | PDSI/SAVI | PDSI/IAF  |
|---------|-----------|-----------|-----------|
| ago/13  | 0,248698  | 0,248699  | 0,16894   |
| fev/14  | -0,09617  | -0,09617  | -0,08099  |
| ago/14  | 0,187132  | 0,187132  | 0,14945   |
| fev/15  | 0,117015  | 0,117013  | 0,04881   |
| ago/15  | 0,136352  | 0,136352  | 0,06169   |
| fev/16  | 0,038049  | 0,038049  | -0,02251  |
| ago/16  | -0,01063  | -0,01063  | -0,01285  |
| fev/17  | -0,05333  | -0,05333  | -0,07335  |
| ago/17  | 0,070588  | 0,070587  | 0,04462   |
| fev/18  | -0,19304  | -0,19304  | -0,16681  |
| ago/18  | 0,128963  | 0,128963  | 0,12034   |
| fev/19  | -0,10347  | -0,10347  | -0,049002 |
| ago/19  | 0,21166   | 0,211659  | 0,20665   |
| fev/20  | 0,002268  | 0,002268  | -0,01565  |
| ago/20  | 0,102561  | 0,102561  | 0,10457   |
| fev/21  | 0,001734  | 0,001734  | 0,01768   |
| ago/21  | -0,01036  | -0,01036  | -0,00369  |
| fev/22  | 0,237323  | 0,237324  | 0,24918   |
| ago/22  | -0,12391  | -0,12391  | -0,08166  |
| fev/23  | 0,122701  | 0,122701  | 0,12703   |
| ago/23  | -0,00527  | -0,00527  | 0,03939   |

Fonte: Do Autor. 2024

Os valores de Correlação de Pearson próximos a -1 e 1 indicam a intensidade das variáveis nas análises, seja esta intensidade negativa ou positiva; os resultados obtidos apresentam uma grande variabilidade (FIGUEIREDO FILHO; SILVA JÚNIOR, 2009; PEAK; GIL, 2015). Os resultados demonstraram inconsistência ao longo do tempo e entre os anos

analisados. De modo geral, as variáveis apresentaram correlações muito baixas entre si, com valores próximos de zero na maioria dos cenários. O maior valor positivo registrado foi 0,24918 (correlação entre PDSI e IAF em fevereiro de 2022), enquanto o menor valor, negativo, foi -0,19304 (correlação entre PDSI/NDVI e PDSI/SAVI em fevereiro de 2018).

De acordo Cargnelutti Filho (2011) e Miot (2018), valores dos coeficientes de correlação tão baixos e com variações pouco expressivas como os obtidos nos resultados, podem ser provenientes do grande tamanho das amostras por ano, que devido a magnitude espacial da área de estudo apresentam valores com grande variação que podem impactar o resultado das análises. Vale ressaltar que o alto grau de similaridade entre as correlações dos índices PDSI e NDVI/SAVI indicam que as variáveis podem estar correlacionadas entre si, apresentando multicolinearidade (COIMBRA *et al.*, 2005; SHI; ABDEL-ATY; LEE, 2016).

#### 5.4 GLM – Modelo Linear Generalizado.

O modelo GLM apresentou desempenho limitado em todo o período analisado, com valores de Pseudo  $R^2$  de McFadden baixos em ambas as análises (com e sem transformação logarítmica). Sem transformação, os valores variaram entre 6,75549E-05 e 0,05190583, enquanto com transformação logarítmica, oscilaram entre 0,001570644 e 0,99012493. A exceção ocorreu em agosto de 2013, que registrou os maiores valores de Pseudo  $R^2$  (Tabela 7), mas esse período é considerado atípico devido a características específicas da amostra (SCHMITTER, 2004; CARVALHO, 2019). Nos demais períodos os valores de Pseudo  $R^2$  foram significativamente menores como pode ser visto na Tabela 7.

A transformação logarítmica não necessariamente teve um efeito positivo nos valores de Shapiro-Wilk, mas obteve um efeito positivo no percentual explicativo do modelo como comprovado pelos aumentos dos valores de Pseudo  $R^2$  de McFadden em todos os períodos. Os resultados completos das análises do GLM e do Teste de Shapiro-Wilk podem ser conferidos no Apêndice D. Os resultados das análises para os valores transformados nos indicam que, para os anos de 2014, 2017, 2019, 2020, 2021 e 2023 os valores Pseudo  $R^2$  foram maiores nos meses de agosto (Estação Seca); já para os anos de 2015, 2016, 2018 e 2022 os meses de fevereiro (Estação Chuvosa) obtiveram valores de Pseudo  $R^2$  mais elevados (Tabela 7).

Tabela 7 – Resultados de Shapiro Wilk e do Pseudo  $R^2$  do GML.

| Período | Shapiro-Wilk (S/log) | Shapiro-Wilk (C/log) | Pseudo $R^2$ (S/log) | Pseudo $R^2$ (C/log) |
|---------|----------------------|----------------------|----------------------|----------------------|
|---------|----------------------|----------------------|----------------------|----------------------|

|        |           |           |             |             |
|--------|-----------|-----------|-------------|-------------|
| ago/13 | 3,136E-10 | 0,0001648 | 0,051905830 | 0,959453700 |
| fev/14 | 2,20E-16  | 2,20E-16  | 0,005545971 | 0,046500060 |
| ago/14 | 2,20E-16  | 2,20E-16  | 0,026115470 | 0,222091270 |
| fev/15 | 2,20E-16  | 7,90E-09  | 0,011750810 | 0,039527300 |
| ago/15 | 2,20E-16  | 1,65E-07  | 0,012017490 | 0,038584030 |
| fev/16 | 2,46E-09  | 2,20E-16  | 0,004361661 | 0,038516100 |
| ago/16 | 2,07E-10  | 2,20E-16  | 0,000067555 | 0,007966557 |
| fev/17 | 2,92E-12  | 0,0002206 | 0,002279442 | 0,007681263 |
| ago/17 | 1,02E-09  | 0,0001582 | 0,008115802 | 0,010474000 |
| fev/18 | 8,00E-08  | 1,14E-12  | 0,013060260 | 0,058089500 |
| ago/18 | 1,35E-08  | 7,19E-13  | 0,005897203 | 0,022092510 |
| fev/19 | 2,20E-16  | 2,20E-16  | 0,007919661 | 0,019544580 |
| ago/19 | 7,59E-12  | 2,20E-16  | 0,014052980 | 0,041724600 |
| fev/20 | 3,76E-14  | 2,20E-16  | 0,000421598 | 0,005702436 |
| ago/20 | 7,50E-14  | 2,20E-16  | 0,004023048 | 0,013945460 |
| fev/21 | 1,65E-10  | 8,27E-02  | 0,000432320 | 0,011716040 |
| ago/21 | 1,57E-10  | 0,0001897 | 0,001473611 | 0,015210170 |
| fev/22 | 8,12E-16  | 8,65E-13  | 0,018532260 | 0,056259240 |
| ago/22 | 2,20E-16  | 6,96E-16  | 0,006340917 | 0,011778680 |
| fev/23 | 4,89E-12  | 2,20E-16  | 0,005060169 | 0,033840600 |
| ago/23 | 5,55E-13  | 2,20E-16  | 0,006958695 | 0,015427370 |

Fonte: Do Autor. 2024

Como pode ser observado na Tabela 7, entre os anos de 2013 e 2023, o teste de normalidade (Shapiro-Wilk) para o modelo GLM indica que, sem a transformação logarítmica, os dados não seguem uma distribuição normal, com p-valores extremamente baixos ( $p\text{-value} < 0,05$ ). No entanto, após a transformação logarítmica, a maior parte dos períodos apresentam p-valores mais elevados, sugerindo que a normalidade dos dados melhora consideravelmente, mas ainda assim, abaixo dos padrões do teste (RAZALI *et al.*, 2011; HANUSZ; TARASINSKA; ZIELINSKI, 2016).


Este comportamento pode ter ocorrido devido ao tamanho das amostras, que por serem grandes e de tamanhos diferentes apresentam uma heterogeneidade maior, que pode enviesar os resultados (WEBER, 1999; DEMIDENKO, 2007; WANG; LEE, 2020). A melhora nos resultados, apesar de indicar que o modelo GLM após a transformação logarítmica explica

melhor o comportamento da variável PDSI através das variáveis NDVI, SAVI e IAF, o ganho real não foi significativo uma vez que os valores do Pseudo  $R^2$  de McFadden continuaram a apresentar coeficientes baixos (ALLISON, 2012).

A análise dos Q-Q plots dos resíduos (Apêndice G) confirma isso, nas figuras podemos conferir a dispersão dos dados nos 2 períodos (Fevereiro e Agosto) nos 10 anos de análise, com e sem transformação logarítmica, onde mesmo em situações em que os dados se apresentam como “ruins” os gráficos de normalidade demonstram linearidade na disposição dos resíduos o que indica que, na maioria dos períodos ocorreu sim uma melhora na normalidade dos dados com a transformação; as exceções ocorreram em Ago/13, Fev/16, Ago/16, e Ago/23 onde os resultados das dispersões não foram positivos (Figura 11).

Vale salientar que mesmo nestes períodos de “baixa eficiência” da transformação logarítmica, de forma geral, a transformação melhorou consideravelmente o resultado do Pseudo  $R^2$  de McFadden em todos os períodos analisados, além disso, reduziu também o grau de multicolinearidade das variáveis como pode ser verificado na Tabela 9.

Figura 11 - QQ-Plots - Períodos de exceção da transformação logarítmica.



Fonte: Do Autor. 2024

## 5.5 Regressão Linear Regularizada - Ridge

O  $R^2$  apresenta variações consistentes ao longo dos períodos analisados, com alguns meses registrando valores negativos em diversas ocasiões; Os melhores resultados foram obtidos em agosto de 2013 (0,080439996). Assim como no GLM os melhores resultados foram obtidos em Agosto de 2013, mas este período apresenta um comportamento atípico quando comparado aos demais apresentando valores mais elevados de  $R^2$ , e isto se deve as características específicas dos dados desse período amostrado (SCHMITTER, 2004; ABDEL-ATY; LEE, 2016). O Resultado da Regressão Ridge pode ser visualizado na Tabela 8.

Tabela 8 – Resultados da Regressão Linear Regularizada Ridge

| Período | $R^2$ Ridge  | RMSE Ridge  |
|---------|--------------|-------------|
| ago/13  | 0,080439996  | 0,246394962 |
| fev/14  | 0,010059382  | 0,264269451 |
| ago/14  | 0,046919645  | 0,259302766 |
| fev/15  | 0,019736812  | 0,447789086 |
| ago/15  | 0,020269459  | 0,447667411 |
| fev/16  | 0,000765172  | 0,314657011 |
| ago/16  | -0,003529449 | 0,31533247  |
| fev/17  | -0,01036602  | 0,321767167 |
| ago/17  | -1,3282E-05  | 0,320114425 |
| fev/18  | 0,027954982  | 0,367408522 |
| ago/18  | 0,015768686  | 0,369704405 |
| fev/19  | -0,035834219 | 0,450331739 |
| ago/19  | 0,044051222  | 0,432618155 |
| fev/20  | -0,000670152 | 0,366708333 |
| ago/20  | -0,004891645 | 0,367481029 |
| fev/21  | -0,018695143 | 0,306010386 |
| ago/21  | -0,030590969 | 0,30779192  |
| fev/22  | 0,023403655  | 0,502503521 |
| ago/22  | 0,018608707  | 0,50373562  |
| fev/23  | 0,013836267  | 0,332931485 |
| ago/23  | -0,008347284 | 0,336655272 |

Fonte: Do Autor. 2024

A análise do RMSE na Tabela 8 também revela variações significativas. Os valores mais baixos foram observados em fevereiro de 2021 (0,3060) e fevereiro de 2023 (0,3329), enquanto os mais altos ocorreram em fevereiro de 2015 (0,4478) e agosto de 2015 (0,4477). Esses picos sugerem que o modelo enfrentou dificuldades para gerar previsões precisas nesses períodos específicos. Conforme destacado por Shope *et al.* (2015) e Hadi e Tombul (2018), valores elevados de RMSE estão diretamente associados a desempenhos metodológicos menos eficazes.

Em relação ao ajuste do modelo de Regressão Ridge, os valores baixos de RMSE indicam uma melhor adequação às dinâmicas estudadas. Entretanto, os resultados do  $R^2$ , extremamente baixos, revelam limitações substanciais: o modelo demonstra pouca capacidade para prever com precisão as relações complexas entre as variáveis, indicando uma associação insatisfatória entre elas. Isso implica que as variáveis independentes explicam apenas uma fração mínima do comportamento da variável dependente. (HADI; TOMBUL, 2018; FROST; 2019).

Quanto à transformação logarítmica aplicada às variáveis NDVI, SAVI e IAF, observa-se uma redução gradual nos índices de vegetação ao longo do período analisado, embora os valores permaneçam elevados. Apesar dessa transformação, a Tabela 9 evidencia problemas persistentes de multicolinearidade, que não foram adequadamente mitigados. A exceção é o IAF, cujos valores de VIF ficaram abaixo de 5 na maioria dos períodos, exceto em meses específicos da estação seca (Ago/14, Ago/15, Ago/17, Ago/18, Ago/19 e Ago/21). todos da estação seca. Se as variáveis apresentarem alta correlação entre si, isso pode afetar a robustez das conclusões tiradas é por esta razão o modelo de regressão Ridge é indicado para estes casos (MCDONALD, 2009; SINAN; GENÇ, 2012).

