

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ CAMPUS CASCAVEL

CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

**USO DE DADOS GEOGRÁFICOS E PREVISÃO AUTOMATIZADA COM REDES NEURAIS
NA AGRICULTURA**

NEWMAR WEGNER

CASCAVEL – PARANÁ

2023

NEWMAR WEGNER

**USO DE DADOS GEOGRÁFICOS E PREVISÃO AUTOMATIZADA COM REDES NEURAIS
NA AGRICULTURA**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração em Sistemas Biológicos e Agroindustriais.

Orientador: Prof. Dr. Erivelto Mercante

CASCADEL – PARANÁ – BRASIL

2023

Ficha catalográfica¹

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

WEGNER, NEWMAR
USO DE DADOS GEOGRÁFICOS E PREVISÃO AUTOMATIZADA COM
REDES NEURAIS NA AGRICULTURA / NEWMAR WEGNER; orientador
Erivelto Mercante. -- Cascavel, 2023.
105 p.

Tese (Doutorado Campus de Cascavel) -- Universidade
Estadual do Oeste do Paraná, Centro de Ciências Exatas e
Tecnológicas, Programa de Pós-Graduação em Engenharia Agrícola,
2023.

1. Agricultura de precisão.. 2. PostgreSQL. . 3. Python.
. 4. Sensoriamento remoto.. I. Mercante, Erivelto , orient.
II. Título.

¹ Revisão de língua inglesa, língua portuguesa e normas por Silvana de Araújo Vaillões, em 19 de abril de 2023.



unioeste

Universidade Estadual do Oeste do Paraná
Reitoria
CNPJ 78.680.337/0001-84
Rua Universitária, 1619, Jardim Universitário
Tel.: (45) 3220-3000 - Fax: (45) 3225-4590 - www.unioeste.br
CEP: 85819-110 - Cx. P.: 701
Cascavel - PARANÁ



NEWMAR WEGNER

USO DE DADOS GEOGRÁFICOS E PREVISÃO AUTOMATIZADA COM REDES NEURAIAS NA AGRICULTURA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:



Documento assinado digitalmente
ERIVELTO MERCANTE
Data: 21/03/2023 08:50:47 -0300
Verifique em <https://validar.it.gov.br>

Orientador(a) - Erivelto Mercante

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)



Documento assinado digitalmente
VICTOR HUGO ROHDEN PRUDENTE
Data: 21/03/2023 09:28:08 -0300
Verifique em <https://validar.it.gov.br>

Victor Hugo Rohden Prudente

School for Environment and Sustainability - University of Michigan (UofM)



Documento assinado digitalmente
ANTONIO MARCOS MASSAO HACHISUCA
Data: 21/03/2023 09:37:56 -0300
Verifique em <https://validar.it.gov.br>

Antonio Marcos Massao Hachisuca

Universidade Estadual do Oeste do Paraná - Campus de Foz do Iguaçu (UNIOESTE)



Documento assinado digitalmente
MARCIO ANTONIO VILAS BOAS
Data: 22/03/2023 15:15:05 -0300
Verifique em <https://validar.it.gov.br>

Marcio Antonio Vilas Boas

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)



Documento assinado digitalmente
SILVIA RENATA MACHADO COELHO
Data: 27/03/2023 11:48:14 -0300
Verifique em <https://validar.it.gov.br>

Silvia Renata Machado Coelho

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 20 de março de 2023.

BIOGRAFIA

Newmar Wegner, nascido no município de Foz do Iguaçu/PR, no ano de 1984, é graduado em Engenharia Ambiental pela Universidade Veiga de Almeida, RJ, no ano de 2012, especialista em Geoprocessamento pela Pontifícia Universidade Católica, MG, e Mestre em Engenharia Agrícola pela Universidade do Oeste do Paraná. Atualmente, reside e trabalha no município de Foz do Iguaçu - PR, atuando como Analista Ambiental na Fundação Parque Tecnológico Itaipu – FPTI, no Núcleo de Inteligência Territorial - NIT.

“Planeje seu trabalho e depois trabalhe em seu
plano”.

Robert Baden-Powell

Dedico este trabalho a todos amigos e familiares que estiveram presentes neste período da minha vida, confiando, incentivando e tendo paciência pela minha ausência em certos momentos. Sem esse apoio, seria impossível a realização deste trabalho.

A vocês, o meu muito obrigado.

AGRADECIMENTOS

Em primeiro lugar, agradeço à minha família, que me ajudou na superação de todas as dificuldades encontradas durante a realização desta etapa em minha vida, e por me incentivarem a conquistar meus objetivos, independentemente das dificuldades existentes.

Não posso esquecer-me dos colegas do PTI, que colaboraram para que eu pudesse andar nos caminhos da pesquisa em busca de soluções para minha área de atuação.

Ao meu orientador, Erivelto Mercante, pela paciência, pelos ensinamentos e pelo incentivo à pesquisa e ao aprendizado.

Também aos meus professores, pelo apoio e os ensinamentos que levarei para toda a vida.

À Unioeste e ao PGEAGRI, que proporcionaram um ambiente de apoio e pesquisa para que este projeto fosse possível.

Finalmente, a todos que, direta ou indiretamente, colaboraram na execução deste trabalho.

WEGNER, Newmar. **Uso de dados geográficos e previsão automatizada com redes neurais na agricultura**. Orientador: Erivelto Mercante. 2023. 105 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2023.

RESUMO

A população mundial demanda uma crescente produção de alimentos para subsistência. A busca por processos e modelos que colaborem no aumento de produtividade é fator primordial para alcançar resultados que minimizem custos ao produtor e que contribuam na tomada de decisões sobre as necessidades da lavoura. As geotecnologias, em conjunto com métodos de análises de dados, permitem monitorar a área produtiva visando alcançar melhores resultados. Assim, este trabalho tem por objetivo apresentar funcionalidades e metodologias que permitam a obtenção, processamento, visualização e previsão de índices na agricultura, de forma automatizada, não onerando o usuário final. Em seu Artigo 01, apresenta a aplicação de ferramentas na geração de base de dados para utilização pela agricultura por meio de um processo de automatização para implantação da estrutura de um banco de dados geográfico, utilizando software livre PostgreSQL+Postgis, que é alimentado por fontes de dados relevantes para a agricultura (limite da área analisada e obtidos por sensores); assim, resulta em uma ferramenta temporal de visualização de dados que contempla um total de 16 índices para análise do comportamento da área produtiva. No Artigo 02, a partir da base consolidada, utilizou-se linguagem python e redes neurais convolucionais para estabelecimento de modelos preditivos de índices NDVI, alcançando erro médio absoluto (MAE) nas previsões de 0.16 a 0.17, com apresentação de melhores resultados para o uso de redes que utilizavam janelas de 5 imagens anteriores à previsão subsequente. Ambos os trabalhos possibilitaram estruturar procedimentos de implantação, estruturação, alimentação e análise de base de dados para agricultura de forma automatizada, minimizando custos e aumentando a agilidade da geração de informações relevantes ao desenvolvimento de culturas. Com isso, as metodologias e ferramentas utilizadas podem ser consideradas por produtores ou analistas, de forma a monitorar, realizar ações preventivas e consequentemente alcançar melhores resultados na produção agrícola.

Palavras-chave: Agricultura de precisão. PostgreSQL. Python. Sensoriamento remoto.

WEGNER, Newmar. **Use of geographic data and automated prediction with neural networks in agriculture**. Advisor: Erivelto Mercante. 2023. 105 p. Thesis (Doctorate in Agricultural Engineering) - State University of Western Paraná, Cascavel – Paraná, 2023.

