

**UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CAMPUS JABOTICABAL**

**MODELOS AGROMETEOROLÓGICOS-ESPECTRAIS BASEADOS EM
INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DE CERCOSPORIOSE NO
CAFEEIRO**

Gislaine Ferreira Barbosa

Jaboticabal - SP

**UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CÂMPUS DE JABOTICABAL**

**MODELOS AGROMETEOROLÓGICOS-ESPECTRAIS BASEADOS EM
INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DE CERCOSPORIOSE NO
CAFEEIRO**

Gislaine Ferreira Barbosa

Orientador: Prof. Dr. Glauco de Souza Rolim

Trabalho apresentado à Faculdade de Ciências
Agrárias e Veterinárias – UNESP, Câmpus de
Jaboticabal, para a Graduação em ENGENHARIA
AGRONÔMICA

Jaboticabal

1º Semestre/2023

B238m Barbosa, Gislaine Ferreira
Modelos agrometeorológicos-espectrais baseados em inteligência artificial para estimativa de cercosporiose no cafeeiro / Gislaine Ferreira Barbosa. -- Jaboticabal, 2023
47 f. : il., tabs.

Trabalho de conclusão de curso (Bacharelado - Engenharia Agrônômica) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Glauco de Souza Rolim

1. inteligência artificial. 2. epidemiologia. 3. python. 4. café. 5. cercosporiose. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

DEPARTAMENTO: Engenharia e Ciências Exatas.

CERTIFICADO DE APROVAÇÃO TRABALHO DE INICIAÇÃO CIENTÍFICA

TÍTULO: **MODELOS AGROMETEOROLÓGICOS-ESPECTRAIS BASEADOS EM INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DE CERCOSPORIOSE NO CAFEIEIRO.**

ACADÊMICA: Gislaine Ferreira Barbosa

CURSO: Engenharia Agrônômica

ORIENTADOR (ES): Prof. Dr. Glauco de Souza Rolim

Aprovado e corrigido de acordo com as sugestões da Banca Examinadora

BANCA EXAMINADORA:

(Nomes)

(Assinaturas)

Presidente Prof. Dr. Glauco de Souza Rolim

Membro Dr.^a Ligia Negri Corrêa

Membro MSc. Karita Almeida Silva

gov.br

Documento assinado digitalmente
LIGIA NEGRI CORREA
Data: 08/08/2023 10:22:44-0300
Verifique em <https://validar.iti.gov.br>

gov.br

Documento assinado digitalmente
KARITA ALMEIDA SILVA
Data: 21/07/2023 16:00:01-0300
Verifique em <https://validar.iti.gov.br>

Jaboticabal 21 / 7 / 2023.

Aprovado por ato "ad referendum" da presidência do Conselho do Departamento em 2 / 8 / 2023.


Prof. Dr. Danisio Prado Munari
Chefe de Departamento de Ensino

**... E nunca considerem seu estudo como uma obrigação, mas
sim como uma oportunidade invejável de aprender, sobre a
influência libertadora da beleza no domínio do espírito, para
seu prazer pessoal e para o proveito da comunidade à qual
pertencerá o seu trabalho futuro**

Albert Einstein

AGRADECIMENTOS

Agradeço a Deus, por todas as bênçãos derramadas durante a graduação, sempre ter me amparado, me permitindo nunca desistir daquele que até agora foi meu maior sonho.

À minha grande rainha e querida mãe, Dalva Ferreira de Oliveira, por ter sido meu alicerce em todos os momentos do início ao fim, sem a senhora, nada disso teria valor algum.

Aos meus avós maternos, Alda de Oliveira e Idalino Brito e meus irmãos Kailainy Ferreira da Silva e João Vitor Ferreira de Souza pelo amor e amparo.

Ao meu querido Tio Jaelson Brito, por todo amparo, acreditar e torcer pelo meu sucesso.

Ao meu orientador, Glauco de Souza Rolim, pelos ensinamentos, orientação, disponibilidade e amizade durante toda graduação.

A Karita Almeida da Silva, pelo auxílio durante o desenvolvimento do projeto de Iniciação Científica.

A Ligia Negri Corrêa, que tenho como amiga desde o início e teve participação essencial durante minha graduação, me auxiliou diversas vezes durante o decorrer da IC e também me deu conselhos e dividiu comigo suas experiências e conhecimentos.

Aos membros do grupo GAS que de alguma maneira me ajudaram em alguma fase desse projeto.

Aos funcionários do Departamento de Ciências Exatas. Em especial a Secretária Adriana Takakura, pelo apoio e paciência.

A todas moradoras da república Dama de Copos, por terem sido meu lar, acolhedoras, compreensivas e pela amizade durante esses anos. Lugar onde vivi a melhor fase da minha vida.

À Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, pelo auxílio financeiro para desenvolvimento desta pesquisa - 2021/03746-0

E por fim, à Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal. Segunda casa, e lugar em que fiz amizades e recebi ensinamentos que levarei para toda vida, nos âmbitos pessoal e acadêmico.

Meu sincero e singelo, muito obrigada.

SUMÁRIO

RESUMO	viii
ABSTRACT	ix
1 INTRODUÇÃO	10
2 MATERIAL E MÉTODOS	16
2.1 Obtenção de dados meteorológico	16
2.2 Índice de vegetação	19
2.3 Incidência de cercosporiose	20
2.4 Modelos de estimativas	21
2.5 Avaliação do desempenho dos modelos	23
3 RESULTADOS E DISCUSSÃO	24
4 CONCLUSÃO	40
REFERÊNCIAS	41

RESUMO

O café é uma das bebidas mais consumidas e importantes do mundo. As variáveis climáticas influenciam na sua qualidade, produção e incidência de doenças, como a cercosporiose. O objetivo do trabalho é realizar a estimativa da incidência da cercosporiose para as principais regiões produtoras de café do país, a partir de modelos agrometeorológicos-espectrais que possam ser utilizados em sistemas de alertas fitossanitários. Os dados meteorológicos diários de Franca, Araxá, Patrocínio e Araguari, de 2015 a 2020, como temperatura do ar, precipitação, umidade relativa, velocidade do vento e saldo de radiação foram obtidas a partir da plataforma NASA-POWER. Com base nestes dados foi estimado o balanço hídrico sequencial de Thornthwaite-Mather. Dados de NDVI e EVI foram extraídos da plataforma SATveg (Embrapa). Já os dados de incidência de cercosporiose foram obtidos do acompanhamento mensal do sistema da Fundação Procafé. A estimativa da doença foi realizada usando os modelos de Regressão Linear Múltipla (RLM), redes neurais Multilayer perceptron (MLP) e a máquina de aprendizado Random Forest (RF). A incidência real da doença, dados agrometeorológicos, NDVI e EVI foram as variáveis independentes e a incidência foi a variável dependente. Os resultados confirmaram a influência das variáveis climáticas sobre a incidência da cercosporiose no cafeeiro. Os modelos RLM, MLP, RF, obtiveram RMSEs no período de treinamento iguais a, 12,48; 0,49; 8,0 para carga alta, e 10,6; 2,34; 4,22 cargas baixa respectivamente.

Palavras-chave: Inteligência Artificial, Epidemiologia, *Random Forest Regressor*, *Multilayer perceptron*, *Python*.

ABSTRACT

Coffee is one of the most consumed and important beverages in the world. Climatic variables influence its quality, production and incidence of diseases, such as brown eye spot. The objective of this work is to estimate the incidence of brown eye spot for the main coffee producing regions of the country, based on agrometeorological-spectral models that can be used in phytosanitary alert systems. Daily meteorological data for Franca, Araxá, Patrocínio and Araguari, from 2015 to 2020, such as air temperature, precipitation, relative humidity, wind speed and radiation balance were obtained from the NASA-POWER platform. Based on these data, the Thornthwaite-Mather sequential water balance was estimated. NDVI and EVI data were extracted from the SATveg platform (Embrapa). The data on the incidence of brown eye spot disease were obtained from the monthly follow-up of the Procafé Foundation system. Disease estimation was performed using Multiple Linear Regression (MLR) models, Multilayer perceptron (MLP) neural networks, and Random Forest (RF) machine learning. The actual incidence of the disease, agrometeorological data, NDVI and EVI were the independent variables and the incidence was the dependent variable. The results confirmed the influence of climatic variables on the incidence of brown eye spot on coffee plants. The RLM, MLP, RF models obtained RMSEs in the training period equal to, 12.48; 0.49; 8.0 for high load, and 10.6; 2.34; 4.22 loads down respectively.

Keywords: Artificial Intelligence, Epidemiology, Random Forest Regressor, Python

1. INTRODUÇÃO

O café é a bebida mais consumida do planeta e o Brasil é o maior produtor mundial (ZELBER-SAGI et al., 2015). A produção e a qualidade do café são diretamente influenciadas pela incidência de doenças, e estas são influenciadas pelas condições climáticas (HARVEY et al., 2018; ROLIM et al., 2020).

A distribuição pluviométrica é um dos principais elementos que causa interferência na fenologia do cafeeiro e, conseqüentemente, condiciona fatores como intensidade e a severidade das doenças (CAMARGO, 2010). A temperatura do ar regula a taxa de desenvolvimento vegetativo e reprodutivo (HODGES, 1990) e temperaturas entre 5 °C e 30 °C com altos níveis de umidade relativa e molhamento foliar de 42 a 72 horas favorecem o desenvolvimento de doenças fúngicas (SENTELHAS et al., 2008; BERUSKI et al., 2015).

Outros elementos climáticos também interferem no processo infeccioso, tais como o fotoperíodo, o vento, a radiação solar e a chuva, estes que atuam nos processos de disseminação, germinação e penetração de esporos (SENTELHAS et al., 2001).

A detecção e mapeamento de pragas e doenças na agricultura que faz uso do sensoriamento remoto é geralmente baseado em mudanças na resposta espectral da planta devido ao prejuízo estrutural principalmente em suas folhas (MARTINS et al., 2017).

A ação de patógenos em geral sobre o cultivo de café pode causar diversas alterações na reflectância da espécie, afetando algumas bandas como na região visível (VIS), e o infravermelho próximo (NIR), bem como a alteração da densidade do dossel e a área foliar observadas no NIR (MALTHUS; MADEIRA, 1993; WEST et al., 2003). Algumas espécies demonstram um composto característico de pigmentos quando a doença se encontra em estágios de infecção mais elevados e agravados. Em função dessas

manifestações, é possível a detecção baseada em sensores de cultivos infectados como reportado por PETORRELLI et al. (2005) e MAHLEIN (2016).

Existem duas diferentes abordagens para a detecção de doenças de cultivos: sensores de curto alcance, como por exemplo os sensores manuais (MOSHOU et al., 2004; FRANKE et al., 2005) e sistemas de sensores transportados por satélite/aéreos (APARECIDO et al., 2020). Nos últimos anos, pesquisadores têm estudado vários Índices de Vegetação Espectral (Vis) para detectar diferentes doenças vegetais (ZHANG, 2012; HILLNHÜTTER, 2011). Mirik et al. (2006) e Kuckenberg et al. (2009) reportaram a utilização do índice de vegetação por diferença normalizada (NDVI) para analisar a desfolhação, doenças e pragas em cultivos agrícolas. Por exemplo Hansen (1991) estudou com sucesso o efeito da ferrugem amarela na produtividade do trigo, a partir da utilização de índices de vegetação.

Katsuhama et al. (2018) conseguiram identificar áreas em cultivo de café com ferrugem a partir de imagens de NDVI com sucesso, permitindo otimizar o sistema de aplicação de fungicidas.

Dentre as doenças fúngicas que afetam o cultivo do café, destaca-se a cercosporiose. A cercosporiose, mancha de olho pardo ou olho de pomba, é uma doença causada pelo fungo *Cercospora coffeicola* (Berk e Cooke) e é a segunda das principais enfermidades que afetam folhas e frutos do café, atacando de mudas até plantas adultas (LIMA et al., 2012; POZZA et al., 2010). Além de causar perdas significativas na produção de até 30%, também afeta a qualidade da bebida (POZZA et al., 2001).

O fungo é capaz de produzir a toxina cercosporina que é um fator de patogenicidade durante a colonização da doença sobre o vegetal (ALMEIDA et al., 2005; CHEN et al., 2007). Na presença de luz a cercosporina torna-se excitada assumindo

capacidade de interagir e danificar macromoléculas (ANDRADE, 2019). Essa toxina é um fator de virulência que aumenta significativamente a incidência e a severidade da doença (CHEN et al., 2007). Estudos observaram maiores concentrações da toxina a temperaturas entre 22 e 26 °C (SOUZA et al., 2012).