Tabela 9 – Resultados da Transformação logarítmica na Multicolinearidade das Variáveis através do Teste VIF

| Período | NDVI (S/log) | NDVI (C/log) | SAVI (S/log) | SAVI (C/log) | IAF (S/log)  | IAF (C/log) |
|---------|--------------|--------------|--------------|--------------|--------------|-------------|
| ago/13  | 8,878986E+09 | 5018,612167  | 8,879031E+09 | 4945,461392  | 3,736374E+00 | 2,364469    |
| fev/14  | 1,441032E+10 | 2382,626293  | 1,441039E+10 | 2332,671410  | 3,862506E+00 | 2,486183    |
| ago/14  | 1,615057E+10 | 6445,934701  | 1,615075E+10 | 6179,321927  | 1,023296E+01 | 7,572405    |
| fev/15  | 1,439669E+10 | 7046,004068  | 1,439674E+10 | 6917,380538  | 4,636970E+00 | 3,250837    |
| ago/15  | 1,285034E+10 | 8465,085778  | 1,285043E+10 | 8223,908170  | 6,155271E+00 | 5,410703    |



|        |              |              |              |              |              |           |
|--------|--------------|--------------|--------------|--------------|--------------|-----------|
| fev/16 | 1,277834E+10 | 4548,951591  | 1,277839E+10 | 4511,194315  | 3,276216E+00 | 1,774508  |
| ago/16 | 1,276818E+10 | 4947,065421  | 1,276827E+10 | 4861,507270  | 4,649702E+00 | 2,724022  |
| fev/17 | 1,415433E+10 | 4161,044900  | 1,415440E+10 | 4067,057385  | 5,016069E+00 | 3,333648  |
| ago/17 | 1,375038E+10 | 10530,815640 | 1,375047E+10 | 9973,724160  | 1,406573E+01 | 14,420450 |
| fev/18 | 1,410441E+10 | 3367,374123  | 1,410448E+10 | 3300,322183  | 4,089131E+00 | 2,755304  |
| ago/18 | 1,014687E+10 | 13345,700555 | 1,014694E+10 | 12875,233671 | 1,041762E+01 | 9,542493  |
| fev/19 | 1,543695E+10 | 2528,240635  | 1,543708E+10 | 2448,379615  | 4,814107E+00 | 3,439113  |
| ago/19 | 1,300599E+10 | 6358,344058  | 1,300604E+10 | 6061,353615  | 1,247092E+01 | 8,952143  |
| fev/20 | 1,223070E+10 | 9305,990452  | 1,223077E+10 | 9193,410561  | 4,152362E+00 | 2,681946  |
| ago/20 | 1,373395E+10 | 5126,544304  | 1,373405E+10 | 4970,695867  | 7,219591E+00 | 4,712918  |
| fev/21 | 1,229879E+10 | 4271,177556  | 1,229883E+10 | 4180,084439  | 4,347276E+00 | 3,099927  |
| ago/21 | 9,302398E+09 | 7074,824810  | 9,302466E+09 | 6648,926270  | 1,723814E+01 | 13,686320 |
| fev/22 | 1,657231E+10 | 3087,642518  | 1,657240E+10 | 3023,816340  | 3,488541E+00 | 2,600209  |
| ago/22 | 1,265706E+10 | 3396,325580  | 1,265713E+10 | 3304,314295  | 5,291239E+00 | 3,395071  |
| fev/23 | 1,792613E+10 | 2813,128479  | 1,792623E+10 | 2752,184598  | 4,163549E+00 | 2,743706  |
| ago/23 | 9,545403E+09 | 5219,230000  | 9,545363E+09 | 5098,954480  | 6,958624E+00 | 3,751050  |

---

Fonte: Do Autor. 2024

De uma forma geral, os resultados das análises estatísticas (Teste de Shapiro-Wilk e Teste VIF) indicaram melhorias significativas de normalidade e multicolinearidade após a adoção da transformação logarítmica, então podemos concluir que a transformação foi efetiva; entretanto os ganhos representados nestas análises não refletem em ganhos substanciais de predição dos modelos GLM e de Regressão Ridge, onde mesmo apresentando melhora, os modelos apresentam baixo poder explicativo.

A análise do desempenho do GLM pode ser feita através de coeficientes alternativos (Pseudo  $R^2$ ) não têm uma interpretação direta como proporções de erro reduzido. Em vez disso, eles refletem melhorias na verossimilhança do modelo em comparação ao modelo nulo; portanto, um valor maior de Pseudo  $R^2$  indica um melhor ajuste do modelo (ALLISON, 2012).

Em relação ao modelo linear generalizado (GLM), os valores de Pseudo  $R^2$  indicam que, sem a transformação logarítmica, o modelo tem um ajuste fraco, explicando uma quantidade limitada de variação nos dados. Quando a transformação logarítmica é aplicada, os valores dos Pseudo  $R^2$  aumentam, sugerindo um ajuste melhor do modelo e uma maior capacidade de explicação da variação observada nos dados. Assim, a transformação logarítmica melhora tanto a normalidade quanto o desempenho do modelo ao longo do período analisado.

Vale salientar, que mesmo com os resultados de Pseudo  $R^2$  relativamente melhores após a transformação logarítmica, o modelo GLM e a Regressão Ridge não foram capazes de explicar o comportamento da variável PDSI com base nas outras três variáveis, o NDVI, o SAVI e o IAF; isto pode ter sido ocasionado por conta da heterogeneidade local em decorrência do grande tamanho da área de estudo e de lacunas provenientes das cenas obtidas (BARRETO, 1999; ROSSETO; DOS SANTOS, 2007; MOURA, 2012).

É válido ressaltar que a análise de grandes áreas enfrenta desafios significativos, como dados incompletos, erros de medição, escolha inadequada de modelos estatísticos e multicolinearidade. Dados ausentes ou imprecisos podem introduzir vieses e comprometer a robustez das análises, enquanto modelos mal ajustados frequentemente falham em capturar a complexidade dos fenômenos analisados, gerando previsões imprecisas (LITTLE; RUBIN, 2019; FROST, 2019).

Além disso, a multicolinearidade, comum em datasets com muitas variáveis correlacionadas, pode dificultar a identificação do impacto real de cada variável, levando a interpretações distorcidas. Esses problemas não apenas comprometem a validade e confiabilidade dos resultados, mas também limitam a generalização e aplicabilidade das conclusões, prejudicando decisões baseadas nesses estudos. (DORMANN *et al*, 2013; FROST, 2019).

## 6 CONSIDERAÇÕES FINAIS

Novas tecnologias são essenciais na obtenção e processamento de dados geoespacializados para análises ambientais, especialmente em áreas que apresentam maior vulnerabilidade climática como o Norte de Minas Gerais; o que torna seu monitoramento contínuo fundamental para identificar e prever possíveis alterações nos padrões hídricos e de vegetação; uma vez que este monitoramento possibilita uma análise mais precisa das condições ambientais, permitindo respostas mais rápidas e eficazes para enfrentar a escassez de água e outros desafios climáticos. O monitoramento tradicional costuma ser muito moroso e financeiramente custoso, de modo que os recursos de SR e de plataformas como o GEE agregam celeridade, baixo custo e eficiência.

A metodologia apresentada oferece uma abordagem alternativa por meio da obtenção e processamento de dados espaciais através do Google Earth Engine - GEE, que proporciona ganhos operacionais e computacionais significativos, principalmente em grandes escalas de trabalhos, apresentando-se como uma abordagem promissora para trabalhos futuros. Entretanto, deve ser utilizada com cautela em áreas que apresentem características complexas de vegetação, uma vez que as relações ambientais são mais complexas do que nos ambientes de vegetação já tradicionalmente estudados.

Com base nos resultados obtidos, os dados apresentam uma baixa correlação no Coeficiente de Pearson, valores de Pseudo  $R^2$  de McFadden baixos no GLM e valores baixos de  $R^2$  na Regressão Ridge; isto significa que a metodologia proposta, apesar de promissora no seu propósito, não foi suficiente para mapear as relações entre os Índices de Vegetação NDVI, SAVI e IAF e o Índice de Severidade de Seca de Palmer PDSI. Os resultados sugerem que, apesar do potencial da abordagem com uso de recursos da computação em nuvem no Google Earth Engine (GEE), outros fatores, como a variabilidade climática, condições do solo, ou aspectos específicos da vegetação local, podem influenciar a dinâmica da seca de forma mais complexa dificultando a obtenção de bons resultados em forma linear e direta.

O Índice de severidade de Seca de Palmer - PDSI se mostra efetivo para verificar períodos de maior intensidade de seca meteorológica, mas seu uso deve ser feito com cuidado em grandes áreas, visto sua tendência em generalizar nos valores médios da área de estudo como mais “Secos”, mesmo quando os valores mais altos dos períodos apresentam classificações umidade maiores.

Uma alternativa a ser explorada para evitar a falta de dados ocasionadas por nuvens e altas resoluções temporais é utilizar a fusão com cenas de outros satélites como Landsat 2 ou MODIS, para se obter uma malha mais homogênea, consistente e livre de lacunas.

Para melhorar a precisão e a aplicabilidade da metodologia, seria recomendável integrar variáveis adicionais ou adotar abordagens complementares, como modelos mais robustos que capturem as heterogeneidades da área e modelos que incluam variáveis hidrológicas e climáticas, a fim de capturar de forma mais detalhada as interações entre vegetação e seca. Outra abordagem possível é a estratificação da área de estudo previamente baseando-se em parâmetros pré-definidos.

## REFERÊNCIAS

- ABATZOGLOU, J. T. et al. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. **Scientific data**, v. 5, n. 1, p. 1-12, 2018.
- ALLEN, R. G. et al. Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. **Fao, Rome**, v. 300, n. 9, p. D05109, 1998.
- ALLEN, R. G. et al. **SEBAL Surface Energy Balance Algorithm for Land – Advanced Training and Users Manual** – Idaho Implementation, version 1.0, 2002a.
- ALLEY, W.M. The Palmer drought severity index: limitations and assumptions. **Journal of climate and applied meteorology**, p. 1100-1109, 1984.
- ALLISON, P. Logistic regression using SAS: Theory and application. **SAS institute**, 2012.
- AMMESF. Associação dos Municípios da Bacia do Médios São Francisco. Disponível em <http://ammesf.org.br/municipios/>. Acesso em: 09 jun. 2023.
- BARRETO, C. C. Heterogeneidade espacial do habitat e diversidade específica: implicações ecológicas e métodos de mensuração. **Oecologia Brasiliensis**, v. 7, n. 1, p. 6, 1999.
- BEATO, D.; CÂNDIDO, M.; PAIXÃO, M. Bacias hidrogeológicas representativas: projeto águas do norte de Minas Gerais. 2012.
- BELEM, R. A. Zoneamento ambiental e os desafios da implementação do Parque Estadual Mata Seca, Município de Manga, Norte de Minas Gerais. 2008.
- BERLIANA S, S. et al. Analysis of wet and dry season by using the Palmer Drought Severity Index (PDSI) over Java Island. In: **AIP Conference Proceedings**. AIP Publishing, 2021.
- BLAIN, G.; BRUNINI, O. Análise comparativa dos índices de seca de Palmer, Palmer adaptado e índice padronizado de precipitação no estado de São Paulo. **Revista Brasileira de Meteorologia**, v. 22, p. 105-111, 2007.
- BRAGA, A. C. **Evapotranspiração e produtividade primária bruta em áreas agrícolas utilizando técnicas de sensoriamento remoto**. 2014. 122 p. Tese (Doutorado em Meteorologia) - Universidade Federal de Campina Grande, Centro Ciências e Tecnologia, 2014.
- CAI, M. et al. An adaptive spatiotemporal tensor reconstruction method for GIMMS-3g+ NDVI. **Remote Sensing of Environment**, v. 316, p. 114511, 2025.
- CARGNELUTTI FILHO, A. et al. Tamanho de amostra para estimação do coeficiente de correlação de Pearson entre caracteres de Crambe abyssinica. **Revista Ciência Agronômica**, v. 42, p. 149-158, 2011.
- CARVALHO, F. J. Modelos lineares generalizados na agronomia: análise de dados binomiais e de contagem, zeros inflacionados e enfoque bayesiano. 2019. 115 f. Tese (Doutorado em Agronomia) - Universidade Federal de Uberlândia, Uberlândia, 2019. DOI <http://dx.doi.org/10.14393/ufu.te.2019.1244>.

- CERQUEIRA, M. C. et al. Fragmentação da paisagem no entorno e na Reserva de Desenvolvimento Sustentável Nascentes das Geraizeiras, Minas Gerais. **Ciência Florestal**, v. 31, p. 607-633, 2021.
- CHAMBERS, R.; HENTGES, A.; ZHAO, X. Robust automatic methods for outlier and error detection. **Journal of the Royal Statistical Society Series A: Statistics in Society**, v. 167, n. 2, p. 323-339, 2004.
- CLIMATOLOGY LAB. Disponível em: <https://www.climatologylab.org/terraclimate.html>. Acesso em: 25 out. 2024.
- COELHO, C. A. S.; CARDOSO, D. H.F.; FIRPO, M. A.F. A seca de 2013 a 2015 na região sudeste do Brasil. **Climanálise**, n. 1, p. 55-61, 2016.
- COIMBRA, J. L. M. et al. Consequências da multicolinearidade sobre a análise de trilha em canola. **Ciência Rural**, v. 35, p. 347-352, 2005.
- DA SILVA, V. S. et al. Methodological evaluation of vegetation indexes in land use and land cover (LULC) classification. **Geology, Ecology, and Landscapes**, v. 4, n. 2, p. 159-169, 2020.
- DAI, A.; TRENBERTH, K. E.; QIAN, T. A global dataset of Palmer Drought Severity Index for 1870–2002: Relationship with soil moisture and effects of surface warming. **Journal of Hydrometeorology**, v. 5, n. 6, p. 1117-1130, 2004.
- DALAGNOL, R. et al. Extreme rainfall and its impacts in the Brazilian Minas Gerais state in January 2020: Can we blame climate change? **Climate Resilience and Sustainability**, v. 1, n. 1, p. e15, 2022.
- DAOUD, J. I. Multicollinearity and regression analysis. In: **Journal of Physics: Conference Series**. IOP Publishing, 2017. p. 012009.
- DE BORATTO, I. M.; GOMIDE, R. L. Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais. In: **Embrapa Milho e Sorgo-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. Anais... São José dos Campos: INPE, 2013. p. 7345-7352., 2013.
- DE LA IGLESIA MARTINEZ, A.; LABIB, S. M. Demystifying normalized difference vegetation index (NDVI) for greenness exposure assessments and policy interventions in urban greening. **Environmental research**, v. 220, p. 115155, 2023.
- DE MORAIS DANELICHEN, V. H. et al. Estimativas de índice de área foliar de uma pastagem por sensoriamento remoto no Pantanal Mato-grossense. **Ciência e Natura**, v. 36, n. 3, p. 373-384, 2014.
- DE OLIVEIRA, A. C. et al. Classificação Supervisionada de Áreas Queimadas do Cerrado Utilizando Atributos Espectrais Provenientes de Séries Temporais do Sensor WFI. **Rev. Bras. Cartogr**, v. 76, p. 1, 2024.
- DE SOUZA, R. R. et al. Sample size and Shapiro-Wilk test: An analysis for soybean grain yield. **European Journal of Agronomy**, v. 142, p. 126666, 2023.
- DECHANT, C. M.; MORADKHANI, H. Analyzing the sensitivity of drought recovery forecasts to land surface initial conditions. **Journal of Hydrology**, v. 526, p. 89-100, 2015.