ABSTRACT

The world population demands an increased production of food for its subsistence. The search for processes and models that collaborate to increase productivity is a key factor to achieve results that minimize costs to the producer and contribute to decision making about the crop's needs. Geotechnologies, in conjunction with data analysis methods, allow monitoring of the productive area aiming to achieve better results. Thus, this work aims to present functionalities and methodologies that allow obtaining, processing, visualization, and prediction of indexes in agriculture in an automated way, not burdening the final user. In Article 01, it presents the application of tools in the generation of a database to be used by agriculture through an automation process for the implementation of a geographic database structure, using free software PostgreSQL+Postgis, which is fed by relevant data sources for agriculture (limits of the analyzed area and obtained by sensors). Thus, it results in a temporal data visualization tool that includes 16 indexes for analyzing the behavior of the productive area. In Article 02, from the consolidated base, Python language and convolutional neural networks were used to establish predictive models of NDVI indices, reaching mean absolute error (MAE) in the predictions from 0.16 to 0.17, with the presentation of better results for the use of networks that used windows of 5 images prior to the subsequent prediction. Both works made it possible to structure procedures for implementing, structuring, feeding, and analyzing agricultural databases in an automated way, minimizing costs and increasing the agility to generate relevant information for crop development. With this, the methodologies and tools used can be considered by producers or analysts to monitor, perform preventive actions and consequently achieve better results in agricultural production.

Keywords: Precision farming. PostgreSQL. Python. Remote sensing.

SUMÁRIO

BIOGRAFIA	v
RESUMO.....	ix
LISTA DE TABELAS	xiii
LISTA DE ABREVIATURAS	xviii
1 INTRODUÇÃO	20
2 OBJETIVOS	22
2.1 Objetivo geral.....	22
2.2 Objetivos específicos	22
3 ORGANIZAÇÃO GERAL DO TRABALHO	23
4.1 Agricultura e aspectos de sua produtividade	25
4.2 Sensoriamento remoto na agricultura.....	26
4.3 Agricultura de precisão	29
4.4 Geotecnologias aplicadas na agricultura.....	32
4.5 Banco de dados geográficos Postgres	34
4.6 Python	35
4.7 GEE – Google Earth Engine	36
4.8 Sistemas de informações geográficas	36
4.9 Redes Neurais artificiais	38
REFERÊNCIAS	42
ARTIGO 1 – INFRAESTRUTURA DE DADOS ESPACIAIS COM PROCESSOS DE ANÁLISES AUTOMATIZADAS PARA A AGRICULTURA.....	51
1 INTRODUÇÃO.....	52
2 MATERIAIS E MÉTODOS	54
2.1. Implantação de banco de dados geográficos para dados de agricultura obtidas por sensoriamento remoto.....	55
2.2. Utilização de linguagem Python e plataforma Google Earth Engine	56
2.2.1. Importação de módulos e autenticação de usuário.....	57
2.2.2. Estruturação de códigos para variáveis relevantes	57
2.2.3. Alimentação de banco de dados geográficos e uso de módulos Python para análise	59
3 RESULTADOS E DISCUSSÃO.....	60
4 CONCLUSÕES.....	63
ARTIGO 2 – USO DE REDES NEURAIS EM PROGNÓSTICOS DE ÍNDICE NDVI PARA AGRICULTURA.....	74
1. INTRODUÇÃO.....	75

MATERIAIS E MÉTODOS	78
Levantamento de imagens, processamento e geração de índices NDVI	78
Estruturação da Rede Neural	78
Treinamento da Rede Neural	79
Validação	81
RESULTADOS E DISCUSSÕES	82
5 CONCLUSÕES.....	92

LISTA DE TABELAS

Tabela 1 - Índices utilizados no levantamento de base de dados	58
Tabela 2 - População de imagens utilizadas para treinamento e suas respectivas datas	80
Tabela 3 - Treinamentos de modelos realizados com diferentes grupos datasets e 800 epochs	83
Tabela 4 - Treinamentos de modelos realizados com diferentes datasets e 100 epochs	87

LISTA DE FIGURAS

Figura 1 - Fluxograma geral de organização das atividades. Artigo 1 - contemplando 4 etapas para obtenção de base de dados consistida para alimentação de dashboard e Artigo 2 – contemplando 4 etapas para geração de modelo utilizável para previsão de NDVI.....	24
Figura 2 - Etapas contempladas na agricultura de precisão	30
Figura 3 - Estrutura de rede neural artificial - Em verde, a representação da camada de entrada de dados; em azul, camadas ocultas, e, em vermelho, a camada de saída. As linhas representam as conexões entre os neurônios	41
Figura 4 - a) Localização Município de Céu Azul b) Localização área experimental Aldo Tasca	54
Figura 5 - Fluxo e ferramentas utilizadas na construção do banco	55
Figura 6 - Estrutura criada em banco de dados PostgreSQL	56
Figura 7 - Delimitação da área de estudo do Aldo Tasca para obtenção dos dados de sensoriamento remoto disponibilizados na plataforma Google Earth Engine	60
Figura 8 - Parâmetros armazenados em banco de dados - data: data de obtenção da imagem; index: índice gerado por meio dos processamento; raster_array: estrutura com valores de refletância dos rasters; zonal_stats: valores de mínimo, máximo e média do índice para a data; raster_profile: parâmetros para reconstrução do raster	61
Figura 9 - Recuperação de valores do índice NDVI presente em banco de dados. Esquerda: valores mínimo, máximo e médio de NDVI para período de anos determinado na área do talhão; Direita superior: Comparação entre índices NDVI e AVI histórico; Direita inferior: recuperação da imagem do índice especificado e data presente no banco de dados.	62
Figura 10 - Comparação entre índices NDVI (vermelho) e fe3+ (azul) demonstrando a correlação negativa entre os dois.....	62
Figura 11 - Comparação entre índices SCI (vermelho) e NDVI (azul) demonstrando a correlação negativa entre os dois.....	63
Figura 12 - Estrutura das camadas da rede neural ConvLSTM	79
Figura 13 - Funcionamento de janelas temporais fixas e deslizantes para realização de prognósticos de NDVI's	80
Figura 14 - Histórico de valores de NDVI na área de estudo	82

Figura 15 - Curvas do comportamento da função de perda utilizando grupo de dados Global e janela de 5 imagens e 800 epochs	83
Figura 16 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados Global e janela de 5 imagens e 800 epochs	83
Figura 17 - Curvas do comportamento da função de perda utilizando grupo de dados Global e janela de 10 imagens e 800 epochs.....	84
Figura 18 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados Global e janela de 10 imagens e 800 epochs.....	84
Figura 19 - Curvas do comportamento da função de perda utilizando grupo de dados Global e janela de 15 imagens e 800 epochs.....	84
Figura 20 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados Global e janela de 15 imagens e 800 epochs.....	84
Figura 21 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 5 imagens e 800 epochs	85
Figura 22 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 5 imagens e 800 epochs.....	85
Figura 23 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 10 imagens e 800 epochs	85
Figura 24 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 10 imagens e 800 epochs.....	85
Figura 25 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 15 imagens e 800 epochs	85
Figura 26 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 15 imagens e 800 epochs.....	85
Figura 27 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 5 imagens e 800 epochs	86
Figura 28 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 5 imagens e 800 epochs.....	86
Figura 29 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 10 imagens e 800 epochs	86
Figura 30 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 10 imagens e 800 epochs.....	86