No estudo realizado por Salgado et al. (2007), do progresso da cercosporiose em folhas de diferentes sistemas de cultivo agroflorestais e a pleno sol, os autores relatam que, a radiação solar direta pode ter favorecido a maior incidência da cercosporiose nos cafeeiros. De forma semelhante, há influência determinante do fator ambiental radiação solar na incidência da cercosporiose em folhas do cafeeiro (CUSTODIO, 2010). O fungo da cercosporiose se desenvolve a partir da incidência de luz; assim, mudas mantidas a pleno sol são mais susceptíveis ao patógeno (ZAMBOLIM et al., 2005).

Além disso, o ataque da cercosporiose é agravado em função de estresse nas plantas de café, vários trabalhos indicam que a nutrição deficiente ou desequilibrada tem efeito direto na intensidade de ataque da cercóspora (CARVALHO et al., 2008; POZZA et al., 2001; TALAMINI et al., 2003), portanto, plantas com alta carga pendente, pela sua maior exigência nutricional, são mais atacadas. Muitas vezes as deficiências nutricionais são induzidas por problemas agrometeorológicos, como a deficiência hídrica em períodos críticos. Regiões mais quentes e secas, como as áreas mais expostas ao sol, sofrem maior ataque do fungo (MATIELLO et al., 2010).

A disseminação do fungo ocorre através dos conídios, que são formados, principalmente, à noite e em dias frios e nublados, transportados pelo vento e água da chuva e/ou irrigação; havendo umidade suficiente ocorre germinação dos conídios, penetrando nas folhas através de aberturas naturais na face superior. No caso de infecção de frutos, o patógeno pode atingir as sementes (ZAMBOLIM et al., 2005). As condições

ideais para ocorrência da doença são de elevada umidade relativa e temperaturas entre 10 e 25 °C (JULIATTI et al., 2001).

A doença inicia o ataque nas folhas onde é possível notar o seu aparecimento, as lesões são pequenas, até 1,5 cm, mais ou menos circulares, de coloração marrom a pardo claro, com o centro cinza claro, quase sempre envolvido por um halo amarelado, dando um aspecto de um olho. Por isso, é chamada popularmente de “mancha de olho pardo” ou “olho de pomba” (MESQUITA et al., 2016).

As folhas que sofrem o ataque caem, provocando desfolhas e seca dos ramos. Em frutos, as lesões se iniciam quando ainda estão muito pequenos, e vão aumentando conforme sua granação, permanecendo até seu amadurecimento. São caracterizadas por uma cor marrom-claro a arroxeadas, crescendo no sentido polar do fruto, tendo maior incidência em ramos ponteiros e naqueles mais expostos ao sol (MATIELLO et al., 2010). Nos frutos atacados ainda verdes, ocorre uma maturação forçada da casca ao redor da mancha, com prejuízos na qualidade da bebida, em decorrência de processos fermentativos desenvolvidos. A parte da casca necrosada fica fortemente aderida ao pergaminho, impedindo a sua remoção por ocasião do descascamento, reduzindo a percentagem de café descascado. Pode ocorrer também queda desses frutos (MESQUITA et al., 2016). A estratégia mais utilizada no controle de doenças e pragas é através do uso de agroquímicos como, fungicidas e inseticidas foliares. Porém, alternativas devem ser buscadas a fim de substituir esse método, como o uso da modelagem agrometeorológica que evita a realização indiscriminada de pulverizações, gerando resultados positivos para o ambiente com a diminuição das aplicações e, conseqüentemente, em menor custo com a produção (SENTELHAS et al., 2008).

De forma tradicional a modelagem de cercosporiose, como outras doenças é pelo método de área abaixo da curva de progresso da incidência (AACPI), entretanto os resultados obtidos são diversos, dependendo do tipo de sistema de condução da lavoura (CUSTÓDIO, 2010).

Logo, existe a necessidade de desenvolver modelos que auxiliem o produtor na estimativa da incidência de doenças e que possam melhorar a interpretação do ciclo das mesmas, incorporando fatores clima-solo-vegetal (MALAU et al., 2018; BADNAKHE et al., 2018) e permitindo uma racionalização na aplicação de pulverizações (ROLIM et al., 2008). Uma maneira mais atualizada e com maior veracidade nas informações são os modelos agrometeorológicos, onde a variabilidade de pragas e doenças da cafeicultura em função dos elementos meteorológicos pode ser simulado (ROLIM et al., 2008).

Apesar das tecnologias de monitoramento agrometeorológico serem largamente utilizadas como ferramentas de auxílio à tomada de decisão na agricultura (RAMOS et al. 2016), muitas vezes as fontes de dados meteorológicos para desenvolvimento das mesmas são de difícil acesso. As estações meteorológicas de superfície são mal distribuídas e nem sempre os dados são disponibilizados em tempo real, apresentando um problema em potencial (SILVA, 2015). Uma alternativa para suprir essa carência de dados é a utilização de imagens obtidas por satélites e/ou sistemas meteorológicos globais em grid, como o da NASA-POWER (FRANKENBERG et al., 2011). Ainda são poucos artigos que utilizam esses tipos de dados meteorológicos em relação à modelagem epidemiológica de Cercosporiose em cafeeiros.

Também neste sentido, informações de índices de vegetação por sensoriamento remoto estão sendo utilizados cada vez mais frequentemente para detecção de pragas e doenças, contribuindo para alerta precoce, manejo e controle efetivo de problemas

fitossanitários no cultivo (SANTOS et al., 2019). A associação entre informações meteorológicas de superfície e de respostas espectrais dos cultivos como os índices de vegetação trazem melhorias nas previsões dos modelos, existindo vários exemplos como: para indicadores de crescimento de pastagens (CORRÊA, 2016), na estimativa de produtividade de grãos de arroz (KLERING et al., 2016; LEIVAS et al., 2015) e de soja (MELO et al., 2008) no Rio Grande do Sul, assim como, na estimativa de produtividade de milho em Moçambique (MABILANA et al., 2012).

Contudo poucos trabalhos associam dados meteorológicos e espectrais para a estimativa ou previsão de doenças no cafeeiro e a inacessibilidade às variáveis climáticas correlacionadas ao aparecimento de doenças, tem dificultado o manejo das mesmas (POZZA; ALVES, 2008). Portanto, a utilização de sistemas de alertas fitossanitários por meio de modelos de estimativa de incidência de doenças se torna uma opção economicamente e ambientalmente necessária. Diante do exposto, objetivou-se com o presente trabalho desenvolver um modelo agrometeorológico-espectral para estimar a incidência da cercosporiose na cultura do café para importantes regiões produtoras no Brasil para as regiões do Triângulo Mineiro, Alto Paranaíba e Alta Mogiana, entre 2015 e 2020, que totalizam aproximadamente 6.500.000 ha, utilizando Regressão Linear Múltipla e aprendizagem de máquina pelo modelo de *Random Forest* e por redes neurais *Multilayer Perceptron*.

2. MATERIAL E MÉTODOS

2.1. Obtenção de dados meteorológicos

Dados meteorológicos diários como temperatura média, máxima e mínima do ar, precipitação, umidade relativa, velocidade do vento e saldo de radiação, de 2015 a 2020 ano, foram obtidos a partir da plataforma NASA-POWER (<https://power.larc.nasa.gov/>), abrangendo as regiões do Triângulo Mineiro/Alto Paranaíba - MG e da Alta Mogiana – SP. Sendo analisados os seguintes locais de estudo: Araguari, Araxá, Patrocínio e Franca (Figura 1).

Os dados meteorológicos do programa de pesquisa em Ciências da Terra da NASA são baseados em modelos e informações de satélite que são suficientemente precisos para fornecer dados confiáveis de medições solares e meteorológicas, possuindo a vantagem de fornecer os mesmos para regiões onde as medições de superfície são escassas ou inexistentes. Os elementos meteorológicos são baseados no modelo de assimilação do MERRA-2 e estão disponíveis como meios climatológicos e interanuais e séries temporais diárias. Todos os elementos estão disponíveis em grids de $0,5 \times 0,625^\circ$ (STACKHOUSE et al., 2018).

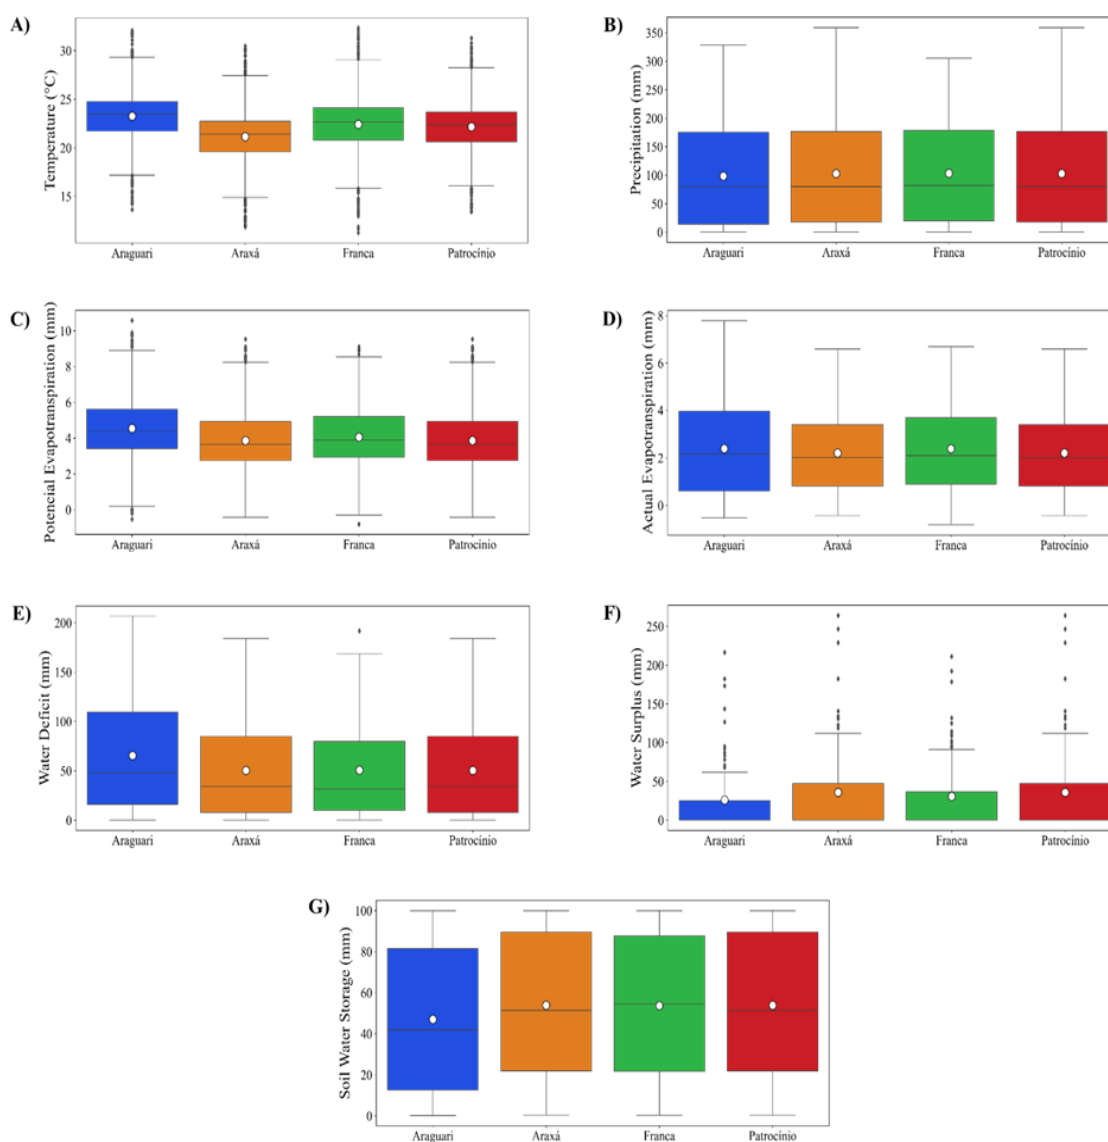


Figura 1. A. Distribuição da Temperatura do Ar, B. Precipitação, C. Evapotranspiração Potencial, D. Evapotranspiração real, E. Armazenamento de Água no Solo, F. Deficiência Hídrica e G. Excedente Hídrico para Franca, Araxá, Patrocínio e Araguari, de 2015 a 2020. Legenda: (— interno) representa o segundo quartil ou mediana; (☐) primeiro e terceiro quartis; (T e ⊥) terceiro e primeiro quartis até os limites superior e inferior; (□) outliers.