- DECHANT, C. M.; MORADKHANI, H. Toward a reliable prediction of seasonal forecast uncertainty: Addressing model and initial condition uncertainty with ensemble data assimilation and Sequential Bayesian Combination. **Journal of Hydrology**, v. 519, n. PD, p. 2967–2977, 2014.
- DEMIDENKO, E. Sample size determination for logistic regression revisited. **Statistics in medicine**, v. 26, n. 18, p. 3385-3397, 2007.
- DORMANN, C. F. et al. Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. **Ecography**, v. 36, n. 1, p. 27-46, 2013.
- DUTRA, D. J. et al. Uso do sensoriamento remoto para análise de eventos de seca em bacias hidrográficas: estudo de caso na sub-bacia do ribeirão Serra Azul, MG. 2021.
- EL-DERENY, M.; RASHWAN, N. I. Solving multicollinearity problem using ridge regression models. **International Journal of Contemporary Mathematical Sciences**, v. 6, n. 12, p. 585-600, 2011.
- ESRI. ArcGIS for Windows Version 10.8. License type ArcInfo. [S.I]: ESRI – Enviromental Systems Research Institute, 2019.
- FADL, M. E. et al. Assessing soil productivity potential in arid region using remote sensing vegetation indices. **Journal of Arid Environments**, v. 222, p. 105166, 2024.
- FEITOSA, J. R. P. **Uso de técnicas de sensoriamento remoto e imagens Landsat 5 - TM e NOAA-AVHRR na estimativa do balanço de radiação à superfície**. 164p. Tese (Doutorado em Meteorologia), Universidade Federal de Campina Grande, Campina Grande, 2005.
- FERNANDES, D. S. et al. **Índices para a quantificação da seca. Embrapa Arroz e Feijão- Documentos (INFOTECA-E)**, Empresa Brasileira de Pesquisa Agropecuária, Embrapa Arroz e Feijão, Ministério da Agricultura, Pecuária e Abastecimento, Santo Antônio de Goiás, GO, 2009.
- FERRARI, G. T. **Imputação de dados pluviométricos e sua aplicação na modelagem de eventos extremos de seca agrícola**. 2011. Dissertação (Mestrado em Estatística e Experimentação Agrônômica) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2011. doi:10.11606/D.11.2011.tde-28062011-103251. Acesso em: 2025-03-01.
- FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista política hoje**, v. 18, n. 1, p. 115-146, 2009.
- FITZ, P. R. **Cartografia básica**. Oficina de Textos, 2008.
- FREITAS, L. O.; CALHEIROS, T.; DOS REIS, R. J. Vulnerabilidade da mesorregião Norte de Minas Gerais face às mudanças climáticas. **Caderno de Geografia**, v. 29, n. 56, p. 134-155, 2019.
- FROST, J. **Regression analysis: An intuitive guide for using and interpreting linear models**. Statistics By Jim Publishing, 2019.
- GHASEMI, A; ZAHEDIASL, S. Normality tests for statistical analysis: a guide for non-statisticians. **International journal of endocrinology and metabolism**, v. 10, n. 2, p. 486, 2012.
- GOOGLE EARTH ENGINE. Disponível em: <https://earthengine.google.com/platform/>. Acesso em: 17 out. 2024.

GOUVEIA, C. M. et al. Drought impacts on vegetation activity in the Mediterranean region: An assessment using remote sensing data and multi-scale drought indicators. **Global and Planetary Change**, v. 151, p. 15-27, 2017.

GURGEL, H. C. **Variabilidade especial e temporal do NDVI sobre o Brasil e suas conexões com o clima**. São José dos Campos, 2000. 118 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais.

GUTTMAN, N. B. Comparing the palmer drought index and the standardized precipitation index 1. **JAWRA Journal of the American Water Resources Association**, v. 34, n. 1, p. 113-121, 1998.

HADI, S. J.; TOMBUL, M. Comparison of spatial interpolation methods of precipitation and temperature using multiple integration periods. **Journal of the Indian Society of Remote Sensing**, v. 46, p. 1187-1199, 2018.

HANUSZ, Z; TARASINSKA, J; ZIELINSKI, Wojciech. Shapiro–Wilk test with known mean. **REVSTAT-Statistical Journal**, v. 14, n. 1, p. 89–100-89–100, 2016.

HOERL, A. E.; KENNARD, R. W. Ridge regression: Biased estimation for nonorthogonal problems. **Technometrics**, v. 12, n. 1, p. 55-67, 1970.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

INPE. História. Disponível em: <http://www.cbers.inpe.br/sobre/historia.php>. Acesso em: 15 jul. 2023.

INPE. Lançamento CBERS 04A. Disponível em: <http://www.cbers.inpe.br/lancamentos/cbers04a.php>. Acesso em: 15 jul. 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Cidades: Estimativa da População. 2018**. Brasília: IBGE 2010. Disponível em: <http://www.cidades.ibge.gov.br/xtras/home.php?lang=>. Acesso em: 06 jun. 2023.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **Climate change 2014: Synthesis Report**. Geneva, Switzerland: IPCC, p.151, 2014 b.

JANIZADEH, S. et al. Combination four different ensemble algorithms with the generalized linear model (GLM) for predicting forest fire susceptibility. **Geomatics, Natural Hazards and Risk**, v. 14, n. 1, p. 2206512, 2023.

JENNINGS, M. J.; ZUMBO, B. D.; JOULA, J. F. The robustness of validity and efficiency of the related samples t-test in the presence of outliers. **Psicologica**, v. 23, n. 2, 2002.

JENSEN, J. R. **Remote sensing of the environment: An earth resource perspective 2/e**. Pearson Education India, 2009.

JU, J.; ROY, D. P. The availability of cloud-free Landsat ETM+ data over the conterminous United States and globally. **Remote Sensing of Environment**, v. 112, n. 3, p. 1196-1211, 2008.

JUNIOR, W. M. D. S.; RIBEIRO, G. P. Qualidade dos dados geográficos disponibilizados em ambiente de sistema de informação geográfica na internet. IV SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, Anais... Recife, p. 06-09, 2012.



- LEMENKOVA, P. Evaluating the Performance of Palmer Drought Severity Index (PDSI) in Various Vegetation Regions of the Ethiopian Highlands. **Acta Biologica Marisiensis**, v. 4, n. 2, p. 14-31, 2021.
- LIMA, M. A.; ALVES, B.J.R. Vulnerabilidades, impactos e adaptação à mudança do clima no setor agropecuário e solos agrícolas. **Parcerias Estratégicas**, Brasília (DF), n. 27, p. 73-112, dez. 2008.
- LITTLE, R. JA; RUBIN, D. B. **Statistical analysis with missing data**. John Wiley & Sons, 2019.
- LUIZ, A. J. B. et al. Estimativa amostral objetiva de área plantada regional, apoiada em imagens de sensoriamento remoto. **Pesquisa Agropecuária Brasileira, Brasília**, v. 47, n. 9, p. 1279-1287, 2012.
- MARENGO, J. A. et al. A seca e a crise hídrica de 2014-2015 em São Paulo. **Revista USP**, n. 106, p. 31, 2015.
- MARENGO, J. A. et. al. Vulnerabilidade, impactos e adaptação à mudança do clima no semi-árido do Brasil. **Parcerias Estratégicas**, Brasília (DF), n. 27, p. 149-176, dez. 2008.
- MCDONALD, G. C. Ridge regression. **Wiley Interdisciplinary Reviews: Computational Statistics**, v. 1, n. 1, p. 93-100, 2009.
- MICROSOFT OFFICE 2019 Project for Windows. [S. l.]: Microsoft Corporation, 2019.
- MIOT, H. A. Análise de correlação em estudos clínicos e experimentais. **Jornal Vascular Brasileiro**, v. 17, n. 4, p. 275-279, 2018.
- MOURA, V. M. Relação solo-vegetação em gradientes na zona de tensão ecológica Norte de Minas Gerais e Centro-Sul da Bahia Brasil. 2012.
- PAUL, R. K. Multicollinearity: Causes, effects and remedies. **IASRI, New Delhi**, v. 1, n. 1, p. 58-65, 2006.
- PEAK, S.; GIL, K. Correlation analysis of factors affecting removal efficiency in vegetative filter strips. **Environmental Earth Sciences**, v. 75, p. 1-8, 2016.
- PETRUCCI, E.; DE OLIVEIRA, L. A.; SILVA, R. C. Secas pluviométricas no estado de Minas Gerais, de 1980 a 2017. **RA'E GA-O Espaço Geográfico em Análise**, v. 54, p. 129-153, 2022.
- POSIT SOFTWARE, PBC. RStudio 2024.09.1+394 "Cranberry Hibiscus" Release (a1fe401fc08c232d470278d1bc362d05d79753d9, 2024-11-03) for windows Mozilla/5.0 (Windows NT 10.0; Win64; x64) AppleWebKit/537.36 (KHTML, like Gecko) RStudio/2024.09.1+394 Chrome/124.0.6367.243 Electron/30.4.0 Safari/537.36, Quarto 1.5.57.
- QGIS. QGis for Windows Version 3.28 Firenze. QGis Project, 2024.
- QUESADA, H. B. et al. Análise da vegetação ripária em bacia hidrográfica utilizando índice de vegetação normalizada (NDVI) no município de Maringá-PR/Analysis of riparian vegetation in a watershed using ndvi index in Maringa-PR. **Geo Uerj**, n. 31, p. 439-455, 2017.
- RADEMANN, L. K. et al. INFLUÊNCIA DOS GCPS NA ACURÁCIA DE PRODUTOS CARTOGRÁFICOS A PARTIR DE VANT EM ÁREA DE GRANDE VARIAÇÃO ALTIMÉTRICA. **REVISTA GEOGRÁFICA ACADÊMICA**, v. 18, n. 1, p. 24-38, 2024.

- RAHNAMA, S. et al. Comparison of different drought monitoring indices in different climatic conditions in Iran. **Atmósfera**, v. 38, 2024.
- RAO, M. et al. Mapping drought-impacted vegetation stress in California using remote sensing. **GIScience & Remote Sensing**, v. 54, n. 2, p. 185-201, 2017.
- RAVANELLI, R. et al. Monitoring the impact of land cover change on surface urban heat island through Google Earth Engine: Proposal of a global methodology, first applications and problems. **Remote Sensing**, v. 10, n. 9, p. 1488, 2018.
- RAZALI, N. M. et al. Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. **Journal of statistical modeling and analytics**, v. 2, n. 1, p. 21-33, 2011.
- ROBINSON, N. P. et al. A dynamic Landsat derived normalized difference vegetation index (NDVI) product for the conterminous United States. **Remote sensing**, v. 9, n. 8, p. 863, 2017.
- ROßBERG, T.; SCHMITT, M. Dense NDVI Time Series by Fusion of Optical and SAR-Derived Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 2024.
- ROSSETO, V.; DOS SANTOS, F. A. M. A heterogeneidade ambiental de três fisionomias Florestais em um fragmento em Campinas (SP). **Revista Brasileira de Biociências**, v. 5, n. S1, p. 408-410, 2007.
- SANTOS, A. S. Geoestatística aplicada na avaliação da qualidade de dados geoespaciais. 2013.
- SAUSEN, T. M.; LACRUZ, Maria Silvia Pardi. **Sensoriamento remoto para desastres**. 1. ed. São Paulo: Oficina de Textos, 2015.
- SCHMITTER, H. The sample size needed for the calculation of a GLM tariff. **ASTIN Bulletin: The Journal of the IAA**, v. 34, n. 1, p. 249-262, 2004.
- SHAO, Z. et al. Deep learning-based fusion of Landsat-8 and Sentinel-2 images for a harmonized surface reflectance product. **Remote Sensing of Environment**, v. 235, p. 111425, 2019.
- SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, v. 52, n. 3-4, p. 591-611, 1965.
- SHI, Q.; ABDEL-ATY, M.; LEE, J. A Bayesian ridge regression analysis of congestion's impact on urban expressway safety. **Accident Analysis & Prevention**, v. 88, p. 124-137, 2016.
- SHIBANI, N. et al. Study on the variation of NDVI, SAVI and EVI indices in Punjab State, India. In: **IOP Conference Series: Earth and Environmental Science**. IOP Publishing, 2023. p. 012070.
- SHOPE, C. L. et al. Modeling spatiotemporal precipitation: Effects of density, interpolation, and land use distribution. **Advances in Meteorology**, v. 2015, 2015.
- SINAN, A.; GENÇ, A. Comparing the most commonly used classical methods for determining the ridge parameter in ridge regression. 2012.
- SMITH, T. J.; MCKENNA, C. M. A comparison of logistic regression pseudo R2 indices. **Multiple Linear Regression Viewpoints**, v. 39, n. 2, p. 17-26, 2013.