Figura 31 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 15 imagens e 800 epochs	86
Figura 32 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 15 imagens e 800 epochs.....	86
Figura 33 - Curvas do comportamento da função de perda utilizando grupo de dados global e janela de 5 imagens e 100 epoch	87
Figura 34 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados global e janela de 5 imagens e 100 epochs.....	87
Figura 35 - Curvas do comportamento da função de perda utilizando grupo de dados global e janela de 10 imagens e 100 epoch	88
Figura 36 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados global e janela de 10 imagens e 100 epochs.....	88
Figura 37 - Curvas do comportamento da função de perda utilizando grupo de dados global e janela de 15 imagens e 100 epoch	88
Figura 38 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados global e janela de 15 imagens e 100 epochs.....	88
Figura 39 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 5 imagens e 100 epoch	89
Figura 40 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 5 imagens e 100 epochs.....	89
Figura 41 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 10 imagens e 100 epoch	89
Figura 42 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 10 imagens e 100 epochs.....	89
Figura 43 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 15 imagens e 100 epoch	89
Figura 44 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 15 imagens e 100 epochs.....	89
Figura 45 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 5 imagens e 100 epoch	90
Figura 46 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 5 imagens e 100 epochs.....	90

Figura 47 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 10 imagens e 100 epoch	90
Figura 48 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 10 imagens e 100 epochs.....	90
Figura 49 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 15 imagens e 100 epoch	91
Figura 50 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 15 imagens e 100 epochs.....	91
Figura 51 - Prognósticos de NDVI utilizando janela de 5 imagens anteriores, aplicação dos 3 modelos gerados para 30% das imagens de validação em conjunto com dados até 31/03/2023.	92

LISTA DE ABREVIATURAS

AHP –	Processo hierárquico analítico
ARI -	Anthocyanin reflectance index
ARVI -	Atmospherically Resistant Vegetation Index
ATSAVI -	Adjusted transformed soil-adjusted VI
AVI -	Ashburn Vegetation Index
AVIRIS -	Airborne Visible Infrared Imaging Spectrometer
CHLGREEN -	Chlorophyll Green
CTVI -	Corrected Transformed Vegetation Index
EVI -	Enhanced Vegetation Index
FAO -	Food and Agriculture Organization of the United Nations
Fe ³⁺ -	Ferric iron
Fo -	Ferric oxides
GEE –	Google Earth Engine
GIS -	Geographic information systems
GNDVI -	Green normalized Difference Vegetation Index
GVMI -	Global vegetation Moisture Index
LCI -	Leaf chlorophyll index
LSTM -	Long short-term memory
MAE -	Erro médio absoluto
MAPE -	Erro percentual absoluto médio
MODIS -	Moderate-Resolution Imaging Spectroradiometer
MSE -	Erro quadrático médio
MSI –	MultiSpectral Instrument
NDMI -	Normalize difference Moisture index
NDVI -	Normalized Difference Vegetation Index
OLI -	Operational Land Imager
PostgreSQL -	Banco de dados
Postgis -	Extensão espacial para banco de dados PostgreSQL
Python -	Linguagem de programação
RGB -	Red-Green-Blue (faixas utilizadas em composições de imagens)
RMSE -	erro quadrático médio
RNA -	Redes neurais artificiais
SAVI -	Soil adjusted Vegetation Index
SCI -	Soil composition index

SIG -	Sistemas de informação geográfica
SR -	Sensoriamento Remoto
UAVs -	Unmanned aerial vehicle

1 INTRODUÇÃO

Com o aumento exponencial da população e a necessidade por mais alimentos, novas tecnologias vêm sendo desenvolvidas com o objetivo de contribuir para uma maior capacidade do potencial de produção. Nesse contexto, podemos ressaltar as buscas por tecnologias que permitam gerar diagnósticos de produção em maior velocidade, subsidiando os produtores a fim de realizarem ações assertivas sobre suas áreas, para obter maiores produtividades sem incremento de sua área física.

Na agricultura, fatores, como disponibilidade hídrica, características físicas e biológicas do solo, processo de mecanização, presença de pragas, entre outros, são elementos que influenciam diretamente a capacidade de produção. Esses elementos devem ser monitorados durante o cultivo de forma a identificar possíveis alterações relevantes que possam de fato influenciar a qualidade e quantidade final produzida.

Atualmente, diversas são as tecnologias utilizadas no monitoramento e diagnóstico de áreas agrícolas, destacando-se as geotecnologias que permitem a aquisição, armazenamento, análise e visualização de dados geográficos, e que, quando combinados com ferramentas de modelagem e estatísticas, podem proporcionar simulações e diagnósticos relevantes para os tomadores de decisões (SANTOS *et al.*, 2016).

Dentro dos processos de aquisição, há de se considerar o uso de sensoriamento remoto, que nos permite, a partir de sensores orbitais, obter informações a respeito da reflexão eletromagnética, podendo, assim, ser utilizado em diferentes métodos e algoritmos para análise dos dados de agricultura, como o uso de recursos baseado em estrutura para avaliação de pousios, recursos geométricos, considerando formas e texturas, séries temporais para identificação de fases de sucessão, janelas críticas que identificam distribuição espacial, além de recursos espectrais que contemplam o uso de diversos índices que nos permitem, por meio da sensibilidade de faixas espectrais dos sensores, delinear e interpretar determinadas características da área analisada (JIANG; LI; FENG, 2022). O processo de identificação e análise de alvos, a partir do sensoriamento remoto, permite verificar alterações significativas em áreas cultivadas, contribuindo para a interpretação de comportamentos, características e possíveis mudanças que possam vir a ocorrer no desenvolvimento de plantas. Assim, é possível gerar informações que possibilitam a tomada de ações imediatas sobre possíveis alterações que possam afetar diretamente a capacidade produtiva final da área em questão.

As imagens obtidas a partir de sensoriamento remoto possuem, como características, sua resolução espacial (mínimo tamanho possível de ser representado), resolução

radiométrica (nível de sensibilidade do sensor) e resolução temporal (tempo de revisita). Atualmente, possuímos diversos sensores para obtenção de dados e suas resoluções estão se tornando cada vez mais altas, resultando em uma grande quantidade de dados, ou seja, uma consequente massiva geração de informações geográficas, que contemplam dados tabulares e de imagens, os quais, quando tratados e analisados, geram informações relevantes ao usuário final (FENG *et al.*, 2022).

Para tanto, uma estrutura de dados geográficos e ferramentas que permitam o processamento adequado dessa quantidade massiva de dados devem estar disponibilizadas de forma a alcançar resultados favoráveis. Essa combinação pode ser realizada com a integração de redes neurais, que tratam de questões da realidade com a mesma capacidade de um sistema nervoso biológico, a partir de estruturas organizadas que atuam com a mesma função da rede neural humana. Isso permite, a partir de um processo de aprendizagem sobre uma abstração teórica, simplificar e simular várias características do elemento avaliado (XU *et al.*, 2020).

O uso de redes neurais vem amplamente sendo utilizado para reconhecimento de padrões em imagens, de maneira que, atualmente, existe um desenvolvimento científico grande na área com diversas publicações sobre o tema (LIU *et al.*, 2020a). Tal afirmação vai de encontro à necessidade atual da agricultura e considerada neste estudo, ao utilizar imagens obtidas por sensoriamento remoto para análise histórica da área agricultável e, a partir delas, realizar o treinamento de rede neural, visando gerar previsões automatizadas para a agricultura, haja vista que um crescimento exponencial na utilização de imagens para avaliação de culturas é uma realidade atual.

Dessa maneira, as geotecnologias, com a utilização das ferramentas de aprendizagem de máquinas, são consideradas técnicas promissoras para levantamentos e diagnósticos do setor agrícola, permitindo mapear e avaliar o desenvolvimento da produção, consequentemente, gerando informações que permitam melhorar as características produtivas da área, além de benefícios econômicos ao produtor e analistas.