A partir dos dados meteorológicos foi realizada a estimativa da evapotranspiração potencial pelo método de Penman-Monteith (FAO) de acordo com a Equação 1 (ALLEN et al., 1998):

$$PET = \frac{0,408\Delta(Rn-G) + \gamma \frac{900}{T+273} U_2 (e_s - e_a)}{\Delta + \gamma(1+0,34U_2)} \quad \text{Eq. (1)}$$

Em que, PET – evapotranspiração potencial (mm dia^{-1}), Rn – saldo de radiação à superfície do cultivo ($\text{MJ m}^{-2} \text{dia}^{-1}$), G – densidade do fluxo de calor do solo ($\text{MJ m}^{-2} \text{dia}^{-1}$), T – temperatura do ar a 2 m de altura ($^{\circ}\text{C}$), U_2 – velocidade de vento a 2 m de altura (m s^{-1}), e_s – pressão de vapor de saturação (kPa), e_a – pressão parcial de vapor (kPa), Δ – declividade da curva de pressão de vapor de saturação (kPa), γ – coeficiente psicrométrico ($\text{kPa } ^{\circ}\text{C}^{-1}$).

Os valores de evapotranspiração real (AET, mm), armazenamento de água no solo (STO, mm), deficiência hídrica (DEF, mm) e excedente hídrico (SUR, mm) foram estimados pelo modelo sequencial de balanço hídrico desenvolvido por Thornthwaite; Mather (1955) (Figura 2) utilizando uma capacidade solo/água disponível de 100 mm, pois este valor representa a maioria dos solos nas regiões cafeeiras brasileiras, conforme relatado por Meireles et al. (2009).

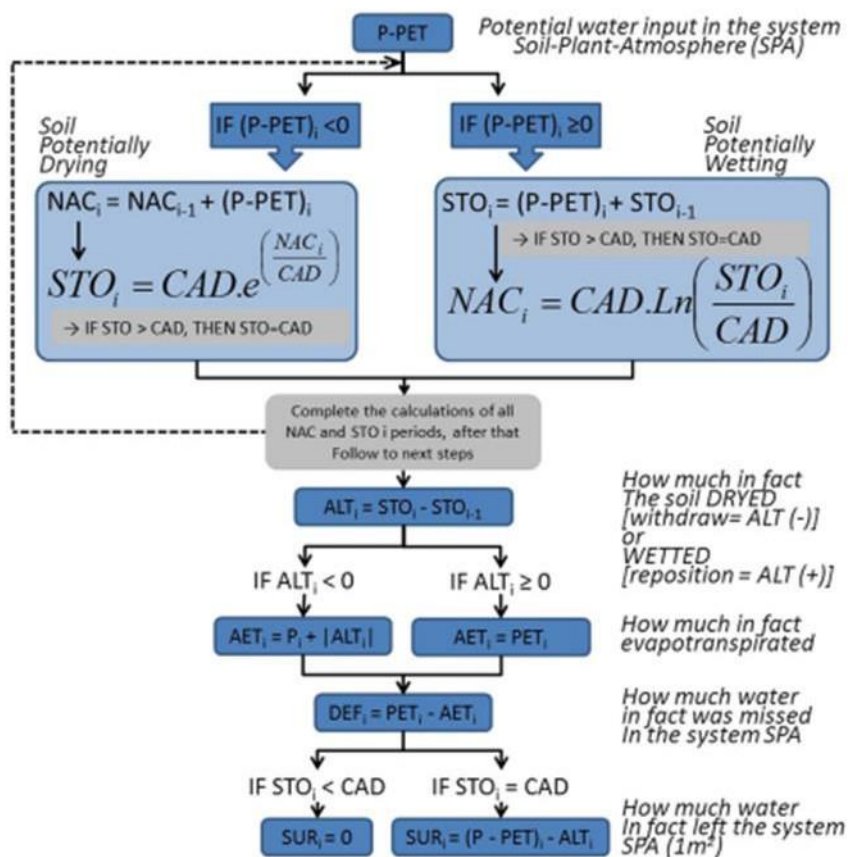


Figura 2. Fluxograma do modelo de balanço hídrico modificado de Thornthwaite; Mather (1955). Adaptado de Rolim et al. (2020).

2.2. Índice de vegetação

Os dados do índice de vegetação com diferença normalizada (NDVI, Equação 2) e o índice de vegetação melhorado (EVI, Equação 3) foram extraídos da plataforma SATveg (Sistema de Análise Temporal da Vegetação) (satveg.cnptia.embrapa.br) que é uma ferramenta *web* desenvolvida pela Embrapa Informática Agropecuária, destinada ao acesso e visualização de perfis temporais do índice vegetativo de NDVI e EVI do sensor MODIS em qualquer local da América do Sul. Em cada região foram selecionados 10

polígonos em áreas conhecidamente de café. Foram calculadas médias de NDVI e EVI como representativas de cada região.

Os dados são disponibilizados a cada 16 dias a partir do satélite TERRA.

$$NDVI = \frac{NIR-Red}{NIR+Red} \quad \text{Eq. (2)}$$

Em que, *NIR* é a reflectância no comprimento de onda infravermelho próximo, *Red* é a reflectância média do vermelho.

$$EVI = G \times \frac{NIR-Red}{NIR+C1 \times Red - C2 \times Blue + L} \quad \text{Eq. (3)}$$

Em que, *Blue* é a reflectância no comprimento de onda médio no azul, *C1*, *C2*, *L* e *G* são coeficientes de ajuste relacionados à quantidade de aerossóis iguais a 6, 7.5, 1 e 2.5, respectivamente.

2.3. Incidência de cercosporiose

Os dados da cercosporiose obtidos se referem ao acompanhamento mensal em campo da incidência das doenças do sistema da Fundação Procafé (<http://fundacaoprocafe.com.br/>), no período de 2015 a 2020. Das oito lavouras de café em produção, com idade entre 6 a 20 anos, foram escolhidas duas lavouras com alta carga pendente de frutos (acima de 30 sacas beneficiadas por hectare) e duas com baixa carga (abaixo de 10 sacas beneficiadas por hectare). Não houve controle da doença durante o ano agrícola nos talhões escolhidos. Obtivemos ainda valores de N° Nós/Ramos e % Enfolhamento.

As plantas foram escolhidas aleatoriamente em um padrão de zigzag na área, conforme recomendado por Chalfoun (1997). A incidência da doença foi determinada para as folhas do terceiro ou quarto nó de ramos no terço médio das plantas. Para tanto, primeiramente fez-se a amostra de 20 plantas por talhão; escolheu-se cinco ramos laterais

aleatoriamente em cada lado da planta; foi feita a remoção de uma folha completamente desenvolvida, do 3º ou 4º par de folhas, de cada ramo; coletou-se, portanto, um total de 10 folhas/planta (cinco de cada lado). Então, os escores de incidência foram determinados para um total de 200 folhas/talhão, do terceiro ou quarto nó de galhos no terço médio das plantas.

Para quantificar o nível de severidade da doença (Severity%), foi utilizada a equação 4. Os dados de Severity% são separados no sistema da Procafé em áreas com alta (carga alta) e baixa (carga baixa) produtividade, decorrente de diferentes tratos culturais aplicados na região e da bienalidade da produção.

$$Severity (\%) = \left[\frac{\text{(number of leaves with } Cercospora)}{\text{total number of leaves}} \right] \cdot 100 \quad \text{Eq. (4)}$$

2.4. Modelos de estimativas

Para estimativa da cercosporiose foram utilizados tanto os dados de incidência de doença quanto os dados meteorológicos obtidos através da Fundação Procafé e os dados dos índices de vegetação (NDVI e EVI) obtidos pela plataforma SATveg. A estimativa da doença será realizada utilizando os modelos de *Regressão Linear Múltipla* (RLM) a máquina de aprendizado por florestas aleatórias *Random Forest* (RF) e as redes neurais *Multilayer Perceptron* (MLP).

Os dados meteorológicos diários, o NDVI e o EVI serão considerados como variáveis independentes (*features*) e a incidência observada como variável dependente (*target*) (Figura 3) para todos os modelos testados. Será considerado o período de incubação da doença para a definição das variáveis de entrada em 16 dias (FERNANDES, 1988; FERNANDES et al., 1991).

Os valores de NDVI2 e EVI2 são referentes aos dados espectrais do mesmo mês dos dados meteorológicos, sendo utilizados os dados mais próximos às datas utilizadas. Já os dados de NDVI1 e EVI1 são referentes aos dados espectrais anteriores aos dados do NDVI2 e EVI2.”

Input Data (Features, or independent data (Xs))																	Target (Y)	
		Days before the quantification of Cercosporiosis in the field																
Previous data	Given within the period of 16 days	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	
NDVI1	NDVI2	Tmean1	Tmean2	Tmean3	Tmean4	Tmean5	Tmean6	Tmean7	Tmean8	Tmean9	Tmean10	Tmean11	Tmean12	Tmean13	Tmean14	Tmean15	Tmean16	Severity level (%)
EVI1	EVI2	Tmin1	Tmin2	Tmin3	Tmin4	Tmin5	Tmin6	Tmin7	Tmin8	Tmin9	Tmin10	Tmin11	Tmin12	Tmin13	Tmin14	Tmin15	Tmin16	
		Tmax1	Tmax2	Tmax3	Tmax4	Tmax5	Tmax6	Tmax7	Tmax8	Tmax9	Tmax10	Tmax11	Tmax12	Tmax13	Tmax14	Tmax15	Tmax16	
		P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14	P15	P16	
		RU1	RU2	RU3	RU4	RU5	RU6	RU7	RU8	RU9	RU10	RU11	RU12	RU13	RU14	RU15	RU16	
		u1	u2	u3	u4	u5	u6	u7	u8	u9	u10	u11	u12	u13	u14	u15	u16	
		Rn1	Rn2	Rn3	Rn4	Rn5	Rn6	Rn7	Rn8	Rn9	Rn10	Rn11	Rn12	Rn13	Rn14	Rn15	Rn16	
		PET1	PET2	PET3	PET4	PET5	PET6	PET7	PET8	PET9	PET10	PET11	PET12	PET13	PET14	PET15	PET16	
		AET1	AET2	AET3	AET4	AET5	AET6	AET7	AET8	AET9	AET10	AET11	AET12	AET13	AET14	AET15	AET16	
		STO1	STO2	STO3	STO4	STO5	STO6	STO7	STO8	STO9	STO10	STO11	STO12	STO13	STO14	STO15	STO16	
		DEF1	DEF2	DEF3	DEF4	DEF5	DEF6	DEF7	DEF8	DEF9	DEF10	DEF11	DEF12	DEF13	DEF14	DEF15	DEF16	
		SUR1	SUR2	SUR3	SUR4	SUR5	SUR6	SUR7	SUR8	SUR9	SUR10	SUR11	SUR12	SUR13	SUR14	SUR15	SUR16	

Figura 3. Esquema de identificação das variáveis de entrada (*Features*) e saída (*Target* ou dependente) nos modelos de regressão linear múltipla, *Random Forest Regressor* e

MLP a serem testados. Simbologia: (Tmean) temperatura diária do ar; (Tmin) temperatura mínima diária; (Tmax) temperatura máxima diária; (P) Precipitação; (RU) Umidade Relativa do Ar; (u) Velocidade do Vento; (Rn) Saldo de radiação à superfície do cultivo, (PET) Evapotranspiração potencial; (AET) Evapotranspiração real; (STO) Armazenamento de água no solo; (DEF) Deficiência hídrica; (SUR) Excedente hídrico; (NDVI) Índice de Vegetação da Diferença Normalizada, (EVI) Índice de Vegetação Melhorado, os números significam os dias anteriores a avaliação de cercospora no campo.

Primeiramente foi feita uma correlação de Spearman entre todas as *features* e Severity% para avaliação do grau de importância de cada elemento meteorológico e em qual momento em relação a severidade de cercospora nas regiões analisadas. A correlação de Spearman foi escolhida por não ter nenhum pressuposto de normalidade dos dados.

Visando uma redução dos dados de entrada para colaborar na redução de ‘*overfitting*’ dos modelos, a seleção de variáveis será feita pelo método de *stepwise*

backwards a partir de valores significativos dos pesos das variáveis. As variáveis selecionadas serão utilizadas para todos modelos.