- SOUSA, H. L. de. Sensoriamento Remoto com VANTs: uma nova possibilidade para a aquisição de geoinformações. **Revista Brasileira de Geomática**, v. 5, n. 3, p. 326-342, 2017.
- TADANO, Y. S.; UGAYA, C. M. L.; FRANCO, A. T. Método de regressão de Poisson: metodologia para avaliação do impacto da poluição atmosférica na saúde populacional. **Ambiente & Sociedade**, v. 12, p. 241-255, 2009.
- TEIXEIRA, D. S. Efeito da seca natural e induzida sobre remodelação de ácidos graxos de plantas nativas e exóticas de Cerrado. 2022. Disponível em: Disponível em: <http://hdl.handle.net/11449/235520>. Acesso em: 06 jun. 2023.
- TESFAMARIAM, B. G.; GESSESSE, B.; MELGANI, F. Characterizing the spatiotemporal distribution of meteorological drought as a response to climate variability: The case of rift valley lakes basin of Ethiopia. **Weather and Climate Extremes**, v. 26, p. 100237, 2019.
- ULIANA, E. M. et al. Validação e análise espaço-temporal de dados de precipitação obtidos por sensoriamento remoto CHIRPS para o estado de Mato Grosso, Brasil. **Revista Brasileira de Climatologia**, v. 35, p. 630-654, 2024.
- USGS. Landsat Satellite Missions. Disponível em: <https://www.usgs.gov/core-science-systems/nli/landsat/landsat-satellite-missions>. Acesso em: 17 mai. 2024.
- VANI, V.; MANDLA, V. R. Comparative study of NDVI and SAVI vegetation indices in Anantapur district semi-arid areas. **Int. J. Civ. Eng. Technol**, v. 8, n. 4, p. 559-566, 2017.
- WANG, C.; LEE, W. Evaluation of the normality assumption in meta-analyses. **American journal of epidemiology**, v. 189, n. 3, p. 235-242, 2020.
- WEBER, E. et al. Qualidade de dados geoespaciais. **Relatório de Pesquisa. Universidade Federal do Rio Grande do Sul**, 1999.
- ZHANG, H. et al. Surface urban heat island and its relationship with land cover change in five urban agglomerations in China based on GEE. **Environmental Science and Pollution Research**, v. 29, n. 54, p. 82271-82285, 2022.

## APÊNDICE A – SCRIPT DO ÍNDICES DE VEGETAÇÃO

```
// Carregar o asset da ROI
var roi = ee.FeatureCollection('projects/ee-paulovictorgeo/assets/norte_minas');

// Adicionar a ROI ao mapa
Map.addLayer(roi, {}, 'ROI', true);
Map.centerObject(roi);

// Função para máscara de nuvens (Landsat 8 C2 T1 L2)
function maskLandsatClouds(image) {
  var qa = image.select('QA_PIXEL'); // Selecionar banda de qualidade
  // Bits 3 e 5 indicam a presença de nuvens e sombras de nuvens.
  var cloudShadowBitMask = (1 << 3);
  var cloudsBitMask = (1 << 5);
  // Cria uma máscara para pixels sem nuvens e sombras de nuvens
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
  // Aplica a máscara à imagem
  return image.updateMask(mask); // Mantém apenas os pixels sem nuvens e sem sombras de
  nuvens
}

// Função para cálculo do NDVI, IAF e SAVI após a filtragem de nuvens
var calcularIndices = function(image) {
  // Calculo do NDVI após a filtragem de nuvens
  var ndvi = image.normalizedDifference(['SR_B5', 'SR_B4']); // Landsat 8 usa SR_B5 (NIR)
  e SR_B4 (Red)
  image = image.addBands(ndvi.rename('NDVI'));

  // Calculo do IAF
  var iaf = image.expression(
    '-log((0.69 - (1.5 * (nir - red) / (nir + red + 0.5))) / 0.59) / 0.91',
    {
```

```

    red: image.select('SR_B4'), // 640-670nm, RED
    nir: image.select('SR_B5'), // 850-880nm, NIR
  });
image = image.addBands(iaf.rename('IAF'));

// Calculo do SAVI
var savi = image.expression(
  '1.5 * (nir - red) / (nir + red + 0.5)',
  {
    red: image.select('SR_B4'), // 640-670nm, RED
    nir: image.select('SR_B5'), // 850-880nm, NIR
  });
image = image.addBands(savi.rename('SAVI'));

return image.clip(roi); // Recortar a imagem para a ROI
}

// Função para compor as melhores imagens (baseada na qualidade, não no NDVI)
function composicaoMelhoresPixels(collection) {
  return collection.median(); // Usa a mediana das imagens já filtradas pelas nuvens
}

// Definição da faixa temporal analisada
var startyear = 2013;
var endyear = 2024;

// Definir a data de inicio e fim das análises
var startdate = ee.Date.fromYMD(startyear,1,1); // ano inicial, mes 1 e dia 1
var enddate = ee.Date.fromYMD(endyear,12,31); // ano final, mes 12 e dia 31

// Criar lista de variável para anos
var years = ee.List.sequence(startyear, endyear);

// Coleção Landsat 8 com filtro de nuvens

```

```

var OLI = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
  .filterDate(startdate, enddate)
  .filterBounds(roi)
  .map(maskLandsatClouds); // Aplicar máscara de nuvens antes de calcular NDVI

// Função para exportar rasters para os meses de fevereiro e agosto
years.getInfo().forEach(function(year) {
  // Período de fevereiro (mês 2)
  var startFeb = ee.Date.fromYMD(year, 2, 1);
  var endFeb = ee.Date.fromYMD(year, 2, 28); // Considerando fevereiro sem ano bissexto

  // Filtrar para fevereiro e compor os melhores pixels
  var collectionFeb = OLI.filterDate(startFeb, endFeb);
  var melhoresPixelsFeb = composicaoMelhoresPixels(collectionFeb); // Seleciona os
  melhores pixels antes do cálculo

  // Aplicar cálculo dos índices após selecionar os melhores pixels
  var indicesFeb = calcularIndices(melhoresPixelsFeb);

  // Exportar NDVI para fevereiro
  Export.image.toDrive({
    image: indicesFeb.select('NDVI'),
    description: 'NDVI_Feb_' + year,
    fileNamePrefix: 'NDVI_Feb_' + year,
    region: roi.geometry(),
    scale: 100,
    maxPixels: 1e9,
    crs: 'EPSG:4326'
  });

  // Exportar IAF para fevereiro
  Export.image.toDrive({
    image: indicesFeb.select('IAF'),
    description: 'IAF_Feb_' + year,

```

```

fileNamePrefix: 'IAF_Feb_' + year,
region: roi.geometry(),
scale: 100,
maxPixels: 1e9,
crs: 'EPSG:4326'
});

```

```

// Exportar SAVI para fevereiro
Export.image.toDrive({
  image: indicesFeb.select('SAVI'),
  description: 'SAVI_Feb_' + year,
  fileNamePrefix: 'SAVI_Feb_' + year,
  region: roi.geometry(),
  scale: 100,
  maxPixels: 1e9,
  crs: 'EPSG:4326'
});

```

```

// Período de agosto (mês 8)
var startAug = ee.Date.fromYMD(year, 8, 1);
var endAug = ee.Date.fromYMD(year, 8, 31);

```

```

// Filtrar para agosto e compor os melhores pixels
var collectionAug = OLI.filterDate(startAug, endAug);
var melhoresPixelsAug = composicaoMelhoresPixels(collectionAug); // Seleciona os
melhores pixels antes do cálculo

```

```

// Aplicar cálculo dos índices após selecionar os melhores pixels
var indicesAug = calcularIndices(melhoresPixelsAug);

```

```

// Exportar NDVI para agosto
Export.image.toDrive({
  image: indicesAug.select('NDVI'),
  description: 'NDVI_Aug_' + year,

```

```

fileNamePrefix: 'NDVI_Aug_' + year,
region: roi.geometry(),
scale: 100,
maxPixels: 1e9,
crs: 'EPSG:4326'
});

```

```
// Exportar IAF para agosto
```

```

Export.image.toDrive({
  image: indicesAug.select('IAF'),
  description: 'IAF_Aug_' + year,
  fileNamePrefix: 'IAF_Aug_' + year,
  region: roi.geometry(),
  scale: 100,
  maxPixels: 1e9,
  crs: 'EPSG:4326'
});

```

```
// Exportar SAVI para agosto
```

```

Export.image.toDrive({
  image: indicesAug.select('SAVI'),
  description: 'SAVI_Aug_' + year,
  fileNamePrefix: 'SAVI_Aug_' + year,
  region: roi.geometry(),
  scale: 100,
  maxPixels: 1e9,
  crs: 'EPSG:4326'
});

```

```
});
```

```
// Intervalo de cores
```

```

var palette= [
  'FFFFFF', 'CE7E45', 'DF923D', 'F1B555', 'FCD163', '99B718',
  '74A901', '66A000', '529400', '3E8601', '207401', '056201',

```



```

'004C00', '023B01', '012E01', '011D01', '011301'];

// Gráficos
var lon = ui.Label();
var lat = ui.Label();

// Register a callback on the default map to be invoked when the map is clicked.
Map.onClick(function(coords) {
  // Update the lon/lat panel with values from the click event.
  lon.setValue('lon: ' + coords.lon.toFixed(2)),
  lat.setValue('lat: ' + coords.lat.toFixed(2));

  // Add a red dot for the point clicked on.
  var point = ee.Geometry.Point(coords.lon, coords.lat);
  // Create a vegetation index chart.
  var ndviChart = ui.Chart.image.series(OLI.select('NDVI', 'IAF', 'SAVI'), point);
  ndviChart.setOptions({
    title: 'Serie temporal de indices de vegetação',
    vAxis: {title: 'Indice de vegetação'},
    hAxis: {title: 'date', format: 'MM-yy', gridlines: {count: 7}},
  });

  //Add the chart to the map
  ndviChart.style().set({
    position: 'bottom-right',
    width: '500px',
    height: '300px',
  });
  Map.add(ndviChart);
});

// Mostrar no mapa
Map.addLayer(OLI.median().clipToCollection(roi), {bands:['SR_B5', 'SR_B4',
'SR_B3']}, 'OLI');
```

```
Map.addLayer(OLI.median().clipToCollection(roi), {min:0,max:1,  
bands:['NDVI'],palette:palette},'NDVI');  
Map.addLayer(OLI.median().clipToCollection(roi), {min:0,max:1,  
bands:['IAF'],palette:palette},'IAF');  
Map.addLayer(OLI.median().clipToCollection(roi), {min:0,max:1,  
bands:['SAVI'],palette:palette},'SAVI');
```

## APÊNDICE B – SCRIPT DO ÍNDICE PDSI

```
// Carregar o asset da ROI
var roi = ee.FeatureCollection('projects/ee-paulovictorgeo/assets/norte_minas');

// Adicionar a ROI ao mapa
Map.addLayer(roi, {}, 'ROI', true);
Map.centerObject(roi);

// PDSI
var dataset = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE')
  .filterDate('2023-01-01', '2023-12-31');

// Paleta de cores para visualização
var redToBlue = ['c70039', 'ff5733', 'ff8c1a', 'ffc300', 'ffe300', 'ffed99', 'e5fff5', '99ffcc',
  '4dff88', '00b33c', '009933'];

var vizClass = {
  palette: redToBlue,
  min: -10,
  max: 10
};

// Calcular a média do PDSI ao longo do período
var pdsi = dataset
  .select('pdsi')
  .mean()
  .clip(roi)
  .multiply(0.01); // Multiplicação para ajustar escala do PDSI

// Parâmetros de visualização do PDSI
var pdsiVis = {
  min: -5, // Ajuste da escala de visualização
  max: 5,
```

```

palette: ['red', 'orange', 'yellow', 'green', 'blue']
};

// Adicionar o PDSI ao mapa
Map.addLayer(pdsi, pdsiVis, 'PDSI');

// Definir classes de PDSI para categorizar as condições
var pdsiclass = ee.Image(1) // Cria uma imagem base para classificação
  .where(pdsi.lte(-4), 1) // Categoria 1: PDSI <= -4 (Extremamente seco)
  .where(pdsi.gt(-4).and(pdsi.lte(-3)), 2) // Categoria 2: -4 < PDSI <= -3 (Severamente seco)
  .where(pdsi.gt(-3).and(pdsi.lte(-2)), 3) // Categoria 3: -3 < PDSI <= -2 (Moderadamente
seco)
  .where(pdsi.gt(-2).and(pdsi.lte(0)), 4) // Categoria 4: -2 < PDSI <= 0 (Normal/seco)
  .clip(roi);

// Adicionar a classificação do PDSI ao mapa
Map.addLayer(pdsiclass, vizClass, 'PDSI Class');

// Visualizar e imprimir a imagem PDSI e as classes
print('PDSI Image', pdsi);
print('PDSI Class Image', pdsiclass);

// Exportar a imagem PDSI para o Google Drive
Export.image.toDrive({
  image: pdsi,
  description: 'PDSI_2023_Norte_Minas',
  scale: 1000, // Ajuste a escala conforme necessário
  region: roi.geometry(),
  fileFormat: 'GeoTIFF'
});

// Exportar a classificação do PDSI para o Google Drive
Export.image.toDrive({
  image: pdsiclass,