2 OBJETIVOS

2.1 Objetivo geral

Implementar processo de coleta e armazenamento de dados obtidos por sensoriamento remoto, por meio da automatização de processos com algoritmos desenvolvidos, utilizando softwares livres que gerem informações e previsões automatizadas para a agricultura.

2.2 Objetivos específicos

- Estabelecer um modelo de infraestrutura de dados espaciais e algoritmos para obtenção de informações de sensoriamento remoto utilizáveis para monitoramento de culturas agrícolas, por meio de índices derivados das imagens e possíveis de serem visualizados historicamente em ambiente amigável ao produtor ou analista;
- Desenvolver metodologia e modelo para geração de previsão de índice NDVI, utilizando técnicas de implementação de redes neurais LSTM e convolucionais que permitam verificar possíveis alterações ou tendências que possam contribuir nas tomadas de decisões de áreas agricultáveis monitoradas.

3 ORGANIZAÇÃO GERAL DO TRABALHO

A organização do trabalho consistiu em duas etapas, referentes aos dois artigos esperados como resultado na tese.

O Artigo 1 considera a geração de um banco de dados Postgres visando ao armazenamento de dados recuperados da plataforma GEE – Google Earth Engine (imagens sensor MSI – Sentinel 2); criação de scripts em linguagem Python com objetivo de obter dados de sensoriamento remoto, processar os dados gerando os índices relacionados às características de umidade, solo e vegetação contemplados neste projeto; alimentar o banco de dados; e disponibilizar essas informações ao usuário final considerando o uso de uma ferramenta de dashboard.

Quanto ao Artigo 2, concentra seus trabalhos na implementação de rede neural ConvLSTM, com o objetivo de diminuir dimensionalidade das imagens obtidas por sensoriamento remoto, de forma que possam ser utilizadas para gerar previsões de NDVI da área estudada, a fim de contribuir na análise de tendências de novas médias dos índices para datas ainda não existentes.

Tal organização e desenvolvimento são apresentados na Figura 1:




Figura 1 - Fluxograma geral de organização das atividades. Artigo 1 - contemplando 4 etapas para obtenção de base de dados consistida para alimentação de dashboard e Artigo 2 – contemplando 4 etapas para geração de modelo utilizável para previsão de NDVI.

4 REVISÃO BIBLIOGRÁFICA GERAL

4.1 Agricultura e aspectos de sua produtividade

O desenvolvimento da agricultura ao longo dos anos ocorreu a partir da relação entre o crescimento populacional e a capacidade de produzir alimentos considerando a subsistência humana, não esquecendo de considerar todos os processos de desenvolvimento tecnológicos que ocorreram há séculos e que contribuíram com a segurança alimentar dos dias atuais (SILBERGELD, 2019).

Diversos países possuem a atividade agrícola como propulsora de seu desenvolvimento econômico devido à sua conexão com a indústria, sob uma dependência de que, quando ocorre o processo de estagnação de uma, a outra é diretamente influenciada em relação à sua capacidade produtiva (ADOM; ADAMS, 2020). Cabe ressaltar que sua necessidade de aumento de produtividade para atender à crescente demanda da população está se tornando uma das maiores preocupações mundiais, uma vez que diversos são os aspectos relevantes ao aumento da capacidade produtiva, sendo a umidade do solo, nutrientes, retenção de água, alguns elementos contemplados nos fatores físicos, químicos ou biológicos que afetam diretamente o desenvolvimento de culturas (SRIVASTAVA *et al.*, 2019).

Além desses aspectos, com o crescimento populacional em ascendência, é estimada a necessidade de dobrar a capacidade de produção de alimentos até 2050; ademais, processos de produção sustentáveis deverão ser fomentados, de forma a mitigar impactos ambientais que possam gerar recessão de recursos naturais necessários para esse crescimento (FAO, [s.d.]; SU *et al.*, 2020). Plantio e colheita inadequados, as incertezas sobre o clima, possíveis pragas são apenas alguns fatores responsáveis sobre as perdas agrícolas devido às práticas insustentáveis; isso acarreta cerca de um terço de alimentos produzidos desperdiçados anualmente, impactando não só economicamente, mas também a quantidade de alimentos que serão necessários para atender à demanda existente e estimada (DE RANGO *et al.*, 2019; PERAKIS *et al.*, 2020).

Sistemas de produção agrícolas sustentáveis consideram um sistema produtivo rentável e economicamente viável ao produtor, com a utilização de recursos que minimizem impactos nas pessoas e sobre o meio ambiente. Isso a fim de preservar sempre a produtividade e a qualidade das terras de forma que melhore as condições sociais, econômicas e ambientais de produtores e consumidores de alimentos (WALTERS *et al.*, 2016).

Diante da necessidade de resposta quanto à disponibilização de alimentos, bem como a segurança alimentar mundial necessária, a agricultura enfatiza o uso de determinados insumos com a finalidade de aumentar o rendimento por área, além de alcançar maior eficiência na força de trabalho. Todavia, o uso desenfreado desses insumos pode contribuir negativamente quando não aplicado na quantidade adequada sobre o cultivo, fortalecendo as questões de não sustentabilidade na produção, que vão desde as diminuições ou depredações de recursos naturais, até não alcançar os objetivos econômicos finais da cultura para o produtor (AMINI *et al.*, 2019; FAR; REZAEI-MOGHADDAM, 2018). Dessa maneira, as premissas da agricultura sustentável e segurança alimentar são considerados os principais desafios do mundo para alcançar uma produção que atenda às necessidades da população, uma vez que a segurança alimentar permite disponibilização do alimento com qualidade e a sustentabilidade considera a resiliência dos agroecossistemas (MWALUPASO *et al.*, 2019).

Considerando os desafios lançados pela FAO quanto à necessidade de produção agrícola, foi recomendado que o setor agrícola investisse em soluções que otimizassem o rendimento por área. Assim, para o alcance desses resultados, é necessário um acompanhamento da cultura de forma sistematizada que pode ser obtido com a implantação de ferramentas de tecnologia da informação, ou seja, implantação de infraestruturas, como o caso da centralização de dados em um banco de dados espacial, que contemple não somente a mensuração da variável, mas também sua localização geográfica para posterior análise (TRILLES *et al.*, 2019).

Logo, será necessário o desenvolvimento de um futuro agrícola que minimize o uso de insumos, diminuindo os problemas de dependências com produtos químicos, com integração da diversidade biológica. Isso para o aumento da qualidade de estruturas físicas do solo, de forma a manter condições ideais de produção com menores impactos, porém, visando também ao desenvolvimento socioeconômico (CHABERT; SARTHOU, 2020).

4.2 Sensoriamento remoto na agricultura

Atualmente, a agricultura passa por um momento de pressão para maiores produções devido ao contexto global de necessidade de alimentos. Devido a isso, várias metodologias são utilizadas de forma a obter previsões e monitorar condições a respeito do desenvolvimento de culturas.

Há décadas, vem sendo utilizado o sensoriamento remoto para monitoramento, em que, a partir de faixas espectrais (também conhecidas como bandas espectrais), na faixa do visível e infravermelho, se torna possível estimar determinados parâmetros de culturas, como

o de cobertura fracionária da vegetação, cobertura de resíduos da cultura e solo exposto (YUE; TIAN, 2020).

O sensoriamento remoto pode ser utilizado para várias finalidades, como ferramenta para a agricultura, gerando informações, a saber, previsão, que subsidiam decisões sobre irrigação, identificação de ervas daninhas, dentre outros elementos que influenciam diretamente o impacto econômico final do desenvolvimento de culturas. Assim, todas essas variáveis podem ser monitoradas a partir de plataformas orbitais (satélites), como também com o uso de veículos aéreos não tripulados (drones), a partir de sensores que atuam sobre os alvos de forma ativa ou passiva (WEISS; JACOB; DUVEILLER, 2020).