2.5. Avaliação do desempenho dos modelos

Para estabelecer a precisão, tendência e acurácia dos modelos de Regressão Linear Múltipla e *Random Forest* aplicados à estimativa da cercosporiose, os dados na fase de teste serão comparados usando métricas de desempenho estatístico. Serão utilizados o coeficiente de determinação ajustado (R^2 ajustado), erro do quadrado médio (RMSE) e erro absoluto percentual médio (MAPE) (Eqs. 5-7):

$$R^2 \text{ ajustado} = 1 - \left[\frac{(1-R^2)(n-1)}{n-k-1} \right] \quad \text{Eq. (5)}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_m - Y_p)_i^2} \quad \text{Eq. (6)}$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N |Y_m - Y_p|_i \quad \text{Eq. (7)}$$

Todas as análises foram realizadas utilizando a linguagem Python 3.9.7 (van ROSSUM; DRAKE, 1995). Para a organização do banco de dados foi utilizada a biblioteca *Pandas* (McKINNEY et al., 2010), cálculos numéricos a biblioteca *Numpy* (HARRIS et al., 2020), para o processo de seleção de variáveis e regressão linear múltipla a biblioteca *Statsmodels* (SEABOLD; PERKTOLD, 2010) e para a modelos de *Machine Learning* a biblioteca *Scikit-Learn* (PEDREGOSA et al., 2011).

3. RESULTADOS E DISCUSSÃO

Houve uma certa uniformidade das condições climáticas durante o cultivo de café entre as localidades e os anos estudados (Figura 4), esse resultado é esperado já que as localidades pertencem a uma mesma região. O ano que apresentou maior variabilidade de temperatura do ar entre as regiões foi 2015, e o menor foi em 2018. Os maiores índices de precipitação ocorreram em 2019. A importância de se analisar o comportamento das variáveis meteorológicas se deve ao fato de que o ritmo da disponibilidade de energia e de água de uma região determina o seu potencial produtivo, de modo que a radiação global, a temperatura, e a umidade podem ser consideradas condicionantes meteorológicos que afetam não apenas o desenvolvimento e crescimento dos vegetais, mas também o desenvolvimento de microrganismos que favorecem à incidência de doenças nos cultivos (SENTELHAS et al., 2001).

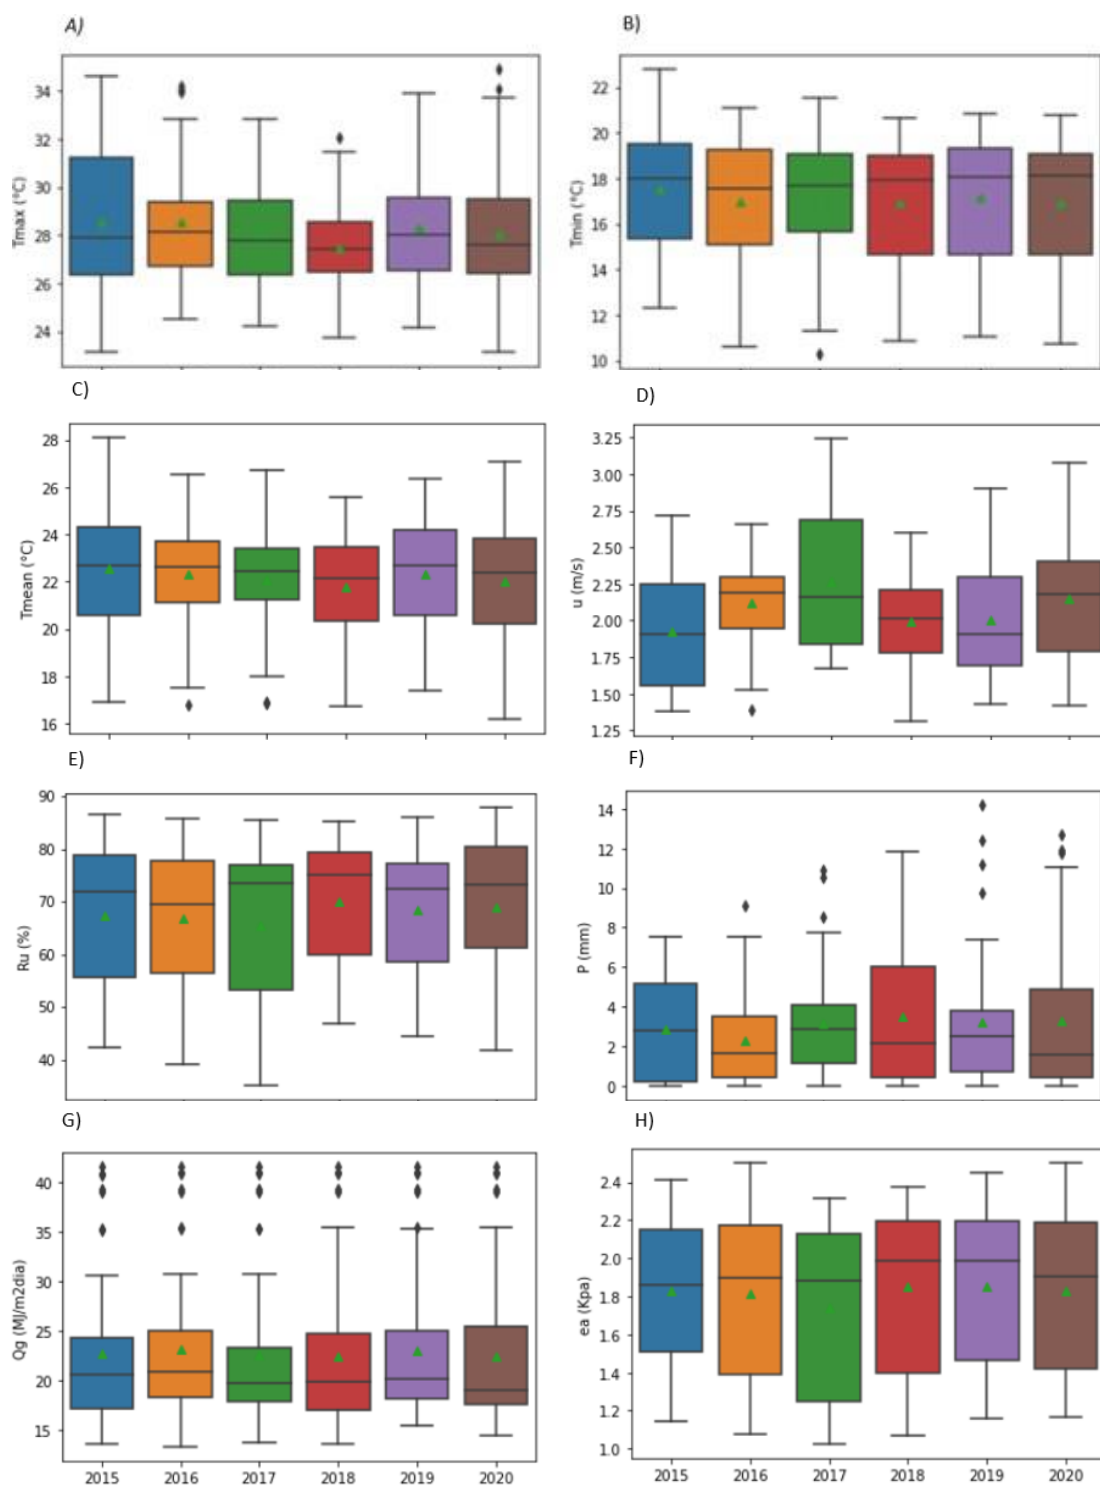


Figura 4. Os eixos Y correspondem as Médias de: A) Temperatura máxima do ar (°C), B) Temperatura mínima do ar (°C), C) Temperatura média do ar (°C), D) Velocidade do Vento ($m s^{-1}$), E) Umidade Relativa (%), F) Precipitação (mm), G) Radiação Global (cal/cm^2), H) Pressão parcial de vapor (kPa) e o eixo X corresponde aos anos. Legenda:

(— interno) representa o segundo quartil ou mediana; (☐) primeiro e terceiro quartis; (T e ⊥) terceiro e primeiro quartis até os limites superior e inferior; (◻) outliers.

Dessa forma, foram apresentados os componentes do balanço hídrico (Figura 5), sendo eles os valores de evapotranspiração real (ETR, mm), armazenamento de água no solo (ARM, mm), deficiência hídrica (DEF, mm) e excedente hídrico (EXC, mm), para posterior análise de sua relação com os dados da doença (Figura 6).

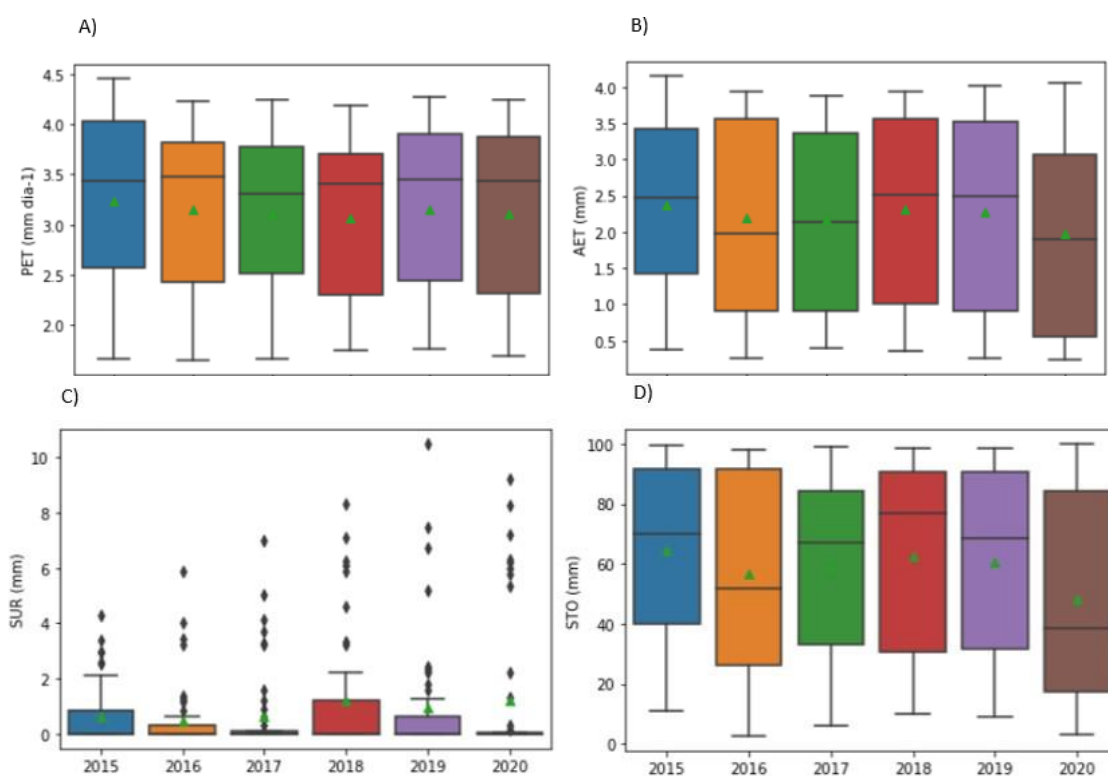


Figura 5. Representação ilustrativa dos resultados médios estimados do Balanço Hídrico, respectivamente: A) ETP – evapotranspiração potencial (mm dia⁻¹), B) ETR - evapotranspiração real (mm), C) EXC - excedente hídrico (mm), D) ARM- armazenamento de água no solo (mm), E) DEF - deficiência hídrica (mm) e F) UA- Umidade Absoluta(mm).