```

```
description: 'PDSI_Class_2023_Norte_Minas',  
scale: 1000, // Ajuste a escala conforme necessário  
region: roi.geometry(),  
fileFormat: 'GeoTIFF'  
});
```

## APÊNDICE C – SCRIPT R DO GLM – MODELO LINEAR GENERALIZADO

```

library(nortest)
library(gmodels)
library(aod)
library(ggplot2)
library(car)      # Para o teste de Durbin-Watson
library(lmtest)   # Para o teste de Breusch-Pagan
library(moments)
library(e1071)
library(pacman)
library(forecast)
library(dplyr)
library(gmodels)
library(aod)
library(ggplot2)
library(car)      # Para o teste de Durbin-Watson
library(lmtest)   # Para o teste de Breusch-Pagan
library(moments)
library(e1071)
library(pacman)
library(forecast)
library(pscl)
library(MASS)
# Ler o arquivo CSV
dados = X2023
dados$PDSI_2023_log = log(dados$PDSI_2023 + abs(min(dados$PDSI_2023)) + 1)
View(dados)
glimpse(dados)

#avaliação da variveis
hist(dados$PDSI_2023)
hist(dados$NDVI_Aug)
hist(dados$SAVI_Aug)

```

```
hist(dados$IAF_Aug)
plot(dados$PDSI_2023)
plot(dados$NDVI_Aug)
plot(dados$SAVI_Aug)
plot(dados$IAF_Aug)
```

```
dados23 = X2023
dados23$PDSI_2023_log = log(dados23$PDSI_2023 + abs(min(dados23$PDSI_2023)) + 1)
dados23$NDVI_Aug_log = log(dados23$NDVI_Aug + abs(min(dados23$NDVI_Aug)) + 1)
dados23$SAVI_Aug_log = log(dados23$SAVI_Aug + abs(min(dados23$SAVI_Aug)) + 1)
dados23$IAF_Aug_log = log(dados23$IAF_Aug + abs(min(dados23$IAF_Aug)) + 1)
dados23$NDVI_Feb_log = log(dados23$NDVI_Feb + abs(min(dados23$NDVI_Feb)) + 1)
dados23$SAVI_Feb_log = log(dados23$SAVI_Feb + abs(min(dados23$SAVI_Feb)) + 1)
dados23$IAF_Feb_log = log(dados23$IAF_Feb + abs(min(dados23$IAF_Feb)) + 1)
View(dados23)
glimpse(dados23)
```

```
#avaliação da variveis
hist(dados23$PDSI_2023)
hist(dados23$NDVI_Aug)
hist(dados23$SAVI_Aug)
hist(dados23$IAF_Aug)
plot(dados23$PDSI_2023)
plot(dados23$NDVI_Feb)
plot(dados23$SAVI_Feb)
plot(dados23$IAF_Feb)
```

```
# Média e Variância
mean(dados23$PDSI_2023)
var(dados23$PDSI_2023)
```

```
# Calcule a assimetria
skewness_value <- skewness(dados23$PDSI_2023)
print(paste("Assimetria:", skewness_value))
```

```

# Calcule a curtose
kurtosis_value <- kurtosis(dados23$PDSI_2023)
print(paste("Curtose:", kurtosis_value))

# Teste de Jarque-Bera para normalidade
jarque.test <- jarque.test(dados23$PDSI_2023_log)
print(jarque.test)

#Construção do Modelo

mod = glm(PDSI_2023 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"), data = dados23)
summary(mod)

pR2(mod)

# Gráfico de Resíduos com Escala Normalizada
plot(mod, which = 2, main = "Normal Q-Q dos Resíduos")

# Verificação da Normalidade dos Resíduos
par(mfrow = c(2, 2))
plot(mod)

# Teste formal de normalidade (Teste de Shapiro-Wilk)
shapiro.test(residuals(mod))

# 2. Verificação da Linearidade
# Plotando resíduos vs valores ajustados
plot(mod$fitted.values, residuals(mod),
      xlab = "Valores Ajustados", ylab = "Resíduos",
      main = "Resíduos vs Valores Ajustados")

```



```
abline(h = 0, col = "red")
```

```
# 3. Verificação da Homoscedasticidade
```

```
# Usar o teste de Breusch-Pagan
```

```
bptest(mod)
```

```
# 4. Verificação da Independência dos Resíduos
```

```
# Usar o teste de Durbin-Watson para independência dos resíduos
```

```
durbinWatsonTest(mod)
```

```
#Construção do segundo Modelo
```

```
mod2 = glm(PDSI_2023 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =  
"identity"), data = dados23)
```

```
summary(mod2)
```

```
pR2(mod2)
```

```
# Gráfico de Resíduos com Escala Normalizada
```

```
plot(mod2, which = 2, main = "Normal Q-Q dos Resíduos2")
```

```
# Verificação da Normalidade dos Resíduos
```

```
par(mfrow = c(2, 2))
```

```
plot(mod2)
```

```
# Teste formal de normalidade (Teste de Shapiro-Wilk)
```

```
shapiro.test(residuals(mod2))
```

```
# 2. Verificação da Linearidade
```

```
# Plotando resíduos vs valores ajustados
```

```
plot(mod2$fitted.values, residuals(mod2),  
      xlab = "Valores Ajustados", ylab = "Resíduos",
```

```
    main = "Resíduos vs Valores Ajustados")
abline(h = 0, col = "red")

# 3. Verificação da Homoscedasticidade
# Usar o teste de Breusch-Pagan
bptest(mod2)

# 4. Verificação da Independência dos Resíduos
# Usar o teste de Durbin-Watson para independência dos resíduos
durbinWatsonTest(mod2)

vif(mod)
vif(mod2)

correlacao <- cor(dados23)

# Exibir a matriz de correlação
print(correlacao)
```

## APÊNDICE D – RESULTADOS DO GLM – MODELO LINEAR GENERALIZADO

Sem Transformação

Ago 2013

Call:

```
glm(formula = PDSI_2013 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados13)
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -3.960e+00  6.689e-02 -59.197 < 2e-16 ***
NDVI_Aug    -5.642e+04  2.276e+04  -2.479 0.013288 *
SAVI_Aug     3.762e+04  1.517e+04   2.480 0.013283 *
IAF_Aug      2.299e-01  6.828e-02   3.367 0.000784 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

(Dispersion parameter for gaussian family taken to be 0.2351858)

Null deviance: 320.23 on 1265 degrees of freedom  
Residual deviance: 296.80 on 1262 degrees of freedom  
AIC: 1766.4

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -878.18174026 | -926.26003528 | 96.15659005 | 0.05190583 | 0.07314030 | 0.09516963 |

FEV 2014

Call:

```
glm(formula = PDSI_2014 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
  data = dados14)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )   |
|-------------|------------|------------|---------|------------|
| (Intercept) | -3.515e+00 | 8.820e-02  | -39.850 | <2e-16 *** |
| NDVI_Feb    | 1.287e+04  | 2.465e+04  | 0.522   | 0.602      |
| SAVI_Feb    | -8.582e+03 | 1.643e+04  | -0.522  | 0.602      |
| IAF_Feb     | -7.040e-03 | 3.791e-02  | -0.186  | 0.853      |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.3230238)

Null deviance: 425.90 on 1309 degrees of freedom  
 Residual deviance: 421.87 on 1306 degrees of freedom  
 AIC: 2243.3

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

|          | llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|----------|---------------|---------------|--------------|--------------|--------------|--------------|
| Ago 2014 | -1.116637e+03 | -1.122865e+03 | 1.245475e+01 | 5.545971e-03 | 9.462390e-03 | 1.154077e-02 |

Call:

```
glm(formula = PDSI_2014 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
  data = dados14)
```

Coefficients:

|  | Estimate | Std. Error | t value | Pr(> t ) |
|--|----------|------------|---------|----------|
|--|----------|------------|---------|----------|

(Intercept) -4.326e+00 1.025e-01 -42.216 < 2e-16 \*\*\*

NDVI\_Aug 4.599e+04 3.366e+04 1.366 0.17216

SAVI\_Aug -3.066e+04 2.244e+04 -1.366 0.17220

IAF\_Aug 4.170e-01 1.514e-01 2.755 0.00596 \*\*

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.3118318)

Null deviance: 425.90 on 1309 degrees of freedom

Residual deviance: 407.25 on 1306 degrees of freedom

AIC: 2197.1

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

|  | llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|--|---------------|---------------|--------------|--------------|--------------|--------------|
|  | -1.093541e+03 | -1.122865e+03 | 5.864828e+01 | 2.611547e-02 | 4.378231e-02 | 5.339894e-02 |

Fev 2015

Call:

glm(formula = PDSI\_2015 ~ NDVI\_Feb + SAVI\_Feb + IAF\_Feb, family = gaussian(link = "identity"),

data = dados15)

Coefficients:

Estimate Std. Error t value Pr(>|t|)

(Intercept) -6.484e+00 2.863e-01 -22.648 < 2e-16 \*\*\*

NDVI\_Feb 2.842e+05 8.274e+04 3.435 0.000625 \*\*\*

SAVI\_Feb -1.895e+05 5.516e+04 -3.435 0.000625 \*\*\*

IAF\_Feb 4.742e-01 1.647e-01 2.878 0.004115 \*\*

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 2.30313)

Null deviance: 1780.3 on 743 degrees of freedom

Residual deviance: 1704.3 on 740 degrees of freedom

AIC: 2738.1

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.364033e+03 | -1.380252e+03 | 3.243817e+01 | 1.175081e-02 | 4.266289e-02 | 4.373299e-02 |

>

Ago 2015

Call:

```
glm(formula = PDSI_2015 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados15)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )     |
|-------------|------------|------------|---------|--------------|
| (Intercept) | -6.765e+00 | 2.892e-01  | -23.391 | < 2e-16 ***  |
| NDVI_Aug    | -1.166e+05 | 1.044e+05  | -1.117  | 0.265        |
| SAVI_Aug    | 7.776e+04  | 6.963e+04  | 1.117   | 0.264        |
| IAF_Aug     | 1.631e+00  | 3.717e-01  | 4.387   | 1.32e-05 *** |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 2.300853)

Null deviance: 1780.3 on 743 degrees of freedom

Residual deviance: 1702.6 on 740 degrees of freedom

AIC: 2737.3

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

|          | llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|----------|---------------|---------------|--------------|--------------|--------------|--------------|
| Fev 2016 | -1.363665e+03 | -1.380252e+03 | 3.317432e+01 | 1.201749e-02 | 4.360966e-02 | 4.470350e-02 |

Call:

```
glm(formula = PDSI_2016 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
    data = dados16)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )    |
|-------------|------------|------------|---------|-------------|
| (Intercept) | -7.073e+00 | 1.549e-01  | -45.672 | < 2e-16 *** |
| NDVI_Feb    | -1.649e+04 | 4.096e+04  | -0.403  | 0.68730     |
| SAVI_Feb    | 1.100e+04  | 2.731e+04  | 0.403   | 0.68727     |
| IAF_Feb     | 1.721e-01  | 5.627e-02  | 3.059   | 0.00228 **  |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.7311349)

Null deviance: 717.81 on 974 degrees of freedom

Residual deviance: 709.93 on 971 degrees of freedom

AIC: 2467.6

Number of Fisher Scoring iterations: 2

>

```
> pR2(mod2)
```

```
fitting null model for pseudo-r2
```

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.228797e+03 | -1.234180e+03 | 1.076615e+01 | 4.361661e-03 | 1.098146e-02 | 1.193024e-02 |

Ago 2016

Call:

```
glm(formula = PDSI_2016 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados16)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )   |
|-------------|------------|------------|---------|------------|
| (Intercept) | -6.639e+00 | 1.502e-01  | -44.200 | <2e-16 *** |
| NDVI_Aug    | 3.319e+03  | 5.517e+04  | 0.060   | 0.952      |
| SAVI_Aug    | -2.213e+03 | 3.678e+04  | -0.060  | 0.952      |
| IAF_Aug     | 3.415e-02  | 1.600e-01  | 0.213   | 0.831      |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.7391265)

Null deviance: 717.81 on 974 degrees of freedom

Residual deviance: 717.69 on 971 degrees of freedom

AIC: 2478.2

Number of Fisher Scoring iterations: 2

```
>
```

```
> pR2(mod)
```

```
fitting null model for pseudo-r2
```

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.234096e+03 | -1.234180e+03 | 1.667498e-01 | 6.755491e-05 | 1.710108e-04 | 1.857859e-04 |



Fev 2017

Call:

```
glm(formula = PDSI_2017 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
    data = dados17)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )   |
|-------------|------------|------------|---------|------------|
| (Intercept) | -7.088e+00 | 2.110e-01  | -33.591 | <2e-16 *** |
| NDVI_Feb    | 3.124e+04  | 5.590e+04  | 0.559   | 0.576      |
| SAVI_Feb    | -2.082e+04 | 3.727e+04  | -0.559  | 0.576      |
| IAF_Feb     | 1.641e-01  | 1.104e-01  | 1.486   | 0.138      |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.027686)

Null deviance: 786.16 on 763 degrees of freedom  
 Residual deviance: 781.04 on 760 degrees of freedom  
 AIC: 2195

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.092496e+03 | -1.094992e+03 | 4.991942e+00 | 2.279442e-03 | 6.512655e-03 | 6.905578e-03 |

Ago 2017

Call:

```
glm(formula = PDSI_2017 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
```

```
data = dados17)
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -7.717e+00  2.627e-01 -29.375 < 2e-16 ***
NDVI_Aug     2.174e+05  7.638e+04  2.846  0.00455 **
SAVI_Aug     -1.449e+05  5.092e+04 -2.846  0.00455 **
IAF_Aug       9.948e-01  4.715e-01  2.110  0.03520 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

(Dispersion parameter for gaussian family taken to be 1.010636)