Alguns casos de uso que consideram o sensoriamento remoto na agricultura são tecnologias para irrigação inteligente, fertilização inteligente, controle inteligente de pragas, previsão e detecção de doenças, tendo, como parâmetros analisados, a temperatura, pressão, umidade relativa, umidade do solo e folhas, além de índices de radiação, sob uma determinada periodicidade que atenda às necessidades de análises para os cultivos (POPOVIĆ *et al.*, 2017).

Em escalas de resolução espacial de 250m, já foram realizados inventários de culturas no Paquistão, utilizando sensoriamento remoto com o uso de plataformas orbitais com sensor MODIS e algoritmos de classificação, identificando, assim, diferentes culturas em períodos de 2005 a 2012. Assim, chegou-se à conclusão sobre as produções dominantes de arroz e trigo nos anos analisados (USMAN *et al.*, 2020).

Em larga escala na China, pesquisas são realizadas com o intuito de se obter observações espaço-temporais, analisando dados de sensor MODIS para obter estimativa de rendimento da produtividade do arroz. Isso para que pudessem subsidiar a necessidade crescente de demanda por alimentos ao avaliar a potencialidade da capacidade produtiva dos agricultores (WANG *et al.*, 2020).

Da mesma forma, tais imagens permitem gerar o mapeamento da distribuição espacial de tipos de solo, considerada variável de relevância para a agricultura de precisão, haja vista que, atualmente, a base de dados de tipo de solo é de baixa precisão. Dessa maneira, utilizando-se dessas ferramentas, com características hipertemporais, é possível verificar as nuances de mudanças do solo ao longo dos anos, gerando, assim, uma base mais confiável a ser utilizada (YANG *et al.*, 2020).

Com o uso de SR, também é possível verificar, sob a utilização de imagens Landsat (sensor OLI - Operation Land Imager), a sua aplicação na determinação de áreas aptas para o desenvolvimento de culturas, considerando tais dados em conjunto com outros dados históricos, de maneira a se perceber os requisitos inerentes ao processo agrícola, como

precipitação, temperatura, declividade, tipo de solo e umidade, entre outros (AL-TAANI; AL-HUSBAN; FARHAN, 2020).

Ao longo dos anos, diversos métodos vêm sendo utilizados para obter informações com base em sensores de baixa resolução espacial (resolução acima de 30m), de forma a melhorar a identificação de alvos considerando a limitação dessa resolução para identificação de alvos menores. Ademais, destaca-se o processo de fusão de bandas, que permite preservar mais dados espectrais de determinados pixels, contribuindo, assim, para a determinação da variável estudada (ZHANG *et al.*, 2020).

Porém, cabe ressaltar que, em grandes escalas, esses dados podem contribuir com informações sobre áreas cultivadas apoiando decisões a respeito de importação e exportação de alimentos, diferentemente de escalas locais, de maneira que é necessária uma maior resolução espacial que possa contribuir ao agricultor na decisão quanto ao manejo de sua cultura, ajudando, dessa maneira, a incrementar sua produção (NABIL *et al.*, 2020).

Nesse caso, o uso de imagens de maiores resoluções (abaixo de 30m) tem sido considerada, resultando em maiores processamentos com análises mais precisas de áreas menores, conseqüentemente, necessitando de uma maior infraestrutura para processamento dessa informação (MOHAMMED *et al.*, 2020).

Para isso, soluções não gratuitas, como a PlanetScope, permitem a obtenção de dados com alta resolução espaço-temporal, possibilitando a realização de estimativas da biomassa acima do solo de culturas de cobertura, de forma que, correlacionando posteriormente com o rendimento final, é possível estabelecer mapas de zonas de manejo para as áreas estudadas (BREUNIG *et al.*, 2020).

Uma outra possibilidade é o uso de drones, que atualmente são considerados em classificação de culturas com incremento da precisão da informação, uma vez que eles possibilitam altas resoluções, tanto espaciais como espectrais, permitindo realizar classificações orientadas a objetos, que atualmente se demonstram melhores que as classificadas com algoritmos aplicados a pixel, ou seja, são realizados processos de segmentação gerando um objeto e classificando-o posteriormente (ZHAO *et al.*, 2020).

No Brasil, estudos utilizam a câmera Parrot embarcada em drones para estimar, por meio das bandas de comprimento de onda vermelho e infravermelha, o NDVI da cultura, em que, em conjunto com uma equação que define a taxa de aplicação de defensivos na plantação, pode-se minimizar custos devido a aplicações desnecessárias ou perdas por deriva (SOUZA *et al.*, 2020).

Para o contexto do agricultor, muitas vezes, as imagens de plataformas não gratuitas são muito caras e as questões de resolução espaço-temporal ainda podem deixar a desejar

considerando o custo benefício devido à interferência de condições climáticas ou tempo de revisita (RADOGLOU-GRAMMATIKIS *et al.*, 2020).

4.3 Agricultura de precisão

A competitividade atual do mercado alinhada à necessidade crescente de produção impulsiona o setor agrícola a buscar soluções cada vez mais precisas que permitam tornar suas produções mais rentáveis, com maior qualidade e possíveis de serem inseridas no mercado.

Atualmente, diversas nomenclaturas são utilizadas para tecnologias que buscam monitoramento constante de lavouras, como o caso de agricultura de precisão, smart farm, big data, aprendizagem de máquinas, entre outros, que possuem basicamente a função de possibilitar ao produtor o acesso às informações de processos produtivos, como ciclos produtivos, variabilidade espacial de saúde da lavoura e temporalidade de informações. Isso possibilita que sejam correlacionadas de forma a gerar prognósticos para a realização de maximização dos processos produtivos por meio de práticas sustentáveis que minimizem impactos econômicos e ambientais, com a execução de intervenções pontuais, como os casos de aplicações de taxa variável para controle fitossanitário, eficiência na irrigação, entre outros (MORAIS *et al.*, 2019).

O termo agricultura de precisão tem por finalidade definir uma área de estudo com o objetivo de garantir as características de sustentabilidade de culturas, considerando seus aspectos sociais, econômicos e ambientais, a partir da utilização de ferramentas de tecnologia da informação que garantem respostas pontuais sobre integridade e produtividade da lavoura. Para tanto, uma mudança de paradigma dos produtores vem acontecendo, em que incorporam, em suas atividades, o uso de equipamentos modernos, que permitem a coleta de uma gama de dados, os quais podem ser posteriormente processados, resultando em informações de maneira ágil sobre seu cultivo (KHANNA; KAUR, 2019).

Em suma, a agricultura contempla, em sua essência, 4 etapas, a saber, evidenciadas na Figura 2:




Figura 2 - Etapas contempladas na agricultura de precisão

A obtenção de dados consiste no uso de técnicas, como as de sensoriamento remoto, coletas em campo, ferramentas de geoprocessos e outros que possam subsidiar uma base de dados a ser processada.

O sensoriamento remoto e seus diferentes métodos contribuem significativamente para a caracterização atual de áreas produtivas. Zahran, Saeed e Elazizy (2022) mencionam métodos diretos com índices que monitoram a intensidade de clorofila nas plantas, classificação de imagens rotulando categorias e identificando níveis de crescimentos, comparação de períodos que permitem status de desenvolvimento de culturas, considerando padrões históricos, comparações históricas de dados de produção, modelos de cultivos, entre outros. Assim, concluem que dados obtidos por sensoriamento remoto combinados a outras ferramentas de geotecnologias permitem alcançar precisões relacionadas à produtividade que podem alcançar de 85 a 95%, sendo assim, consideradas técnicas de monitoramento que, quando aliadas a diferentes sistemas de medição, podem proporcionar uma melhora constante na gestão de recursos utilizados durante o processo produtivo.