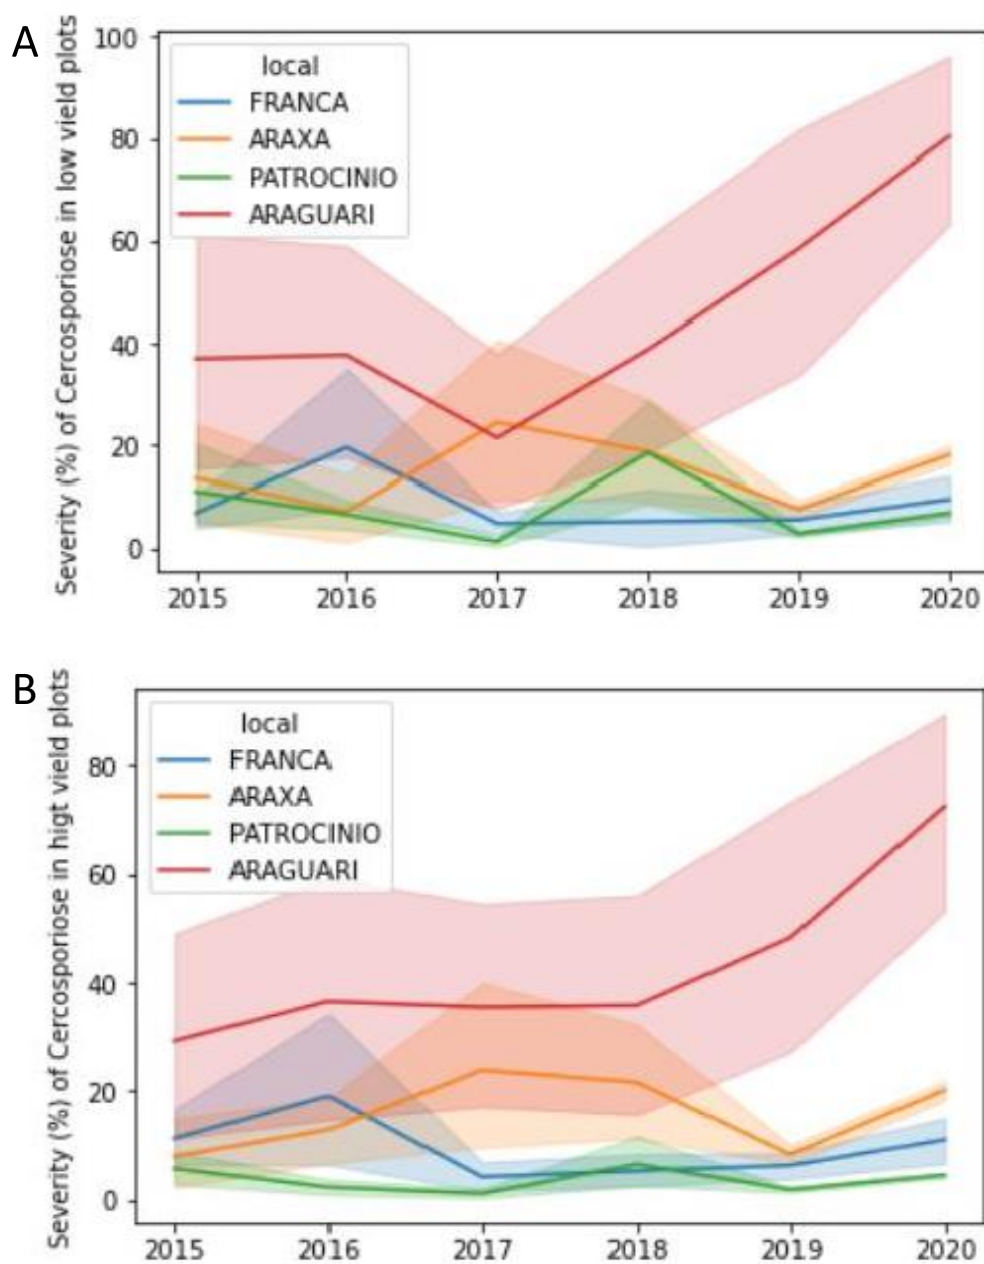


Figura 6. Dados da cercosporiose obtidos no período de 2015 a 2020, nos gráficos vemos uma comparação entre o mesmo período e local, mas com cargas diferentes. A) Carga alta, B) Carga Baixa

Em relação aos índices de vegetação considerados para monitorar a doença nas lavouras de café, os valores médios do índice de vegetação da diferença normalizada

(NDVI) foram maiores do que os valores médios de EVI (Figura 7). De acordo com Risso et al. (2012), o NDVI é mais sensível à presença de pigmentos que participam dos processos fotossintéticos, em particular ao conteúdo de clorofila, e minimiza algumas fontes externas de ruído como, por exemplo a presença de sombras de nuvens. No entanto, devido o NDVI é pouco sensível à detecção de variações de biomassa em condições de elevados índices de área foliar. Nesse sentido, o EVI foi desenvolvido para otimizar o sinal da vegetação, com melhoria na sensibilidade em condições de elevada biomassa. Tanto o EVI quanto o NDVI apresentam potencial para monitorar culturas agrícolas, sendo importante o desenvolvimento de trabalhos considerando esses dois índices de vegetação e analisando comparativamente.




Figura 7. Valores médios de A) EVI (MEVI) e B) NDVI (MNDVI) extraídos da plataforma SATveg (Sistema de Análise Temporal da Vegetação) (satveg.cnptia.embrapa.br).

A severidade de *Cercospora* é maximizada com temperaturas máximas diárias ao redor de 25 °C (ZAMBOLIM et al., 1997) (Figura 8.A) e temperaturas mínimas absolutas entre 5 °C e 10 °C. Temperaturas médias diárias entre 15 °C e 23°C são ótimas para o desenvolvimento de *Cercospora* nas regiões estudadas (Figura 8.C). Irradiância solar

global entre $10 \text{ MJ m}^{-2} \text{ dia}^{-1}$ e $15 \text{ MJ m}^{-2} \text{ dia}^{-1}$, temperaturas mensais médias entre $18 \text{ }^\circ\text{C}$ e $25 \text{ }^\circ\text{C}$ e precipitação média de 3 mm dia^{-1} favorecem a ocorrência da cercosporiose em ambientes controlados (POZZA; ALVES., 2008).

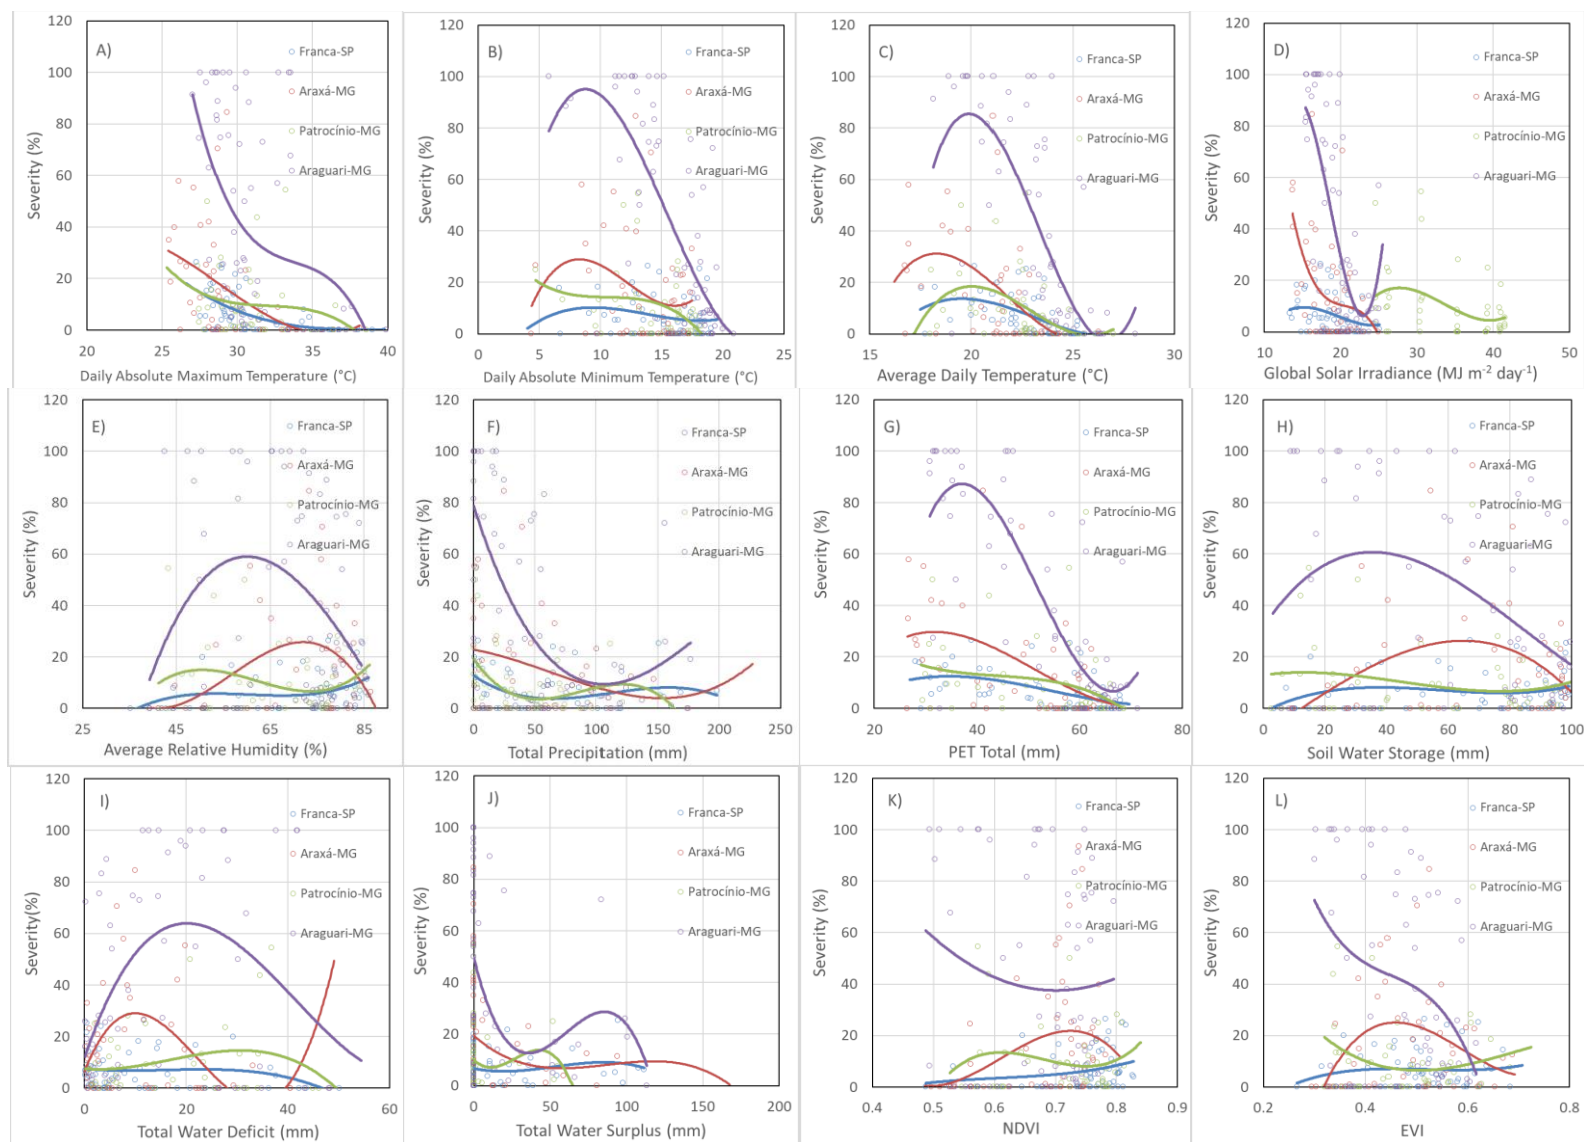


Figura 8. Influência Climática da A) Temperatura máxima absoluta diária (°C) B) Temperatura mínima absoluta diária (°C), C) Irradiância Solar Global ($\text{MJ m}^{-2} \text{ dia}^{-1}$), D) Umidade Relativa Média (%), F) Precipitação total (mm), G) ETP Total (mm), H) Armazenamento de água solo (mm), I) Deficiência Hídrica Total (mm), J) Excedente Hídrico Total (mm), K) NDVI médio e L) EVI médio

Sintetizando as informações da Figura 8 e estabelecendo que um Severity% > 40% pode ser considerado alto, $20 < \text{Severity\%} \leq 40$ considerado médio e Severity% $\leq 20\%$ baixo, podemos classificar a Severity% de cercospora para o cafeeiro, nas regiões estudadas, conforme Figura 9.




Figura 9. Síntese das condições climáticas que afetam a severidade de Cercospora do Cafeeiro

Para as condições de carga alta e baixa, as correlações das variáveis climáticas e os índices de vegetação com o nível de severidade da cercospora foram diversas. Isso demonstra a complexidade do sistema café-cercospora-ambiente como já comentado por Souza et al. (2013) que trabalharam com a doença no sul de Minas Gerais.