```
Null deviance: 786.16 on 763 degrees of freedom
Residual deviance: 768.08 on 760 degrees of freedom
AIC: 2182.2
```

Number of Fisher Scoring iterations: 2

```
>
> pR2(mod)
fitting null model for pseudo-r2
      llh    llhNull      G2   McFadden    r2ML    r2CU
-1.086105e+03 -1.094992e+03  1.777348e+01  8.115802e-03  2.299520e-02  2.438255e-02
```

Fev 2018

Call:

```
glm(formula = PDSI_2018 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
    data = dados18)
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -3.409e+00  2.101e-01 -16.223 <2e-16 ***
```

NDVI\_Feb -6.403e+04 5.430e+04 -1.179 0.239

SAVI\_Feb 4.269e+04 3.620e+04 1.179 0.239

IAF\_Feb 1.380e-02 8.126e-02 0.170 0.865

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.163021)

Null deviance: 1107.0 on 918 degrees of freedom

Residual deviance: 1064.2 on 915 degrees of freedom

AIC: 2752.8

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.371394e+03 | -1.389542e+03 | 3.629556e+01 | 1.306026e-02 | 3.872488e-02 | 4.070326e-02 |

>

Ago 2018

Call:

```
glm(formula = PDSI_2018 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados18)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )   |
|-------------|------------|------------|---------|------------|
| (Intercept) | -4.953e+00 | 2.749e-01  | -18.016 | <2e-16 *** |
| NDVI_Aug    | -6.797e+04 | 7.065e+04  | -0.962  | 0.336      |
| SAVI_Aug    | 4.531e+04  | 4.710e+04  | 0.962   | 0.336      |
| IAF_Aug     | 1.258e-01  | 4.032e-01  | 0.312   | 0.755      |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.188488)

Null deviance: 1107.0 on 918 degrees of freedom

Residual deviance: 1087.5 on 915 degrees of freedom

AIC: 2772.7

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.381348e+03 | -1.389542e+03 | 1.638882e+01 | 5.897203e-03 | 1.767525e-02 | 1.857824e-02 |

Fev 2019

Call:

```
glm(formula = PDSI_2019 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
    data = dados19)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )    |
|-------------|------------|------------|---------|-------------|
| (Intercept) | -3.196e+00 | 2.965e-01  | -10.781 | < 2e-16 *** |
| NDVI_Feb    | -2.281e+05 | 8.077e+04  | -2.824  | 0.00484 **  |
| SAVI_Feb    | 1.521e+05  | 5.385e+04  | 2.824   | 0.00484 **  |
| IAF_Feb     | -2.747e-01 | 1.439e-01  | -1.909  | 0.05660 .   |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.869326)

Null deviance: 1748.7 on 913 degrees of freedom  
 Residual deviance: 1701.1 on 910 degrees of freedom  
 AIC: 3171.6

Number of Fisher Scoring iterations: 2

```
>
> pR2(mod2)
fitting null model for pseudo-r2
```

|  | llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|--|---------------|---------------|--------------|--------------|--------------|--------------|
|  | -1.580795e+03 | -1.593414e+03 | 2.523859e+01 | 7.919661e-03 | 2.723558e-02 | 2.809536e-02 |

Ago 2019

Call:

```
glm(formula = PDSI_2019 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados19)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )   |
|-------------|------------|------------|---------|------------|
| (Intercept) | -5.353e+00 | 3.288e-01  | -16.283 | <2e-16 *** |
| NDVI_Aug    | 1.548e+05  | 9.384e+04  | 1.650   | 0.0993 .   |
| SAVI_Aug    | -1.032e+05 | 6.256e+04  | -1.650  | 0.0993 .   |
| IAF_Aug     | -2.859e-01 | 5.640e-01  | -0.507  | 0.6124     |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.829775)

Null deviance: 1748.7 on 913 degrees of freedom  
 Residual deviance: 1665.1 on 910 degrees of freedom  
 AIC: 3152

Number of Fisher Scoring iterations: 2

```
>
```

```
> pR2(mod)
```

```
fitting null model for pseudo-r2
```

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.571022e+03 | -1.593414e+03 | 4.478442e+01 | 1.405298e-02 | 4.781722e-02 | 4.932673e-02 |

```
Fev 2020
```

```
Call:
```

```
glm(formula = PDSI_2020 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
    data = dados20)
```

```
Coefficients:
```

|             | Estimate   | Std. Error | t value | Pr(> t )     |
|-------------|------------|------------|---------|--------------|
| (Intercept) | -1.347e+00 | 2.995e-01  | -4.500  | 7.66e-06 *** |
| NDVI_Feb    | -3.131e+04 | 6.866e+04  | -0.456  | 0.648        |
| SAVI_Feb    | 2.088e+04  | 4.577e+04  | 0.456   | 0.648        |
| IAF_Feb     | 1.230e-01  | 1.072e-01  | 1.148   | 0.251        |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

```
(Dispersion parameter for gaussian family taken to be 1.975242)
```

```
Null deviance: 1863.4 on 945 degrees of freedom
Residual deviance: 1860.7 on 942 degrees of freedom
AIC: 3334.6
```

```
Number of Fisher Scoring iterations: 2
```

```
>
```

```
> pR2(mod2)
```

```
fitting null model for pseudo-r2
```

| llh | llhNull | G2 | McFadden | r2ML | r2CU |
|-----|---------|----|----------|------|------|
|-----|---------|----|----------|------|------|

```
-1.662278e+03 -1.662979e+03 1.402216e+00 4.215975e-04 1.481160e-03 1.526534e-03
```

Ago 2020

Call:

```
glm(formula = PDSI_2020 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados20)
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.510e+00  2.643e-01 -5.713 1.49e-08 ***
NDVI_Aug    -1.372e+05  8.272e+04 -1.658  0.0976 .
SAVI_Aug     9.145e+04  5.515e+04  1.658  0.0976 .
IAF_Aug     -1.384e-01  2.888e-01 -0.479  0.6319
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

(Dispersion parameter for gaussian family taken to be 1.950389)

```
Null deviance: 1863.4 on 945 degrees of freedom
Residual deviance: 1837.3 on 942 degrees of freedom
AIC: 3322.6
```

Number of Fisher Scoring iterations: 2

```
>
```

```
> pR2(mod)
```

```
fitting null model for pseudo-r2
```

```
      llh    llhNull      G2   McFadden    r2ML    r2CU
-1.656289e+03 -1.662979e+03 1.338049e+01 4.023048e-03 1.404472e-02 1.447497e-02
```

Fev 2021

Call:

```
glm(formula = PDSI_2021 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
  data = dados21)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )     |
|-------------|------------|------------|---------|--------------|
| (Intercept) | -1.682e+00 | 2.559e-01  | -6.574  | 9.74e-11 *** |
| NDVI_Feb    | 2.212e+04  | 5.996e+04  | 0.369   | 0.712        |
| SAVI_Feb    | -1.475e+04 | 3.997e+04  | -0.369  | 0.712        |
| IAF_Feb     | -9.668e-02 | 1.064e-01  | -0.909  | 0.364        |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.26812)

Null deviance: 867.28 on 686 degrees of freedom  
 Residual deviance: 866.13 on 683 degrees of freedom  
 AIC: 2118.8

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.054398e+03 | -1.054854e+03 | 9.120689e-01 | 4.323198e-04 | 1.326730e-03 | 1.391256e-03 |

Ago 2021

Call:

```
glm(formula = PDSI_2021 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
  data = dados21)
```



Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )     |
|-------------|------------|------------|---------|--------------|
| (Intercept) | -1.416e+00 | 3.899e-01  | -3.632  | 0.000303 *** |
| NDVI_Aug    | 1.378e+05  | 8.632e+04  | 1.597   | 0.110821     |
| SAVI_Aug    | -9.188e+04 | 5.755e+04  | -1.597  | 0.110814     |
| IAF_Aug     | -6.467e-01 | 7.836e-01  | -0.825  | 0.409479     |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.264071)

Null deviance: 867.28 on 686 degrees of freedom  
 Residual deviance: 863.36 on 683 degrees of freedom  
 AIC: 2116.6

Number of Fisher Scoring iterations: 2

```
>
> pR2(mod)
fitting null model for pseudo-r2
```

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -1.053300e+03 | -1.054854e+03 | 3.108890e+00 | 1.473611e-03 | 4.515089e-03 | 4.734680e-03 |

Fev 2022

Call:

```
glm(formula = PDSI_2022 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
data = dados22)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )     |
|-------------|------------|------------|---------|--------------|
| (Intercept) | -2.399e+00 | 3.168e-01  | -7.574  | 8.25e-14 *** |
| NDVI_Feb    | -2.866e+05 | 9.100e+04  | -3.149  | 0.00169 **   |
| SAVI_Feb    | 1.911e+05  | 6.067e+04  | 3.149   | 0.00169 **   |

IAF\_Feb -2.467e-01 1.098e-01 -2.246 0.02494 \*

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 3.47286)

Null deviance: 3735.9 on 999 degrees of freedom

Residual deviance: 3459.0 on 996 degrees of freedom

AIC: 4088.8

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -2.039424e+03 | -2.077933e+03 | 7.701757e+01 | 1.853226e-02 | 7.412642e-02 | 7.530664e-02 |

Ago 2022

Call:

```
glm(formula = PDSI_2022 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados22)
```

Coefficients:

Estimate Std. Error t value Pr(>|t|)

(Intercept) 1.683e-01 3.538e-01 0.476 0.6344

NDVI\_Aug 3.174e+05 1.268e+05 2.502 0.0125 \*

SAVI\_Aug -2.116e+05 8.456e+04 -2.503 0.0125 \*

IAF\_Aug -1.043e+00 4.152e-01 -2.512 0.0122 \*

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 3.653348)

Null deviance: 3735.9 on 999 degrees of freedom  
 Residual deviance: 3638.7 on 996 degrees of freedom  
 AIC: 4139.5

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -2.064757e+03 | -2.077933e+03 | 2.635200e+01 | 6.340917e-03 | 2.600781e-02 | 2.642190e-02 |

Fev 2023

Call:

```
glm(formula = PDSI_2023 ~ NDVI_Feb + SAVI_Feb + IAF_Feb, family = gaussian(link =
"identity"),
    data = dados23)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )   |
|-------------|------------|------------|---------|------------|
| (Intercept) | -4.273e+00 | 2.328e-01  | -18.356 | <2e-16 *** |
| NDVI_Feb    | -3.934e+03 | 6.673e+04  | -0.059  | 0.953      |
| SAVI_Feb    | 2.623e+03  | 4.449e+04  | 0.059   | 0.953      |
| IAF_Feb     | -1.245e-01 | 8.782e-02  | -1.417  | 0.157      |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.64069)

Null deviance: 2029.2 on 1219 degrees of freedom  
 Residual deviance: 1995.1 on 1216 degrees of freedom  
 AIC: 4072.2

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -2.031123e+03 | -2.041453e+03 | 2.066020e+01 | 5.060169e-03 | 1.679200e-02 | 1.740469e-02 |

Ago 2023

Call:

```
glm(formula = PDSI_2023 ~ NDVI_Aug + SAVI_Aug + IAF_Aug, family = gaussian(link =
"identity"),
    data = dados23)
```

Coefficients:

|             | Estimate   | Std. Error | t value | Pr(> t )     |
|-------------|------------|------------|---------|--------------|
| (Intercept) | -3.062e+00 | 2.212e-01  | -13.846 | < 2e-16 ***  |
| NDVI_Aug    | 2.253e+05  | 6.570e+04  | 3.429   | 0.000626 *** |
| SAVI_Aug    | -1.502e+05 | 4.380e+04  | -3.429  | 0.000626 *** |
| IAF_Aug     | -1.183e+00 | 3.109e-01  | -3.804  | 0.000149 *** |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 1.630299)

Null deviance: 2029.2 on 1219 degrees of freedom  
 Residual deviance: 1982.4 on 1216 degrees of freedom  
 AIC: 4064.5

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

```

      llh    llhNull      G2    McFadden    r2ML    r2CU
-2.027247e+03 -2.041453e+03 2.841170e+01 6.958695e-03 2.301920e-02 2.385910e-02
>

```

Com Transformação

Ago 2013

Call:

```

glm(formula = PDSI_2013_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados13)

```

Coefficients:

```

      Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.24856    0.27077  -0.918  0.3588
NDVI_Aug_log -23.49735   11.20180  -2.098  0.0361 *
SAVI_Aug_log  18.73863    8.26768   2.266  0.0236 *
IAF_Aug_log   0.07782    0.13542   0.575  0.5657
Signif. Codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

(Dispersion parameter for gaussian family taken to be 0.0589488)

```

Null deviance: 81.059 on 1265 degrees of freedom
Residual deviance: 74.393 on 1262 degrees of freedom
AIC: 14.591

```

Number of Fisher Scoring iterations: 2

```
>
```

```
> pR2(mod)
```

fitting null model for pseudo-r2

```

      llh    llhNull      G2    McFadden    r2ML    r2CU
-2.2955650 -56.6159124 108.6406948 0.9594537 0.0822352 0.9611696
>

```

FEV 2014

Call:

```
glm(formula = PDSI_2014_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados14)
```

Coefficients:

|              | Estimate  | Std. Error | t value | Pr(> t )     |
|--------------|-----------|------------|---------|--------------|
| (Intercept)  | 0.73321   | 0.21276    | 3.446   | 0.000587 *** |
| NDVI_Feb_log | -11.38049 | 7.00174    | -1.625  | 0.104323     |
| SAVI_Feb_log | 8.22601   | 5.31170    | 1.549   | 0.121706     |
| IAF_Feb_log  | -0.06511  | 0.08030    | -0.811  | 0.417591     |

Signif. Codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.07522032)

Null deviance: 99.431 on 1309 degrees of freedom  
 Residual deviance: 98.238 on 1306 degrees of freedom  
 AIC: 334.21

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -162.10272066 | -170.00810709 | 15.81077286 | 0.04650006 | 0.01199675 | 0.05247814 |

AGO 2014

Call:

```
glm(formula = PDSI_2014_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados14)
```

Coefficients:

|             | Estimate | Std. Error | t value | Pr(> t )   |
|-------------|----------|------------|---------|------------|
| (Intercept) | -0.6446  | 0.2621     | -2.459  | 0.014066 * |

```

NDVI_Aug_log 31.6716 13.0519 2.427 0.015376 *
SAVI_Aug_log -21.3492 9.4244 -2.265 0.023656 *
IAF_Aug_log 0.7118 0.1906 3.735 0.000196 ***
Signif. Codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

(Dispersion parameter for gaussian family taken to be 0.07186907)

Null deviance: 99.431 on 1309 degrees of freedom  
 Residual deviance: 93.861 on 1306 degrees of freedom  
 AIC: 274.5

Number of Fisher Scoring iterations: 2

```

>
> pR2(mod)
fitting null model for pseudo-r2
      llh    llhNull      G2    McFadden    r2ML    r2CU
-132.25079113 -170.00810709 75.51463191 0.22209127 0.05601477 0.24502891

```

Fev 2015

Call:

```

glm(formula = PDSI_2015_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados15)

```

Coefficients:

```

      Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.14388    0.29242  -0.492  0.62285
NDVI_Feb_log -62.13188   21.22144  -2.928  0.00352 **
SAVI_Feb_log  46.99869   15.59281   3.014  0.00267 **
IAF_Feb_log   0.05011    0.15118   0.331  0.74038
Signif. Codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

(Dispersion parameter for gaussian family taken to be 0.1838765)

Null deviance: 142.60 on 743 degrees of freedom  
 Residual deviance: 136.07 on 740 degrees of freedom  
 AIC: 857.41

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -423.70625494 | -441.14346640 | 34.87442293 | 0.03952730 | 0.04579259 | 0.06593420 |

Ago 2015

Call:

```
glm(formula = PDSI_2015_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados15)
```

Coefficients:

|              | Estimate   | Std. Error | t value | Pr(> t )     |
|--------------|------------|------------|---------|--------------|
| (Intercept)  | 0.29272    | 0.48609    | 0.602   | 0.547233     |
| NDVI_Aug_log | -103.04870 | 29.17837   | -3.532  | 0.000439 *** |
| SAVI_Aug_log | 75.27630   | 20.83519   | 3.613   | 0.000323 *** |
| IAF_Aug_log  | -0.08154   | 0.33500    | -0.243  | 0.807753     |

Signif. Codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1840823)

Null deviance: 142.60 on 743 degrees of freedom  
 Residual deviance: 136.22 on 740 degrees of freedom  
 AIC: 858.24

Number of Fisher Scoring iterations: 2

>



```
> pR2(mod)
```

```
fitting null model for pseudo-r2
```

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -424.12237197 | -441.14346640 | 34.04218886 | 0.03858403 | 0.04472463 | 0.06439650 |

```
>
```

Fev 2016

Call:

```
glm(formula = PDSI_2016_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados16)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )   |
|--------------|----------|------------|---------|------------|
| (Intercept)  | -0.08393 | 0.33935    | -0.247  | 0.80470    |
| NDVI_Feb_log | 1.34236  | 11.79246   | 0.114   | 0.90939    |
| SAVI_Feb_log | -0.38340 | 8.88309    | -0.043  | 0.96558    |
| IAF_Feb_log  | 0.38073  | 0.11820    | 3.221   | 0.00132 ** |

Signif. Codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.08968576)

Null deviance: 88.571 on 974 degrees of freedom  
 Residual deviance: 87.085 on 971 degrees of freedom  
 AIC: 421.76

Number of Fisher Scoring iterations: 2

```
>
```

```
> pR2(mod2)
```

```
fitting null model for pseudo-r2
```

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -205.88236948 | -214.12981471 | 16.49489047 | 0.03851610 | 0.01677553 | 0.04719197 |

Ago 2016

Call:

```
glm(formula = PDSI_2016_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados16)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )    |
|--------------|----------|------------|---------|-------------|
| (Intercept)  | 1.2447   | 0.3284     | 3.790   | 0.00016 *** |
| NDVI_Aug_log | -22.8191 | 16.1604    | -1.412  | 0.15826     |
| SAVI_Aug_log | 16.7042  | 12.0149    | 1.390   | 0.16476     |
| IAF_Aug_log  | -0.1823  | 0.1691     | -1.078  | 0.28124     |

Signif. Codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.09089733)

Null deviance: 88.571 on 974 degrees of freedom  
 Residual deviance: 88.261 on 971 degrees of freedom  
 AIC: 434.85

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -2.124239e+02 | -2.141298e+02 | 3.411755e+00 | 7.966557e-03 | 3.493120e-03 | 9.826645e-03 |

Fev 2017

Call:

```
glm(formula = PDSI_2017_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados17)
```

Coefficients:

|             | Estimate | Std. Error | t value | Pr(> t ) |
|-------------|----------|------------|---------|----------|
| (Intercept) | 0.80600  | 0.35036    | 2.300   | 0.0217 * |

NDVI\_Feb\_log -9.35826 13.50608 -0.693 0.4886

SAVI\_Feb\_log 7.05233 10.18402 0.692 0.4888

IAF\_Feb\_log 0.07965 0.14930 0.534 0.5938

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.101704)

Null deviance: 77.623 on 763 degrees of freedom

Residual deviance: 77.295 on 760 degrees of freedom

AIC: 427.86

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -2.089306e+02 | -2.105479e+02 | 3.234547e+00 | 7.681263e-03 | 4.224751e-03 | 9.970473e-03 |

Ago 2017

Call:

```
glm(formula = PDSI_2017_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados17)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t ) |
|--------------|----------|------------|---------|----------|
| (Intercept)  | 0.3325   | 0.3904     | 0.852   | 0.3947   |
| NDVI_Aug_log | 24.4531  | 26.6804    | 0.917   | 0.3597   |
| SAVI_Aug_log | -16.6674 | 19.0489    | -0.875  | 0.3819   |
| IAF_Aug_log  | 0.6075   | 0.3575     | 1.699   | 0.0897 . |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1015475)

Null deviance: 77.623 on 763 degrees of freedom  
 Residual deviance: 77.176 on 760 degrees of freedom  
 AIC: 426.69

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -2.083426e+02 | -2.105479e+02 | 4.410555e+00 | 1.047400e-02 | 5.756346e-03 | 1.358506e-02 |

>

Fev 2018

Call:

```
glm(formula = PDSI_2018_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados18)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )     |
|--------------|----------|------------|---------|--------------|
| (Intercept)  | 1.1955   | 0.3172     | 3.768   | 0.000175 *** |
| NDVI_Feb_log | -37.3299 | 12.1909    | -3.062  | 0.002262 **  |
| SAVI_Feb_log | 27.3539  | 9.2102     | 2.970   | 0.003056 **  |
| IAF_Feb_log  | -0.1343  | 0.1196     | -1.123  | 0.261759     |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1216268)

Null deviance: 116.39 on 918 degrees of freedom  
 Residual deviance: 111.29 on 915 degrees of freedom  
 AIC: 677.85

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -333.92666134 | -354.52060773 | 41.18789276 | 0.05808956 | 0.04382867 | 0.08151177 |

Ago 2018

Call:

```
glm(formula = PDSI_2018_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados18)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t ) |
|--------------|----------|------------|---------|----------|
| (Intercept)  | 0.8622   | 0.4945     | 1.743   | 0.0816 . |
| NDVI_Aug_log | 21.9634  | 32.3031    | 0.680   | 0.4967   |
| SAVI_Aug_log | -14.9731 | 23.0853    | -0.649  | 0.5168   |
| IAF_Aug_log  | 0.1538   | 0.3909     | 0.394   | 0.6940   |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1250521)

Null deviance: 116.39 on 918 degrees of freedom

Residual deviance: 114.42 on 915 degrees of freedom

AIC: 703.38

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

```

      llh    llhNull      G2    McFadden    r2ML    r2CU
-346.68835737 -354.52060773 15.66450071 0.02209251 0.01690071 0.03143164
>

```

Fev 2019

Call:

```

glm(formula = PDSI_2019_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados19)

```

Coefficients:

```

      Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.3620    0.3535  6.682 4.09e-11 ***
NDVI_Feb_log -39.6394   14.1288 -2.806 0.00513 **
SAVI_Feb_log  28.4132   10.5370  2.697 0.00714 **
IAF_Feb_log  -0.6264    0.1595 -3.927 9.25e-05 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

(Dispersion parameter for gaussian family taken to be 0.1793562)

```

Null deviance: 166.88 on 913 degrees of freedom
Residual deviance: 163.21 on 910 degrees of freedom
AIC: 1029.2

```

Number of Fisher Scoring iterations: 2

```
>
```

```
> pR2(mod2)
```

fitting null model for pseudo-r2

```

      llh    llhNull      G2    McFadden    r2ML    r2CU
-509.60516329 -519.76372886 20.31713115 0.01954458 0.02198357 0.03236073

```

Ago 2019

Call:

```
glm(formula = PDSI_2019_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados19)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t ) |
|--------------|----------|------------|---------|----------|
| (Intercept)  | 0.7396   | 0.5036     | 1.469   | 0.1423   |
| NDVI_Aug_log | 50.6742  | 26.8196    | 1.889   | 0.0591 . |
| SAVI_Aug_log | -35.6046 | 19.5373    | -1.822  | 0.0687 . |
| IAF_Aug_log  | 0.3589   | 0.3889     | 0.923   | 0.3562   |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1748883)

Null deviance: 166.88 on 913 degrees of freedom  
 Residual deviance: 159.15 on 910 degrees of freedom  
 AIC: 1006.2

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -498.07679669 | -519.76372886 | 43.37386434 | 0.04172460 | 0.04634661 | 0.06822413 |

Fev 2020

Call:

```
glm(formula = PDSI_2020_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados20)
```

Coefficients:

|  | Estimate | Std. Error | t value | Pr(> t ) |
|--|----------|------------|---------|----------|
|--|----------|------------|---------|----------|

```
(Intercept)  0.91144  0.40757  2.236  0.0256 *
NDVI_Feb_log -41.38876  21.02049 -1.969  0.0492 *
SAVI_Feb_log  31.18406  15.76796  1.978  0.0483 *
IAF_Feb_log  -0.07349   0.15581 -0.472  0.6373
```

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.130564)

Null deviance: 123.56 on 945 degrees of freedom  
 Residual deviance: 122.99 on 942 degrees of freedom  
 AIC: 764.67

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -3.773349e+02 | -3.794989e+02 | 4.328137e+00 | 5.702436e-03 | 4.564747e-03 | 8.273760e-03 |

Ago 2020

Call:

```
glm(formula = PDSI_2020_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados20)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )     |
|--------------|----------|------------|---------|--------------|
| (Intercept)  | 1.5877   | 0.3233     | 4.912   | 1.06e-06 *** |
| NDVI_Aug_log | -18.1435 | 17.2552    | -1.051  | 0.293        |
| SAVI_Aug_log | 13.6145  | 12.6823    | 1.074   | 0.283        |
| IAF_Aug_log  | -0.2849  | 0.1984     | -1.436  | 0.151        |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1



(Dispersion parameter for gaussian family taken to be 0.1297034)

Null deviance: 123.56 on 945 degrees of freedom  
 Residual deviance: 122.18 on 942 degrees of freedom  
 AIC: 758.41

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -374.20664970 | -379.49893842 | 10.58457744 | 0.01394546 | 0.01112641 | 0.02016700 |

Fev 2021

Call:

```
glm(formula = PDSI_2021_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados21)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )     |
|--------------|----------|------------|---------|--------------|
| (Intercept)  | 1.4906   | 0.3303     | 4.513   | 7.53e-06 *** |
| NDVI_Feb_log | -27.5454 | 14.1663    | -1.944  | 0.0523 .     |
| SAVI_Feb_log | 20.3193  | 10.5347    | 1.929   | 0.0542 .     |
| IAF_Feb_log  | -0.3003  | 0.1485     | -2.023  | 0.0435 *     |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1112281)

Null deviance: 76.544 on 686 degrees of freedom  
 Residual deviance: 75.969 on 683 degrees of freedom  
 AIC: 446.84

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2         | McFadden   | r2ML       | r2CU       |
|---------------|---------------|------------|------------|------------|------------|
| -218.41978517 | -221.00913650 | 5.17870267 | 0.01171604 | 0.00750980 | 0.01582679 |

Ago 2021

Call:

```
glm(formula = PDSI_2021_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados21)
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )     |
|--------------|----------|------------|---------|--------------|
| (Intercept)  | 2.2771   | 0.5767     | 3.949   | 8.67e-05 *** |
| NDVI_Aug_log | -66.9299 | 29.0378    | -2.305  | 0.0215 *     |
| SAVI_Aug_log | 47.4557  | 20.8920    | 2.271   | 0.0234 *     |
| IAF_Aug_log  | -1.1507  | 0.4924     | -2.337  | 0.0197 *     |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1109783)

Null deviance: 76.544 on 686 degrees of freedom  
 Residual deviance: 75.798 on 683 degrees of freedom  
 AIC: 445.3

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2           | McFadden     | r2ML         | r2CU         |
|---------------|---------------|--------------|--------------|--------------|--------------|
| -2.176476e+02 | -2.210091e+02 | 6.723172e+00 | 1.521017e-02 | 9.738547e-03 | 2.052384e-02 |

Fev 2022