O processamento torna-se uma grande oportunidade para o setor agrícola, uma vez que, diante do exemplo de dados de sensoriamento remoto, podem ser ajustados para atenderem a demandas específicas de propriedades, gerando informação útil a partir dos sensores, que podem possibilitar a geração de informação em uma escala que atenda às características de variabilidade espacial e temporal necessária à agricultura (BROOK *et al.*, 2020).

Da Silva *et al.* (2022) mencionam ainda que índices de vegetação gerados a partir de sensoriamento remoto possuem alta relevância aos aspectos de determinação e compreensão de balanços energéticos da vegetação, contribuindo nos aspectos relacionados ao solo, planta e atmosfera. Ademais, é aplicável ao setor agrícola ao viabilizar monitoramento constante da produção com o uso de imagens orbitais que favorecem o entendimento de variáveis correlacionadas, as quais caracterizam o comportamento de alterações da energia sobre a superfície. A indisponibilidade hídrica também é um dos fatores que podem influenciar diretamente o crescimento da vegetação e produtividade de culturas. Atualmente, o uso de diferentes índices e, em especial, o NDVI é amplamente considerado em processos de correlação com secas agrícolas, haja vista que a deficiência na intensidade de clorofila pode ter relação direta com aspectos de umidade do solo, sendo considerado, assim, o índice mais utilizado para esse tipo de monitoramento em culturas (KAUR; RISHI; CHAUDHARY, 2022).

Assim, **a tomada de decisão** está alinhada aos aspectos relevantes à produtividade de culturas que precisam ser monitorados por meio de tecnologias que permitam agilidade no processo de coleta de dados e geração de informações sobre essas variáveis, haja vista que as culturas tendem a se caracterizar por grandes áreas que podem sofrer alterações dessas variáveis diariamente, ou seja, podendo sofrer alterações em seu desenvolvimento (MUKHERJEE; MISRA; RAGHUWANSHI, 2019).

Dessa maneira, considerando as 3 etapas anteriores, é possível realizar de fato a **atuação em campo**, em que a agricultura de precisão e suas tecnologias incorporadas permitem monitorar a qualidade do potencial produtivo, bem como subsidiar ações para potencializar essa produção, uma vez que seu principal objetivo consiste em melhorar o uso de recursos, minimizar o custo de insumos e gerenciar a lavoura sob uma maior proximidade. Isso pode torná-la uma ferramenta indispensável para atender aos anseios de necessidade de produções globais, pois esse planejamento local reflete diretamente na qualidade e quantidade produzida (BARNES *et al.*, 2019).

A agricultura de precisão pode ainda ser caracterizada pela realização de atividades na lavoura no momento e lugar adequado, considerando as intensidades de ações corretas a serem aplicadas, sob um planejamento subsidiado por técnicas digitais que utilizam imagens de satélites ou drones, sensores, equipamentos com precisão de localização e de dosagem de insumos que otimizam processos e minimizam impactos (EZENNE *et al.*, 2019).

As pesquisas destinadas a essa área foram iniciadas a partir de meados da década de 80, tendo, como propulsores, os Estados Unidos, Canadá, Austrália e Europa Ocidental, que, embora tenham tido grandes investimentos realizados nos estudos, poucos foram os produtores que incorporaram a implantação de novas tecnologias e métodos estudados (ALLAHYARI; MOHAMMADZADEH; NASTIS, 2016).

Na Irlanda, em pastagens, são utilizadas técnicas de agricultura de precisão para avaliar a qualidade do crescimento de grama na região, pois, com a utilização de sensoriamento remoto e verificando a intensidade do índice vegetativo, é possível identificar as áreas com crescimento inadequado. Isso contribui, assim, para a análise de qualidade dos prados, permitindo ações imediatas para aplicação de nutrientes que favorecerão o crescimento vegetativo adequado para alimentação de bovinos da região, melhorando a qualidade de produção de leite desse setor (HIGGINS; SCHELLBERG; BAILEY, 2019).

Outra aplicabilidade consiste no uso de levantamento de dados e processamento para determinação de zonas de manejo específicas a aplicação de insumos, permitindo o uso de ferramentas convencionais em substituição às tecnologias com maior custo, sendo mais interessantes para pequenos e médio produtores (MÉNDEZ-VÁZQUEZ *et al.*, 2019).

Identificação de estresse por seca, detecção de patógenos, ervas daninhas, estado de nutrientes, vigor de crescimento, previsão de rendimento, são outras variáveis que podem ser analisadas com o uso de sensoriamento remoto na agricultura de precisão, mais especificamente com imagens RGB, Multiespectrais, hiperespectrais e térmicas, em que algumas dessas imagens possuem características específicas considerando a finalidade necessária como resultado (MAES; STEPPE, 2019).

Dessa maneira, no momento em que produtores se adequam para internalizar os conceitos de agricultura de precisão em suas culturas, um aumento da eficiência produtiva, minimização dos custos e redução de pegadas ambientais é visto, permitindo um gerenciamento correto da produção. Além disso, demonstra a variabilidade de suas condições de culturas e possíveis impactos que possam ser minimizados com práticas mais adequadas (KHANAL; FULTON; SHEARER, 2017).

4.4 Geotecnologias aplicadas na agricultura

Nos últimos anos, tem ocorrido um aumento das pesquisas realizadas por Instituições que visam utilizar as geotecnologias para as questões de engenharia reversa e também controles de segurança sob uma determinada temporalidade, em que o uso de imagens ópticas em conjunto com outros formatos de dados são processadas pelas mais diversas ferramentas existentes (GONZALEZ-AGUILERA *et al.*, 2012).

Um exemplo é a realização de prognósticos de áreas sob diversos temas que permitem aos tomadores de decisões, com o uso de geotecnologias, otimizar de maneira prévia os recursos humanos e materiais para as áreas com maior necessidade de ações, pois, a partir de um gerenciamento mais assertivo, é possível realizar ações de prevenção e recuperação de possíveis alterações no território analisado (SHARMA; MISRA; SINGH, 2019). Tais

possibilidades corroboram a necessidade da agricultura, quando a busca por informações prévias de condições de culturas é crucial para despender os recursos adequados visando à maior produtividade.

Na agricultura, essas tecnologias podem ser utilizadas para análises de susceptibilidade à salinização de solos, demonstrando a sua espacialização e evolução no tempo-espaço, o que também contribui para a caracterização do local a ser cultivado (CASTRO; ARAÚJO; DOS SANTOS, 2019). Além disso, essas ferramentas são utilizadas para a definição de zoneamentos agroclimatológicos, permitindo a percepção das áreas com maiores aptidões de desenvolvimento, bem como para monitorar a questão de aplicação de defensivos agrícolas, mantendo, assim, a segurança alimentar sobre os alimentos produzidos (DOS SANTOS *et al.*, 2016).

Os estudos relacionados à previsão de safras e identificação de diferentes variedades de soja também necessitam do uso das geotecnologias, uma vez que a assinatura espectral de alvos obtidas com equipamentos *in loco* ou até mesmo por imagens ópticas estão com seu uso cada vez mais difundido, conseqüentemente, gerando mais estudos científicos para proporcionar respostas pertinentes aos interessados (DA SILVA JUNIOR *et al.*, 2018). É o caso de regiões do Egito, que utilizaram sensoriamento remoto e geoprocessamento para determinar a qualidade do solo quanto à prática de seus respectivos manejos, sendo avaliados 29 parâmetros que geraram informações sobre a qualidade do solo da região classificadas como muito alta, alta, moderada, baixa e com baixa qualidade para produção. Assim, servem como base na relação da previsibilidade de capacidade produtiva de áreas (ABUZAID; ABDELLATIF; FADL, 2020).