As variáveis mais importantes correlacionadas com o nível de doença durante 16 dias antes da avaliação de *Cercóspora* no campo foram, evapotranspiração potencial (ETP, mm dia⁻¹) ($\rho \approx -0.35$), temperatura média do ar (T, °C) ($\rho \approx -0.3$), temperatura máxima do ar (°C) ($\rho \approx -0.2$) e temperatura mínima (°C) ($\rho \approx -0.2$), tanto para carga alta como baixa (Figura 10). Os índices de vegetação apresentaram diferenciações para carga alta e baixa, as correlações de NDVI foram preponderantemente positivas entre os dias 1 e 10 para carga alta (Figura 10.A), enquanto que, o EVI foi negativo para o mesmo período.

Esperava-se que a evapotranspiração potencial tivesse uma relação direta com a doença, pois quando os estômatos abrissem para perder água eles também serviriam para a entrada da infecção por *Cercospora*. Entretanto, como a evapotranspiração potencial é uma função direta da temperatura média, mínima e máxima do ar e esta última apresentou correlações negativas com a doença, a evapotranspiração também foi negativa. Sabe-se que a faixa de temperatura favorável para a *Cercospora* é entre 18 °C e 25 °C, sendo ótima quando igual a 24 °C (SANTOS et al., 2008, MORAES et al., 2012). Dessa forma, como as temperaturas médias e máximas do ar foram frequentemente acima desses valores a doença foi desfavorecida (Figura 10).

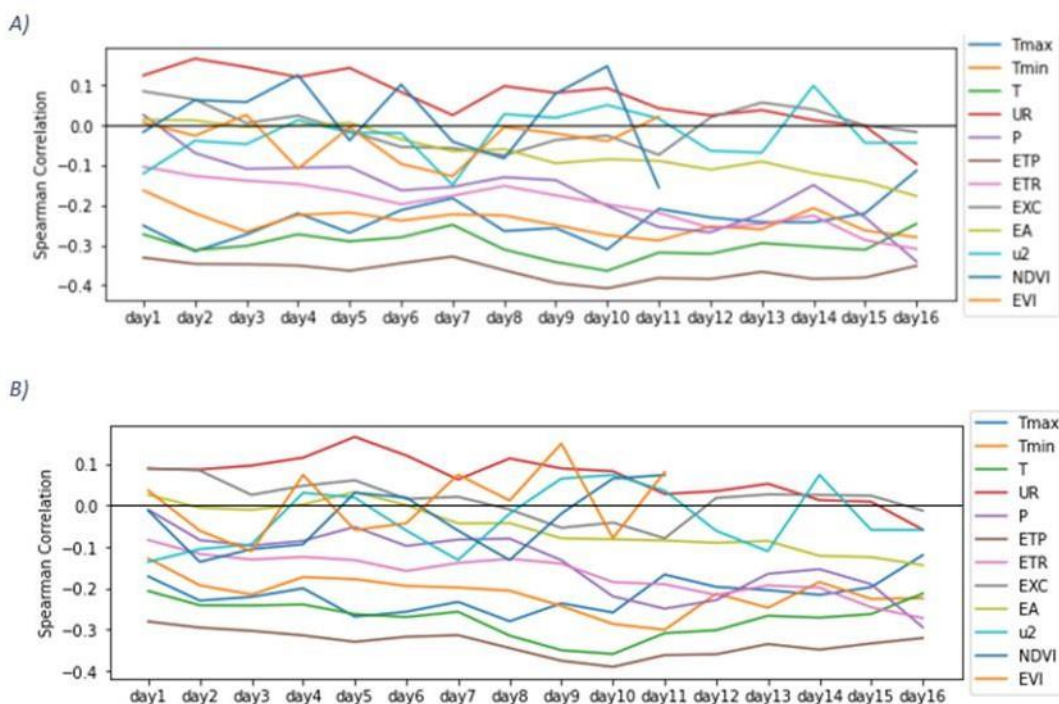


Figura 10. Correlações por Spearman das médias do nível de severidade de *Cercospora* com variáveis meteorológicas e índices de vegetação (NDVI e EVI) a partir de 16 dias antes da análise fitossanitária em campo em A) Carga Alta e B) Carga baixa. Símbolos: Tmax: temperatura máxima diária do ar; Tmin: temperatura mínima diária do ar, T: temperatura média diária do ar, UR: umidade relativa, P: precipitação pluviométrica, ETP: evapotranspiração potencial, ETR: evapotranspiração real, EXC: excedente hídrico, EA: pressão atual de vapor, u2: velocidade do vento, NDVI: índice de vegetação por diferença normalizada e EVI: índice de vegetação realçado.

Os modelos de regressão linear múltipla com seleção de variáveis *Por Stepwise Forward* para estimação da severidade de cercospora (%) foram significativas a 0.05, tanto para carga alta, como para baixa. A seleção de variáveis por *Stepwise Forward* para o modelo de Regressão Linear múltipla resultou numa escolha de 45 variáveis (Figura 11), dentre as 200 variáveis estudadas (Figura 3) para a situação de carga alta.

Resultado da regressão linear múltipla com variáveis selecionadas pelo método *Stepwise Forward* para talhões com carga alta (Eq 9) e carga baixa (Eq 10) realizada com o método OLS da biblioteca *Statsmodels* do *Python* 3.9.7. Símbolos: os números indicam o dia de 1 a 16. Todos os símbolos em escala diária, Tmax: temperatura máxima, Tmin: temperatura mínima, T: temperatura média, Ur: umidade relativa média, ETR: evapotranspiração real, ARM: armazenamento de água no solo, EXC: excedente hídrico, NDVI: índice de vegetação por diferença normalizada e EVI: índice de vegetação realçado, UA: umidade absoluta, u: velocidade do vento, MUr: umidade relativa média do período de 16 dias.

A seleção de variáveis por *Stepwise Forward* para o modelo de Regressão Linear múltipla resultou também numa escolha de 45 variáveis (Figura 11), dentre as 200 variáveis estudadas para a situação de carga baixa:

OLS Regression Results:

Para a situação de Carga Alta, obteve-se um R^2 ajustado de 0,74, Valor p de 1.57×10^{-35} , ALC = 1677 e BIC = 1829.

$$\begin{aligned}
 SEVERITY (\%) = & (14.82 * n_{nos} - 5.02 * foliage + -5.33 * Tmax1 + 3.31 * Tmax6 + 3.60 * \\
 & Tmax8 + 11.58 * Tmax10 + 9.66 * Tmax15 - 24.89 * Tmax16 + 9.88 * Tmin5 - 4.52 * \\
 & Tmin8 - 20.09 * Tmin16 + 8.35 * T1 - 6.65 * T9 + 30.47 * T16 - 9.94 * Ur3 + 6.39 * Ur5 + \\
 & 0.02 * P3 - 10.56 * ETR1 + 10.90 * ETR2 - 6.19 * ETR6 + 3.44 * ETR8 - 0.61 * ARM1 + \\
 & 10.82 * ARM8 + 4.91 * ARM15 - 28.58 * ARM16 - 3.54 * EXC3 + 3.64 * EXC4 - 3.64 * \\
 & EXC6 - 3.16 * EXC7 + 5.74 * EXC10 + 9.13 * NDVI5 - 8.85 * NDVI7 - 20.28 * NDVI10 + 3.38 * EVI1 \\
 & - 5.95 * EVI3 - 3.12 * EVI6 + 4.52 * EVI7 + 9.76 * EVI10 - 17.44 * UA6 - 12.67 * UA10 + 8.47 * \\
 & UA16 - 2.86 * u4 - 2.03 * u5 - 4.33 * u10 + 42.15 * MUr)
 \end{aligned}
 \tag{Eq. (9)}$$

E para a situação de Carga baixa o modelo resultou em um R^2 ajustado de 0,79, valor $p = 7.25 \times 10^{-28}$, ALC = 1218 e BIC de 1357

$$\begin{aligned}
 SEVERITY (\%) = & (9.42 * n_nos - 7.56 * \text{Enfolhamento} + 17.69 * T_{\max 6} - 5.04 * T_{\max 13} - 33 * \\
 & T_{\max 16} - 21.78 * T_{\min 7} - 15.64 T_{\min 13} - 19.61 * T_{\min 16} + 10.86 * T_{10} + 18.00 * T_{13} + \\
 & 57.80 * T_{16} - 8.44 * U_{r3} - 13.75 * U_{r11} + 11.25 * P_5 - 4.09 * P_6 + 5.45 * P_{12} + 6.07 * P_{15} + \\
 & 22.93 * ETP_2 - 10.51 * ETR_1 - 19.61 * ETR_4 + 14.23 * ETR_8 - 8.49 * ETR_9 - 13.82 * \\
 & ETR_{10} - 29.86 * ARM_{16} - 3.22 * EXC_6 - 2.88 * EXC_7 - 4.33 * EXC_{15} - 6.92 * NDVI_4 + 8.58 * \\
 & NDVI_5 - 8.19 * NDVI_7 + 8.14 * NDVI_8 + 6.36 * NDVI_9 - 20.43 * NDVI_{10} + 3.58 * \\
 & EVI_1 - 4.33 * EVI_3 + 4.57 * EVI_4 + 5.32 * EVI_{10} - 6.44 * u_4 + 5.62 * u_{12} + 3.78 * \\
 & u_{14} - 2.15 * u_{15} + 0.92 * Mur - 37.28 * MDEF + 1261 * MUA - 1237 * Mea) \quad \text{Eq. (10)}
 \end{aligned}$$

Para o período de treinamento o modelo de RLM teve uma precisão de R^2 ajustado = 0,74; MAE = 9,78; e RMSE = 12,48. E para Carga Baixa (B), R^2 ajustado = 0,8; MAE = 8,31; RMSE = 10,6. Para o período de teste para carga alta os valores foram, R^2 ajustado = 0,81; MAE= 19,56 e RMSE = 25,23. E para carga baixa, R^2 ajustado = 0,86; MAE = 17,23; RMSE = 22,72. Indicando que o modelo RLM foi acurado para todas as situações.

As redes neurais MLP que foram treinadas possuem três camadas intermediárias. Foram testadas a quantidade de neurônios, a função de ativação, o solver e a taxa de aprendizagem com o método *Gridsearch* da biblioteca *Scikit-Learn* da linguagem *Python* (Tabela 1).

Tabela 1. Parâmetros treinados para o modelo de redes neurais *multilayer perceptron* (MLP) e Random Forest (RF) para áreas de café com carga alta e baixa

Multilayer Perceptron (MLP)		
Parameters	Tested values	Optimized values
(Carga Alta)		
Hidden layer sizes	0-10	2, 2, 4
Solver	Sgd, lbfgs, adam	Lbfgs

Learning_rate	Adaptive	Adaptive
alpha	0.001, 0.05	0.05
cv	4	4
(Carga Baixa)		
Hidden layer sizes	0-10	2, 2, 4
Solver	Sgd, lbfgs, adam	sgd
Learning_rate	Adaptive	Adaptive
alpha	0.001, 0.05	0.05
cv	4	4
Random Forest (RF) (Carga Alta e Baixa)		
max_depth	0-15	7
n_estimators	233	233
max_features	233	233

Os modelos de *MLP* apresentaram alta acurácia e precisão no período de treinamento tanto para carga alta como para baixa (Figura 11.A e 11.B).

Os modelos de Random Forest (RF) apresentaram desempenho acurado no período de treinamento e de teste (Tabela 2). Foram utilizados os parâmetros de max_depth = 7, n_estimators= 233, max_features = 233 do método *RandomForestEstimator* da biblioteca *scikit-learn* da linguagem *Python*.

Tabela 2. Desempenho dos modelos de redes neurais multilayer perceptron (MLP) Random Forest (RF) para períodos de alta e baixa carga.

Modelos	R^2_{ajustado}	MAE	RMSE
MLP			
Carga Alta- Treinamento	0.99	0.35	0.49
Carga Alta- Teste	0.99	2.86	3.52
Carga Baixa-Treinamento	0.92	1.82	2.34
Carga Baixa- Teste	0.83	8.32	11.77
RF			
Carga Alta- Treinamento	0.92	5.36	8.04

Carga Alta- Teste	0.91	5.82	8.59
Carga Baixa-Treinamento	0.94	4.95	7.22
Carga Baixa- Teste	0.92	5.03	7.87

Os modelos de *Random Forest* tanto para carga alta como para baixa apresentaram acurácias superiores as da RLM. Optou-se ainda por utilizar o modelo de *Random Forest* (*RF*) para encontrar modelos mais robustos. A opção por utilizar esses modelos foi porque eles têm vantagens como capacidade para aprender problemas não lineares, apesar de serem mais difíceis de serem treinados por terem mais problemas com mínimos locais (RUMELHART et al., 1986, ROSENBLATT, 1981).