```
glm(formula = PDSI_2022_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados22)
```

Coefficients:

|              | Estimate  | Std. Error | t value | Pr(> t )     |
|--------------|-----------|------------|---------|--------------|
| (Intercept)  | 1.77878   | 0.32551    | 5.465   | 5.86e-08 *** |
| NDVI_Feb_log | 68.80863  | 13.63544   | 5.046   | 5.35e-07 *** |
| SAVI_Feb_log | -50.47820 | 10.16360   | -4.967  | 8.02e-07 *** |
| IAF_Feb_log  | 0.02938   | 0.13591    | 0.216   | 0.829        |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.224248)

Null deviance: 241.91 on 999 degrees of freedom  
 Residual deviance: 223.35 on 996 degrees of freedom  
 AIC: 1348.9

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -669.43315199 | -709.34008549 | 79.81386701 | 0.05625924 | 0.07671182 | 0.10120736 |

Ago 2022

Call:

```
glm(formula = PDSI_2022_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados22)
```

Coefficients:

```

      Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.9598    0.5609  5.277 1.61e-07 ***
NDVI_Aug_log -25.5614   22.0507 -1.159  0.2466
SAVI_Aug_log  17.1462   16.1763  1.060  0.2894
IAF_Aug_log  -0.7830    0.3215 -2.435  0.0151 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

(Dispersion parameter for gaussian family taken to be 0.2388549)

```

Null deviance: 241.91 on 999 degrees of freedom
Residual deviance: 237.90 on 996 degrees of freedom
AIC: 1412

```

Number of Fisher Scoring iterations: 2

```

>
> pR2(mod)
fitting null model for pseudo-r2
      llh    llhNull      G2    McFadden    r2ML    r2CU
-700.98499385 -709.34008549 16.71018328  0.01177868  0.01657134  0.02186289

```

Fev 2023

Call:

```

glm(formula = PDSI_2023_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log,
     family = gaussian(link = "identity"), data = dados23)

```

Coefficients:

```

      Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.43795    0.32375  4.442 9.74e-06 ***
NDVI_Feb_log 21.64818    9.90372  2.186  0.0290 *
SAVI_Feb_log -15.80791    7.47702 -2.114  0.0347 *

```

IAF\_Feb\_log 0.02539 0.12689 0.200 0.8414

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1135416)

Null deviance: 141.29 on 1219 degrees of freedom

Residual deviance: 138.07 on 1216 degrees of freedom

AIC: 813.99

Number of Fisher Scoring iterations: 2

>

> pR2(mod2)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |
|---------------|---------------|-------------|------------|------------|------------|
| -401.99438451 | -416.07459917 | 28.16042933 | 0.03384060 | 0.02281796 | 0.04614905 |

>

Ago 2023

Call:

```
glm(formula = PDSI_2023_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log,
     family = gaussian(link = "identity"), data = dados23)
```

Coefficients:

Estimate Std. Error t value Pr(>|t|)

(Intercept) 2.7940 0.4259 6.560 7.94e-11 \*\*\*

NDVI\_Aug\_log 24.5477 17.2996 1.419 0.1562

SAVI\_Aug\_log -19.0528 12.8219 -1.486 0.1375

IAF\_Aug\_log -0.4524 0.2424 -1.866 0.0622 .

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 0.1149766)

Null deviance: 141.29 on 1219 degrees of freedom  
 Residual deviance: 139.81 on 1216 degrees of freedom  
 AIC: 829.31

Number of Fisher Scoring iterations: 2

>

> pR2(mod)

fitting null model for pseudo-r2

| llh           | llhNull       | G2          | McFadden   | r2ML       | r2CU       |  |
|---------------|---------------|-------------|------------|------------|------------|--|
| -409.65566254 | -416.07459917 | 12.83787327 | 0.01542737 | 0.01046768 | 0.02117075 |  |

## APÊNDICE E – SCRIPT DE PROCESSAMENTO DA REGRESSÃO RIDGE

```
# Instalar pacotes necessários
if (!require(glmnet)) install.packages("glmnet")
if (!require(car)) install.packages("car")

# Ler o arquivo CSV
dados14 = X2014
dados14$PDSI_2014_log = log(dados14$PDSI_2014 + abs(min(dados14$PDSI_2014)) + 1)
dados14$NDVI_Aug_log = log(dados14$NDVI_Aug + abs(min(dados14$NDVI_Aug)) + 1)
dados14$SAVI_Aug_log = log(dados14$SAVI_Aug + abs(min(dados14$SAVI_Aug)) + 1)
dados14$IAF_Aug_log = log(dados14$IAF_Aug + abs(min(dados14$IAF_Aug)) + 1)
dados14$NDVI_Feb_log = log(dados14$NDVI_Feb + abs(min(dados14$NDVI_Feb)) + 1)
dados14$SAVI_Feb_log = log(dados14$SAVI_Feb + abs(min(dados14$SAVI_Feb)) + 1)
dados14$IAF_Feb_log = log(dados14$IAF_Feb + abs(min(dados14$IAF_Feb)) + 1)

# Verificar a estrutura dos dados
View(dados14)
glimpse(dados14)

# Separar variáveis preditoras (X) e resposta (y)
X <- as.matrix(dados14[, c("NDVI_Feb_log", "SAVI_Feb_log", "IAF_Feb_log")])
y <- dados14$PDSI_2014_log

# Dividir os dados em treino e teste (opcional)
set.seed(123)
train_idx <- sample(1:nrow(X), 0.7 * nrow(X))
X_train <- X[train_idx, ]
y_train <- y[train_idx]
X_test <- X[-train_idx, ]
y_test <- y[-train_idx]

# Ajustar modelo Ridge
ridge_mod <- glmnet(X_train, y_train, alpha = 0) # alpha = 0 para Ridge
```

```

plot(ridge_mod, xvar = "lambda", label = TRUE)
cv_ridge <- cv.glmnet(X_train, y_train, alpha = 0)
best_lambda_ridge <- cv_ridge$lambda.min
print(paste("Melhor lambda (Ridge):", best_lambda_ridge))

# Prever com os modelos ajustados
ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)

# Avaliar os modelos (R² e RMSE)
ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))

print(paste("R² Ridge:", ridge_r2))
print(paste("RMSE Ridge:", ridge_rmse))

# Pacote necessário
library(car)

# Ajustar um modelo linear simples para calcular o VIF
mod_vif <- lm(PDSI_2014_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados14)

# Calcular o VIF
vif_values <- vif(mod_vif)

# Exibir os valores de VIF
print("Valores de VIF:")
print(vif_values)

```



## APÊNDICE F – RESULTADOS DA REGRESSÃO RIDGE E RMSE

Ago 2013

```
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.109681458443026"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0804399961610041"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.246394962428329"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2013_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados13)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
```

```

> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
5018.612167 4945.461392 2.364469

Fev 2014
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.146451836537615"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0100593823181242"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.264269451396773"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2014_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados14)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF

```

```
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
2382.626293 2332.671410 2.486183
```

Ago 2014

```
print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.0108442387110993"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0469196452769672"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.259302766383967"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2014_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados14)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
```

```

>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
6445.934701 6179.321927 7.572405

>

Fev 2015
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.0301237173069586"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0197368121542437"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.447789085785768"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF

```

```

> mod_vif <- lm(PDSI_2015_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados15)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
7046.004068 6917.380538 3.250837

```

Ago 2015

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.11316296738716"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0202694587172139"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.447667411459145"
>
>
> # Pacote necessário

```

```

> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2015_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados15)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
8465.085778 8223.908170 5.410703

```

Fev 2016

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.0112456443972991"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.00076517230618911"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.314657010813664"

```

```

>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2016_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados16)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
4548.951591 4511.194315 1.774508

```

Ago 2016

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 11.3192846712334"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))

```

```

[1] "R² Ridge: -0.00352944927001086"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.31533246961747"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2016_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados16)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
4947.065421 4861.507270 2.724022

```

Fev 2017

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.369644809643184"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))

```



```

>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: -0.0103660202717453"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.321767166942083"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2017_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados17)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
4161.044900 4067.057385 3.333648

```

Ago 2017

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 9.63992368892109"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)

```

```

> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: -1.32823022735984e-05"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.320114425099323"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2017_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados17)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
10530.81564  9973.72416   14.42045

Fev 2018
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.137396020091387"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>

```

```

>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0279549817087792"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.367408522326389"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2018_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados18)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
3367.374123 3300.322183 2.755304

Ago 2018
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.14399983353634"
>
>
> # Prever com os modelos ajustados

```

```

> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0157686859289601"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.369704405365848"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2018_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados18)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
13345.700555 12875.233671 9.542493

```

Fev 2019

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.013653181249558"

```

```

>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: -0.035834219322467"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.450331739143515"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2019_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados19)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
2528.240635 2448.379615 3.439113

```

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.107777954667628"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0440512223814422"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.432618155122012"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2019_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados19)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
6358.344058 6061.353615 8.952143

```

Fev 2020

```
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 4.46034514620633"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: -0.000670151972998578"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.366708333364347"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2020_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados20)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
```

NDVI\_Feb\_log SAVI\_Feb\_log IAF\_Feb\_log

9305.990452 9193.410561 2.681946

Ago 2020

```
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
```

```
[1] "Melhor lambda (Ridge): 0.137419758919668"
```

```
>
```

```
>
```

```
> # Prever com os modelos ajustados
```

```
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
```

```
>
```

```
>
```

```
> # Avaliar os modelos (R² e RMSE)
```

```
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
```

```
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
```

```
>
```

```
> print(paste("R² Ridge:", ridge_r2))
```

```
[1] "R² Ridge: -0.00489164507006068"
```

```
> print(paste("RMSE Ridge:", ridge_rmse))
```

```
[1] "RMSE Ridge: 0.367481029265281"
```

```
>
```

```
>
```

```
> # Pacote necessário
```

```
> library(car)
```

```
>
```

```
> # Ajustar um modelo linear simples para calcular o VIF
```

```
> mod_vif <- lm(PDSI_2020_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data = dados20)
```

```
>
```

```
> # Calcular o VIF
```

```
> vif_values <- vif(mod_vif)
```

```
>
```

```
> # Exibir os valores de VIF
```

```
> print("Valores de VIF:")
```



```
[1] "Valores de VIF:"
```

```
> print(vif_values)
```

```
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
```

```
5126.544304 4970.695867 4.712918
```

```
Fev 2021
```

```
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
```

```
[1] "Melhor lambda (Ridge): 0.0292876331374315"
```

```
>
```

```
>
```

```
> # Prever com os modelos ajustados
```

```
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
```

```
>
```

```
>
```

```
> # Avaliar os modelos (R² e RMSE)
```

```
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
```

```
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
```

```
>
```

```
> print(paste("R² Ridge:", ridge_r2))
```

```
[1] "R² Ridge: -0.018695143476114"
```

```
> print(paste("RMSE Ridge:", ridge_rmse))
```

```
[1] "RMSE Ridge: 0.306010385742368"
```

```
>
```

```
>
```

```
> # Pacote necessário
```

```
> library(car)
```

```
>
```

```
> # Ajustar um modelo linear simples para calcular o VIF
```

```
> mod_vif <- lm(PDSI_2021_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =  
dados21)
```

```
>
```

```
> # Calcular o VIF
```

```
> vif_values <- vif(mod_vif)
```

```

>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
4271.177556 4180.084439 3.099927

Ago 2021
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.00944211376012023"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: -0.0305909689026411"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.307791919941506"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2021_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados21)
>

```

```

> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
  7074.82481  6648.92627   13.68632
Fev 2022
> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.137350017391582"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.023403654567251"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.502503520938479"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2022_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados22)

```

```

>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
3087.642518 3023.816340 2.600209

```

Ago 2022

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.0698961860398295"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0186087071082801"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.503735620404632"
>
>
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF

```

```

> mod_vif <- lm(PDSI_2022_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados22)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
3396.325580 3304.314295 3.395071

```

Fev 2023

```

> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.37007153946952"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: 0.0138362665477264"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.332931484742192"
>
>
> # Pacote necessário
> library(car)

```

```

>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2023_log ~ NDVI_Feb_log + SAVI_Feb_log + IAF_Feb_log, data =
dados23)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Feb_log SAVI_Feb_log IAF_Feb_log
2813.128479 2752.184598 2.743706

```

Ago 2023

```


> print(paste("Melhor lambda (Ridge):", best_lambda_ridge))
[1] "Melhor lambda (Ridge): 0.0942035456261196"
>
>
> # Prever com os modelos ajustados
> ridge_pred <- predict(ridge_mod, s = best_lambda_ridge, newx = X_test)
>
>
> # Avaliar os modelos (R² e RMSE)
> ridge_r2 <- 1 - sum((y_test - ridge_pred)^2) / sum((y_test - mean(y_test))^2)
> ridge_rmse <- sqrt(mean((y_test - ridge_pred)^2))
>
> print(paste("R² Ridge:", ridge_r2))
[1] "R² Ridge: -0.00834728384477379"
> print(paste("RMSE Ridge:", ridge_rmse))
[1] "RMSE Ridge: 0.336655272388219"
>
>

```







```
> # Pacote necessário
> library(car)
>
> # Ajustar um modelo linear simples para calcular o VIF
> mod_vif <- lm(PDSI_2023_log ~ NDVI_Aug_log + SAVI_Aug_log + IAF_Aug_log, data
= dados23)
>
> # Calcular o VIF
> vif_values <- vif(mod_vif)
>
> # Exibir os valores de VIF
> print("Valores de VIF:")
[1] "Valores de VIF:"
> print(vif_values)
NDVI_Aug_log SAVI_Aug_log IAF_Aug_log
5219.23000 5098.95448 3.75105
```







## APÊNDICE G – RESULTADOS Q-Q PLOTS




Sem Transformação Logarítmica











### Com Transformação Logarítmica