No Brasil, o uso de geotecnologias permitiu estabelecer um banco de dados de espectros de solos brasileiros desde 1995, definindo seis padrões básicos de assinaturas representativas dos solos brasileiros, com subsídio de planejamentos em conjunto com dados de umidade. Isso contribui com informações para determinação de aplicação de manejo adequado (DEMATTE *et al.*, 2019).

Logo, as diversas geotecnologias existentes, como banco de dados geográficos, sistemas de informações geográficas, sistemas webgis, tecnologias gps, ferramentas de sensoriamento remoto, entre outras, são atualmente presentes em qualquer área com necessidade mínima de planejamento territorial (TROUILLET, 2019).

Dessa maneira, as ferramentas de geotecnologias permitem tornar a agricultura mais robusta, a ponto de monitorar e controlar os processos de forma mais automatizada, integrando respostas a partir de base de dados geradas previamente, como também ao utilizar soluções que proporcionam a geração de informações em tempo real, favorecendo o desenvolvimento produtivo, com uma grande quantidade de variáveis de influência.

4.5 Banco de dados geográficos Postgres

Com o aumento de tecnologias existentes para obtenção de dados agrícolas, torna-se necessária uma infraestrutura de dados que permita armazenar, compartilhar e processar os dados de forma centralizada, permitindo a integração de diversas fontes e possibilitando sua interpretação adequada (BAZZI *et al.*, 2019).

Determinados conjuntos de dados gerados podem ser armazenados e processados com a utilização de banco de dados geográficos e um sistema gerenciador de banco de dados, cabendo ressaltar, ainda, que a infraestrutura optada deve ser acessível, com custos não elevados e com padrões de dados que permitam sua integração com outras fontes, uma vez que esses aspectos determinam a adoção ou não das tecnologias (KAMILARIS; KARTAKOULLIS; PRENAFETA-BOLDÚ, 2017).

Dados em formato vetor, raster, tabulares, ou de séries climáticas podem ser armazenados e recuperados de um banco de dados quando necessário, além de possibilitar integração com outras aplicações conforme as necessidades de desenvolvedores (MANNA *et al.*, 2020).

Infraestruturas de Banco de dados Postgres e sua extensão espacial Postgis foram utilizadas como elemento central em pesquisas com a finalidade de armazenar dados de alto desempenho de agricultura arável, visando subsidiar uma ferramenta *opensource* a ser utilizada para operação de máquinas em campo em processos de aplicação de taxa variável de pulverização (KAIVOSOJA *et al.*, 2014). Tal elemento demonstra a capacidade das soluções *opensource* atenderem às necessidades no âmbito de análise espacial, pois permitem, com a integração de sua extensão espacial Postgis, uma melhora no armazenamento de dados geográficos, operadores e funções espaciais para análise e indexação espacial, além de permitir uma conectividade com softwares de geoprocessamento, possibilitando uma visualização dos dados (JÄGER *et al.*, 2018).

Quanto à robustez do software, é considerado a ferramenta de banco de dados de código aberto mais avançada existente, mantendo a integridade dos dados, velocidade, gerenciamento dos dados sob diferentes níveis de usuários, acesso simultâneo, confidencialidade de informações e recuperação delas por meio de um cliente (TRUMPY; MANZELLA, 2017).

Além disso, o banco de dados Postgres apresenta muitos recursos e melhores desempenhos para uso em grande volume de dados, possuindo características de armazenamento e trabalhos com dados em tempo real (CAO; WACHOWICZ, 2019). Tais elementos são primordiais para o uso com dados de agricultura de precisão devido ao

armazenamento e processamento de um grande volume de dados para obtenção das informações de interesse ao setor agrícola.

4.6 Python

Python é uma linguagem de programação popular presente desde 2021, que aumentou a produtividade no tratamento de dados na comunidade científica visando à substituição de outras linguagens compiladas por sua característica dinâmica, em que muitas bibliotecas de código aberto são disponibilizadas e permitem o tratamento de dados com características espaciais utilizados em ambientes SIG's (LIEGEOIS; PEREGO; HARTLAND, 2023; MARTIN *et al.*, 2023).

Podemos destacar que a linguagem trata tudo como objeto ocupando determinado espaço em memória, controlando, assim, possíveis referências de memórias desnecessárias e consequentemente criando aumento de recursos necessários para execução de processos onerosos (CHEN *et al.*, 2023).

Atualmente, com o crescimento de disponibilização de dados de diferentes fontes e padrões, torna-se necessário o uso de ferramentas que possam contribuir para o tratamento, considerando os padrões necessários para obtenção de informações.

Chen, Judge e Hulse (2022) mencionam que a linguagem Python, a partir da disponibilização de seus diversos módulos geoespaciais, como Fiona, Shapely, Geopandas e GDAL, proporciona de maneira rápida e flexível o tratamento de diversos dados em processos de tratamento e análises de dados tabulares ou rasters, permitindo ao usuário o desenvolvimento de ferramentas geoespaciais com finalidades específicas.

Além dos módulos anteriormente mencionados, podemos também destacar as interfaces de programação de aplicativos (API) desenvolvidas em Python para obtenção de dados de plataformas específicas, como o caso do Google Earth Engine, por meio do pacote geemap desenvolvido em Python, responsável pelo processamento e análise de imagens disponibilizadas pela plataforma. Assim, é possível manter os dados em um ambiente de desenvolvimento que proporciona mais liberdade ao desenvolvedor (VANDERHOOF *et al.*, 2023).

Tal liberdade permite ao desenvolvedor criar métodos específicos de determinado projeto, proporcionando, assim, agilidade e eficácia na resolução dos problemas levantados, por meio de uma ferramenta específica a um determinado tema sem a necessidade de custos com licenças ou dificuldades de serem utilizadas por outros usuários (BARBOSA *et al.*, 2022).

4.7 GEE – Google Earth Engine

Com o advento da internet e difusão de geração de dados que alcançam níveis considerados de *BIG DATA*, plataformas surgem de forma a disponibilizar essas informações em ambiente web para usuários. Dentre elas, podemos destacar o Google Earth Engine que, em sua essência, disponibiliza um ambiente de processamento de imagens de satélites de diferentes fontes em ambiente de nuvem (GHOSH; KUMAR; KUMARI, 2022a; LIANG *et al.*, 2023; ROBERTS *et al.*, 2022).

A plataforma oferece petabytes de dados globais de diferentes sensores, como os presentes nas famílias Landsat, Modis, Sentinel, além de dados relacionados às temáticas de clima, temperatura, ecologia, economia, entre outros, que podem, em conjunto de suas funcionalidades, gerar informações relevantes sobre determinada área de estudo, minimizando a carga de trabalho quando o aspecto é aquisição e processamento de dados (ZHAO *et al.*, 2023). Ghosh, Kumar e Kumari (2022a) reafirmam que o acesso às fontes de sensores já processadas e a disponibilização de tais informações, com um mínimo esforço, agiliza o alcance de resultados, haja vista que processos onerosos de download e processamento não são necessários, o que facilita o processo de levantamento histórico da área a ser analisada.

Além da disponibilização de informações, a plataforma possui mais de 800 funções em linguagem JavaScript para processamento de dados em larga escala, algoritmos para classificação de imagens sobre técnicas supervisionadas e não supervisionadas, como também filtros que permitem o levantamento de fontes sobre determinados períodos de maneira ágil (GHOSH; KUMAR; KUMARI, 2022b).