Figura 11. Valores observados e estimados pelo modelo de *Redes Neurais Multilayer Perceptron* (MLP) de severidade de doença para A) Carga Alta e B) Carga baixa.

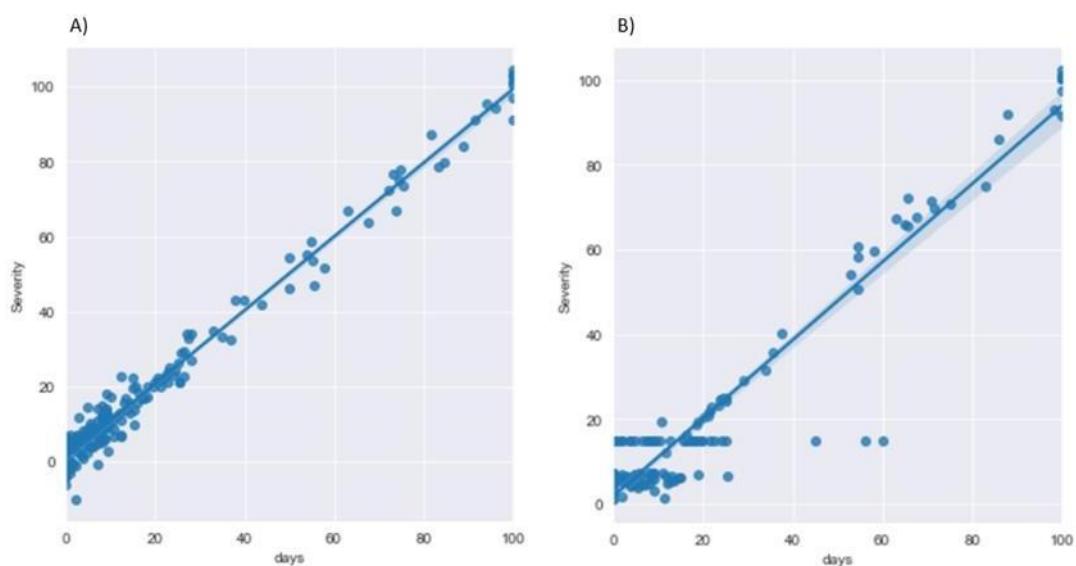


Figura 12. Comparação de dados observados e estimados por rede neural *Multilayer Perceptron* (MLP) de severidade de *Cercospora* para carga alta (A) e baixa (B)

Em média o desempenho dos modelos de redes neurais *Multilayer Perceptron* foram superiores aos de regressão linear múltipla com seleção de variáveis por *Stepwise Forward*. Por fim, o modelo de *Random Forest* para regressão resultou em modelos acurados no período de treinamento e de teste.

4. CONCLUSÃO

Foi possível obter modelos agrometeorológicos-espectrais por regressão linear múltipla com seleção de variáveis por *Stepwise Forward*, *Random Forest* e por redes neurais *Multilayer Perceptron*, suficientemente acurados para o nível de incidência de cercosporiose em Araguari, Araxá, Patrocínio e Franca, regiões importantes para a cafeicultura do Brasil. Modelos de redes neurais multilayer perceptron (MLP) foram mais precisos, que apresentaram uma menor (RMSE), pode-se notar também, que o fator de produção do cafeeiro, ou seja, se ele estava em Carga Alta ou Baixa não apresentou diferença entre os modelos estudados.

REFERÊNCIAS

- ALLEN, R.G.; PEREIRA, L.S.; RAES, D.; SMITH, M. Crop evapotranspiration: Guidelines for computing crop water requirements. **Rome: FAO**, 300 p. 1998 (FAO – Irrigation and Drainage Paper, 56).
- ALMEIDA, A. M. R.; PIUGA, F. F.; MARIN, S. R. R.; BINNECK, E.; SARTORI, F.; COSTAMILAN, L. M.; TEIXEIRA, M. R. O; LOPES, M. Patogenicity, molecular characterization, and cercosporin content of Brazilian isolates of *Cercospora kikuchii*. **Fitopatologia Brasileira** 30:594-602, 2005.
- ANDRADE, M. E. R.; DE RESENDE, M. L. V.; DOS SANTOS BOTELHO, D. M.; TEIXEIRA, A. R.; SANTIAGO, W. D.; PEREIRA, M. B.; ... & DE MUNIZ OLIVEIRA, D. A. Severidade e produção de cercosporina em isolados de *Cercospora coffeicola*. **X Simpósio de Pesquisa dos Cafés do Brasil**. 2019
- APARECIDO, L. E.O; DE SOUZA ROLIM, G.; MORAES, J. R. D. S. C.; COSTA, C. T. S.; DE SOUZA, P.S. Machine learning algorithms for forecasting the incidence of *Coffea arabica* pests and diseases. **International Journal of Biometeorology**, p. 1-18. 2020
- BADNAKHE, M.R.; DURBHA, S.S.; JAGARLAPUDI, A.; GADE, R. M. Evaluation of citrus gummosis disease dynamics and predictions with weather and inversion based leaf optical model. **comput. Electron**. 2018
- BERUSKI, G. C.; PEREIRA, A. B.; JACCOUD-FILHO, D. S.; SARTORI, F. F.; SENTELHAS, P. C. Incidence and severity of white mold for soybean under different cultural practices and local meteorological conditions. **Biosci. J., Uberlândia**, v. 31, n. 4, p. 1004-1014, July/Aug. 2015

- CAMARGO, M. B. P. The impact of climatic variability and climate change on arabic coffee crop in Brazil. **Bragantia**, Campinas, v. 69, p. 239-247, 2010.
- CARVALHO, V. L.; CHALFOUN, S. M. Integrated management of the main diseases of coffee. **Agricultural Report**, Belo Horizonte, v. 19, n. 193, p. 27-35, 1998
- CARVALHO, V. L.; CUNHA, R. L.; CHALFOUN, S. M. Management of coffee diseases for family coffee. **Agricultural Report**, Belo Horizonte, v. 26, p. 86-101, 2005
- CARVALHO, V. L.; CUNHA, R. L. D; GUIMARÃES, P. T. G; CARVALHO, J. P. F. Influence of zinc on the incidence of coffee diseases. **science and agrotechnology**, lavras, v. 32, n. 3, p. 804-808, May/ Jun, 2008
- CHALFOUN, S. M. (1997) Doenças do cafeeiro: importância, identificação e métodos de controle. Lavras: UFLA/FAEPE, 1997. 96p..
- CHEN, H.; LEE, M.-H.; DAUB, M. E.; CHUNG, K. R. (2007) Molecular analysis of the cercosporin biosynthetic gene cluster in *Cercospora nicotianae* **Molecular Microbiology**, 64: 755-770, 2007
- CORRÊA, E. A. **Perdas de solo e índices de vegetação: proposta metodológica para a determinação do fator C (MEUPS) em pastagens e cana-de-açúcar**. Tese (Doutorado em Geociências e Ciências Exatas) – Universidade Estadual Paulista, Campus Rio Claro. 2016
- COSTA, R. V.; CASELA, C. R.; COTA, L.V. Doenças Foliares. Embrapa, Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/milho/producao/pragas-e-doencas/doencas/doencas-foliares>; Acesso: 29/06/2023.

- CUSTÓDIO, A. A. P.; POZZA, E. A.; DE PAIVA CUSTÓDIO, A. A.; DE SOUZA, P. E.; LIMA, L. A.; DE LIMA, L. M. Intensidade da ferrugem e da cercosporiose em cafeeiro quanto à face de exposição das plantas. **Coffee Science**, Lavras, v. 5, n. 3, p. 214-228, set./dez, 2010
- CUTLER, D. R.; EDWARDS, J. R. T. C.; BEARD, K. H.; CUTLER, A.; HESS, K. T.; GIBSON, J.; LAWLER, J. J. J. Random forests for classification in ecology. **Ecology**, 88(11), 2783-2792, 2007
- FERNANDES, C. D. **Efeito de fatores do ambiente e da concentração de inóculo sobre a cercosporiose do cafeeiro**. 1988. 37 f. Dissertação (Mestrado em Fitopatologia) - Universidade
- FERNANDES, C. D.; PELOSO, M.C.; MAFFIA, L.A.; VALE, F.X.R.; ZAMBOLIM, L. Influência da concentração de inóculo de *Cercospora coffeicola* e do período de molhamento foliar na intensidade da cercosporiose do cafeeiro. **Fitopatologia Brasileira**, Brasília, v.16, n.1, p.39-43, 1991.
- FERNANDES, C. F.; VIEIRA JUNIOR, J. R. Doenças do cafeeiro. **Café na Amazônia**. Brasília, DF: Embrapa, 2015.
- FRANKE, J.; MENZ, G.; OERKE, E. C.; RASCHER, U. Comparison of multi-and hyperspectral imaging data of leaf rust infected wheat plants. **In: Remote Sensing for Agriculture, Ecosystems, and Hydrology VII**. SPIE, 2005. p. 349-359.
- FRANKENBERG, C.; FISHER, J. B.; WORDEN, J.; BADGLEY, G.; SAATCHI, S. S.; LEE, J. E.; TOON, G. C.; BUTZ, A.; JUNG, M.; KUZE, A.; YOKOTA, T. New Global Observations of the Terrestrial Carbon Cycle from GOSAT: Patterns of Plant Fluorescence with Gross Primary Productivity. **Geophysical Research Letters**, v. 38, n. 17, p. 1–6, 2011

- HANSEN, J. G. Use of multispectral radiometry in wheat yellow rust experiments. **OEPP/EPPO Bull.** 21, 651–658, 1991.
- HARRIS, C.R.; MILLMAN, K.J.; VAN DER WALT, S.J. et al. Array programming with NumPy. **Nature** 585, 357–362, 2020
- HARVEY, C. A.; SABORIO-RODRÍGUEZ, M.; MARTINEZ-RODRÍGUEZ, M. R.; VIGUERA, B.; CHAIN-GUADARRAMA, A. Climate change impacts and adaptation among smallholder farmers in central america. **agric. food secur.** 7(1): 1–20, 2018
- HILLNHÜTTER, C. **Non-destructive evaluation of complex interactions between *Heterodera schachtii* and *Rhizoctonia solani* on sugar beet as affected by cultivar resistance.** Phd Thesis - Universitäts-und Landesbibliothek Bonn. 2011.
- HODGES, T. **Predicting Crop Phenology.** CRC Press, Boca Raton, FL, 1990
- JULIATTI, F. C.; SILVA, A. S.; JULIATTI, F. C. Problemas fitossanitários em culturas sob pivô central no triângulo Mineiro e Alto Paranaíba. **In: Manejo integrado–fitossanidade: cultivo protegido, pivô central e plantio direto.** Viçosa, p. 205-256, 2001.
- ZHANG J, et al. (2012). Using in-situ hyperspectral data for detecting and discriminating yellow rust disease from nutrient stresses. **Fiel Crops Res.**
- KATSUHAMA, N.; IMAI, M.; NARUSE, N.; TAKAHASHI, Y. (2018). Discrimination of areas infected with coffee leaf rust using a vegetation index. **Remote sensing letters,** 9(12), 1186-1194, 2018
- KLERING, E. V.; FONTANA, D. C.; ROGLIO, V. S.; ALVES, R. D. C. M.; BERLATO, M. A. Modelo agrometeorológico-espectral para estimativa da produtividade de grãos de arroz irrigado no Rio Grande do Sul. **Bragantia,** 75(2), 247-256, 2016.

- KUCKENBERG, J.; TARTACHNYK, I.; NOGA, G. Temporal and spatial changes of chlorophyll fluorescence as a basis for early and precise detection of leaf rust and powdery mildew infections in wheat leaves. **Precision agriculture**, v. 10, n. 1, p. 34-44, 2009.
- LEIVAS, J. F.; TEIXEIRA, A. H. D. C.; ANDRADE, R. G.; VICTORIA, D. D. C.; BAYMA-SILVA, G.; BOLFE, E. L. Application of agrometeorological spectral model in rice area in southern Brazil. **Proc. SPIE 9637, Remote Sensing for Agriculture, Ecosystems, and Hydrology XVII**, 96372B, 2015
- LIMA, L. M.; POZZA, E. A.; SANTOS, F. S. Relationship between incidence of brown eye spot of coffee cherries and the chemical composition of coffee beans. **Journal of Phytopathology**, v. 160, n. 4, p. 209-211, 2012
- MABILANA, H. A.; FONTANA, D. C.; DA FONSECA, E. L. Development of an agrometeorological spectral model to estimate maize yields in the Manica Province-Mozambique. **Revista Ceres**, v. 59, n. 3, p. 337-349, 2012
- MAHLEIN, A. K. Detection of plant diseases by image sensors — parallels and specific demands for precision agriculture and plant phenotyping. **Plant Disease**, vol 100, no. 2. pp 241-251, 2016
- MALAU, S.; LUMBANRAJA, P.; PANDIANGAN, S.; TARIGAN, J. R.; TINDAON, F. Performance of *Coffea arabica* L. in changing climate of north Sumatra of Indonesia. **Sci. Agric. Bohem.** 49(4), 340–349, 2018.
- MALTHUS, T. J.; MADEIRA, A. C. High resolution spectroradiometry: spectral reflectance of field bean leaves infected by *Botrytis fabae*. **Remote Sensing Of Environment**, v. 45, n. 1, p. 107-116, 1993.

- MARTINS, G. D.; GALO, M. L. B. T.; VIEIRA, B. S. Detecting and mapping root-knot nematode infection in coffee crop using remote sensing measurements. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 12, p. 5395-5403, 2017.
- MATIELLO, J. B.; SANTINATO, R.; GARCIA, A. W. R.; ALMEIDA, S. R.; FERNANDES, D. R. **Cultura de café no Brasil: manual de recomendações**. Ed. 1 Varginha: Fundação Procafé, 2010.
- MCKINNEY W, et al. Data structures for statistical computing in python. **In: Proceedings of the 9th Python in Science Conference**. p. 51–6, 2010.
- MEIRELES, E. J. L.; CAMARGO, M. B. P.; PEZZOPANE, J. R. M.; THOMAZIELLO, R. A.; FAHL, J. I.; BARDIN, L.; SANTOS, J. C. F.; JAPIASSÚ, L. B.; GARCIA, A. W. R.; MIGUEL, A. E.; FERREIRA, R. A. Fenologia do Cafeeiro: condições agrometeorológicas e balanço hídrico do ano agrícola 2004–2005. Brasília, DF. **Embrapa Informação Tecnológica**, 2009.
- MELO, R. W.; FONTANA, D. C.; BERLATO, M. A.; DUCATI, J. R. An agrometeorological–spectral model to estimate soybean yield, applied to southern Brazil. **International Journal of Remote Sensing**, v. 29, n. 14, p. 4013-4028, 2008.
- MESQUITA, C. M.; REZENDE, J. D.; CARVALHO, J. S.; FABRI JUNIOR, N. A.; MORAES, N. C.; DIAS, P. T.; CARVALHO, R. M.; ARAÚJO, W. G. Manual do café: distúrbios fisiológicos, pragas e doenças do cafeeiro (*Coffea arábica* L.). **Belo Horizonte: EMATER-MG**, 62 p., 2016
- MIRIK, M.; MICHELS JR., G. J.; KASSYMZHANOVA-MIRIK, S.; ELLIOTT, N. C.; CATANA, V.; JONES, D. B.; BOWLING, R. Using digital image analysis and

- spectral reflectance data to quantify damage by greenbug (Hemiptera: Aphididae) in winter wheat. *Computers and electronics in agriculture*, 51(1-2): 86-98, 2006
- MORAES, W. B.; JUNIOR, W. C. J.; PEIXOTO, L. A.; MORAES, W. B.; COSER, S. M.; CECÍLIO, R. A. Impact of climate change on the phoma leaf spot of coffee in Brazil. *Interciencia*, v. 37, n. 4, p. 272-278, 2012.
- MOSHOV, D.; BRAVO, C.; WEST, J.; WAHLEN, S.; MCCARTNEY, A.; RAMON, H. Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural networks. *Computers and electronics in agriculture*, v. 44, n. 3, p. 173-188, 2004.
- PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; ... & DUCHESNAY, E. Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830, 2011.
- PETORRELLI, N.; VIK, J. O.; MYSTERUD, A.; GAILLARD, J. M.; TUCKER, C. J.; STENSETH, N. C. Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in ecology & evolution*, v. 20, n. 9, p. 503-510, 2005.
- POZZA, A. A. A.; PRIETO MARTINEZ, H. E.; CAIXETA, S. L.; CARDOSO, A. A.; ZAMBOLIM, L.; POZZA, E. A. Influência da nutrição mineral na intensidade da mancha-de-olho-pardo em mudas de cafeeiro. *Pesquisa Agropecuária Brasileira*, v. 36, p. 53-60, 2001.
- POZZA, E. A.; ALVES, M. C. Impacto potencial de mudanças climáticas sobre as doenças fúngicas do cafeeiro no Brasil. In: Ghini, R; Hamada, E. **Mudanças climáticas: impactos sobre doenças de plantas no Brasil**. 1. ed. Brasília:

Embrapa Informação Tecnológica, 2008. 331 p. 1ed. Brasília: Gráfica: EMBRAPA, 2008, v. 1, p. 220-238.

POZZA, E. A.; CARVALHO, V. L.; CHALFOUN, S. M. Sintomas de injúrias causadas por doenças em cafeeiro. In: **Semiologia do Cafeeiro: sintomas de desordens nutricionais, fitossanitárias e fisiológicas**. 01ed. Lavras: Editora UFLA, 2010, v. , p. 67-106.

RAMOS, A. P. M.; JUNIOR, J. M.; DECANINI, M. M. S.; PUGLIESI, E. A.; OLIVEIRA, R. F. DE; PARANHOS FILHO, A. C. Avaliação qualitativa e quantitativa de métodos de classificação de dados para o mapeamento coroplético. **Revista Brasileira de Cartografia**, v.3, n.68, p. 609-629, 2016.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do Bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P. **Cerrado: Ecologia e flora**. Brasília, DF: Embrapa Informação Tecnológica; Planaltina, DF: Embrapa Cerrados, 2008.

RISSE, J.; RIZZI, R.; RUDORFF, B. F. T.; ADAMI, M.; SHIMABUKURO, Y. E.; FORMAGGIO, A. R.; EPIPHANIO, R. D. V. Índices de vegetação Modis aplicados na discriminação de áreas de soja. **Pesquisa Agropecuária Brasileira**, v. 47, p. 1317-1326, 2012.

ROLIM, G. S.; DE OLIVEIRA APARECIDO, L. E.; DE SOUZA, P. S.; LAMPARELLI, R. A. C.; DOS SANTOS, E. R. Climate and natural quality of *Coffea arabica* L. drink. **Theoretical and Applied Climatology**, v. 141, p. 87-98, 2020

ROLIM, G. S.; RIBEIRO, R. V.; AZEVEDO, F. A.; CAMARGO, M. B. P.; MACHADO, E. C. Previsão do número de frutos a partir da quantidade de estruturas reprodutivas em laranjeiras. **Revista Brasileira de Fruticultura**, v. 30, p. 48-53, 2008.

- ROSENBLATT, F. **Principles of neurodynamics**: Perceptrons and the theory of brain mechanisms. Washington, DC: Spartan books, 1962.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533-536, 1986.
- SALGADO, B. G.; MACEDO, R. L. G.; CARVALHO, V. L.; SALGADO, M.; VENTURIN, N. Progresso da ferrugem e da cercosporiose do cafeeiro consorciado com grevílea, com ingazeiro e a pleno sol em Lavras-MG. **Ciência e agrotecnologia**, v. 31, p. 1067-1074, 2007.
- SANTOS, F. S.; SOUZA, P. E.; POZZA, E. A.; MIRANDA, J. C.; BARRETO, S. S.; THEODORO, V. C. Progress of brown eye spot (*Cercospora coffeicola* Berkeley & Cooke) in coffee trees in organic and conventional systems. **Summa Phytopathologica**, v.34, n.1, p.48-54, 2008
- SANTOS, L. M.; FERRAZ, G. A. S.; SANTANA, L. S.; BARBOSA, B. D. S.; XAVIER, L. A. G.; ANDRADE, M. T. Índice de Vegetação (ExGR) Aplicado a Imagens rgb Obtidas por UAV para Detecção de Doença em Cafeeiros. **X Simpósio de Pesquisa dos Cafés do Brasil**, 2019.
- SEABOLD, S.; PERKTOLD, J. Statsmodels: Econometric and statistical modeling with python. **In: Proceedings of the 9th Python in Science Conference**. 2010
- SENTELHAS, P. C.; FARIA, R. T.; CHAVES, M. O.; HOOGENBOOM, G. Evaluation of the WGEN and SIMMETEO weather generators for the brazilian tropics and subtropics, using crop simulation models. **Revista Brasileira de Agrometeorologia**, v. 9, n. 2, p. 357-376, 2001.
- SENTELHAS, P. C.; MARTA, A. D.; ORLANDINI, S.; SANTOS, E. A.; GILLESPIE, T. J.; GLEASON, M. L. Suitability of relative humidity as an estimator of leaf

- wetness duration. **Agricultural and forest meteorology**, v. 148, n. 3, p. 392-400, 2008.
- SILVA, R. B. D.; LEAL, L. D. S.; ALVES, L. S.; BRANDÃO, R. V.; ALVES, R. D. C. M.; KLERING, E. V.; PEZZI, R. P. Estações meteorológicas de código aberto: um projeto de pesquisa e desenvolvimento tecnológico. **Revista brasileira de ensino de Física**, v. 37, p. 1505, 2015.
- SOUZA, A. G. C.; MAFFIA, L. A.; MIZUBUTI, E. S. G. Cultural and Aggressiveness Variability of *Cercospora coffeicola*. **Journal of Phytopathology**, v. 160, n. 10, p. 540-546, 2012.
- SOUZA, V. C. O.; CUNHA, R. L.; ANDRADE, L. N.; VOLPATO, M. M. L.; CARVALHO, V. L.; ESMIN, A. A. A. Technical knowledge extraction applied to modeling of occurrence (*Cercospora coffeicola* Berkeley & Cooke) coffee in the southern region of Minas Gerais. **Coffee Science**, v. 8, n. 1, p. 91-100, 2013.
- STACKHOUSE, P. W. et al. Prediction of worldwide energy resource: agroclimatology methodology. 2018
- TALAMINI, V.; POZZA, E. A.; SOUZA, P. E.; SILVA A. M. Progresso da ferrugem e da cercosporiose em cafeeiro (*Coffea arabica* L.) com diferentes épocas de início e parcelamentos da fertirrigação. **Ciência e Agrotecnologia**, v. 27, p. 141-149, 2003.
- THORNTHWAITE, C. W.; MATHER, J. R. The water balance. centerton: Drexel institute of technology. **Publications in climatology**, 8(1), 104p, 1955
- VAN ROSSUM, G.; DRAKE, F. L. **Python reference manual**. Centrum voor Wiskunde en Informatica Amsterdam, 1995

- WEST, J. S.; BRAVO, C.; OBERTI, R.; LEMAIRE, D.; MOSHOU, D.; McCARTNEY, H. A. The potential of optical canopy measurement for targeted control of field crop diseases. **Annual review of Phytopathology**, v. 41, n. 1, p. 593-614, 2003
- ZAMBOLIM, L. et al. Café (*Coffea arabica* L.), controle de doenças. In: VALE, F. X. R.; ZAMBOLIM, L. (eds) **Controle de doenças de plantas: grandes culturas**, v. 1, p. 83-40, 1997.
- ZAMBOLIM, L.; VALE, F. X. R.; MACIEL-ZAMBOLIM, E. Doenças do cafeeiro (*Coffea arabica* e *C. canephora*). In: KIMATI, H.; AMORIM, L.; BERGAMIM-FILHO, A.; CAMARGO, L. E. A.; REZENDE, J. A. M. (eds) **Manual de fitopatologia: doenças das plantas cultivadas**, 4th edn. Ceres, São Paulo, pp 165–180, 2005.
- ZELBER-SAGI, S.; SALAMONE, F.; WEBB, M.; LOTAN, R.; YESHUA, H.; HALPERN, Z.; SANTO, E.; OREN, R.; SHIBOLET, O. Coffee consumption and nonalcoholic fatty liver onset: a prospective study in the general population. **Translational Research**, v. 165, n. 3, p. 428-436, 2015.