Assim, o GEE é considerado um ambiente de processamento de dados espaciais obtidos por sensoriamento remoto mais avançado do mundo, que supera a deficiência encontrada por muitos usuários no levantamento de informações e processamento de dados em estruturas próprias devido às suas limitações físicas em comparação à estrutura disponibilizada pela plataforma (NGHIA *et al.*, 2022).

4.8 Sistemas de informações geográficas

SIG - Sistemas de informações geográficas são caracterizados por serem ferramentas que possibilitam condições para adquirir, armazenar e processar dados geográficos, resultando em informações espaciais demonstradas a partir de visualizações que permitam aos seus usuários utilizá-las para maior entendimento do território, bem como subsidiar seu planejamento (SANTOS *et al.*, 2016).

Tomar decisões sobre o território tem sido considerada uma das principais atividades dos diferentes setores, sendo utilizada a análise espacial para seleção de locais, adequação de uso de terras, identificação de áreas mais vulneráveis, além de possibilitar a escolha de melhores áreas para implantação de determinadas atividades, considerando suas características (MAHMOODY VANOLYA; JELOKHANI-NIARAKI; TOOMANIAN, 2019).

Durante décadas, as ferramentas SIG subsidiam a coleta de grande quantidade de dados que, quando parametrizados, possibilitam a consulta e processamento de forma integrada com o ambiente de visualização, permitindo a geração de mapas digitais que facilitam o entendimento do território, subsidiando a ação mais adequada a ser realizada quanto à variável analisada (ELIDRISSI *et al.*, 2020).

Correlacionar e sobrepor diversas fontes de dados geográficos são outras características inerentes aos GIS, as quais viabilizam, assim, a análise de tendências, comportamentos e características relevantes que subsidiem o planejamento de metas (ações), por meio da definição de áreas com maior necessidade de atenção (ALZAGHRINI; SROUR; SROUR, 2019).

Na agricultura, o mapeamento da produção, bem como a distribuição espacial de algumas variáveis, permitem ao produtor avaliar benefícios ou danos econômicos quanto à sua produção, possibilitando potencializar seus lucros a partir de um manejo adequado e planejado sobre uma visão de mapas (características) combinadas e sobrepostas sobre a sua área (RADOGLUO-GRAMMATIKIS *et al.*, 2020).

Como exemplo, podemos ressaltar a restrição quanto ao uso de água doce para produção agrícola como um grande impeditivo para o desenvolvimento de culturas, além de gerar um impacto econômico ao pequeno produtor, que, nesses casos, necessita optar por sistemas de abastecimento de baixo custo (VALENCIA *et al.*, 2020).

Dessa maneira, o uso dessas ferramentas fortalece a eficiência do uso desse recurso em sistemas de irrigação da agricultura, pois é possível determinar a melhor região para cada tipo de sistemas, contribuindo diretamente para a tomada de decisões quanto a essa prática (NEISSI; ALBAJI; BOROOMAND NASAB, 2020).

Existem também aplicações do uso de GIS em conjunto com outras técnicas que possibilitam obter respostas relevantes para a agricultura, como o caso de utilização do GIS com *AHP – Analytic Hierarchy Process*, para avaliação da aptidão de terras para determinadas culturas, considerando os atributos do solo, fatores climáticos, entre outras variáveis, nas quais são atribuídas seus respectivos pesos e, no final, identificam-se as regiões com melhores condições para desenvolvimento de culturas (PILEVAR *et al.*, 2020).

Além das ferramentas usuais de geoprocessamento presentes em GIS, esses softwares apresentam ainda a capacidade de espacializar o comportamento de uma área sob

uma variável por meio de um número determinado de amostras em conjunto com interpoladores, gerando, assim, mapas temáticos que podem demonstrar o comportamento dessas variáveis. Um exemplo disso é a espacialização do comportamento de carbono orgânico armazenado no solo por meio dessas ferramentas (ZHANG; ZHOU; HUANG, 2020).

4.9 Redes Neurais artificiais

Redes neurais artificiais - RNA's são modelos matemáticos não lineares que, por meio de um aprendizado projetado para que aconteça, conforme o sistema nervoso biológico, permitem a simulação de estruturas definidas por camadas de entrada, ocultas e camadas de saída de forma a subsidiar o relacionamento das ligações entre diferentes variáveis (LIU *et al.*, 2020b).

O uso dessa técnica considera as variáveis de entrada, pesos para cada variável de entrada, somador e uma função de ativação que possibilita identificar padrões ou gerar modelos para classificação ou predição de variáveis. Assim, seus valores de entrada são multiplicados pelos seus respectivos pesos de entrada e a soma ponderada dos valores subsidia a função de ativação para limitar o intervalo de saída (linear, limiar ou sigmoide), de forma que possibilite a obtenção do resultado final (NGUYEN; NONG; PAUSTIAN, 2019).

Em linhas gerais, RNA's são sistemas que processam informações de forma distribuída, considerando a relevância e impacto de cada variável de entrada sobre a variável final a partir de um conhecimento experimental de aprendizagem dos neurônios, tornando, assim, seu aprendizado disponível para a resolução de resposta a uso posterior (MASHALY; ALAZBA, 2017).

Na construção de estruturas de RNA, deve-se considerar a existência de banco de dados confiável, arquitetura do modelo, treinamento e validação, lembrando que a quantidade de neurônios nas camadas e nós ocultos são obtidos realizando tentativas e erros que permitam avaliar os melhores parâmetros para alcançar o nível de confiança desejado na saída (MAHMOODI; TAGHIZADEH; TAGHIZADEH, 2018). As diferentes arquiteturas de RNA's podem ser classificadas de acordo com sua complexidade estrutural, sendo as mais conhecidas as redes Perceptron, Hamming e Recorrente (LIU; LIANG; LIU, 2018).

Uma das aplicações conhecidas na agricultura de precisão com o uso de redes neurais consiste na identificação de pragas a partir de processos de aquisição de imagens RGB, processamentos, segmentação e classificação de elementos visando reconhecer qual tipo de inseto está afetando a cultura (ESPINOZA *et al.*, 2016).

Em processos de agricultura e nas indústrias agroalimentares, estruturas de redes neurais são utilizadas para predizer a biomassa de sementes de macaúba, chegando à

predição de variáveis do peso seco com precisão de até 98% após o treinamento da rede, favorecendo, assim, os processos de avaliação do potencial de produtividade (CASTRO *et al.*, 2017).

Da mesma forma, quanto à produtividade agrícola, elementos, como nitrogênio, fósforo e potássio, estão diretamente relacionados ao resultado final da produção e, quando aplicados em pouca ou muita dosagem, podem vir a prejudicar economicamente os resultados finais da cultura. Na China, o uso de redes neurais permitiu estabelecer uma relação entre esses elementos, estimando a quantidade adequada a ser aplicada, chegando a resultados de mapas de rendimentos estimados próximos aos mapas de rendimentos reais. Isso possibilita, assim, uma proposta aplicável ao manejo de culturas da região (DONG *et al.*, 2020).

Fatores ambientais, como clima, temperatura e umidade, são elementos extremamente importantes para o desenvolvimento das culturas, em que a seca pode afetar o rendimento das culturas e, em muitos casos, seus métodos de monitoramentos são clássicos com visualização das alterações em campo, muitas vezes, com respostas quando os problemas já estão presentes.

Métodos de redes neurais aplicadas à identificação de teor de umidade no solo permitem correlacionar a distribuição da água no solo e a previsão de crescimento de plantas a partir de dados coletados remotamente para treinamento da RNA, chegando a resultados que demonstram que, mesmo em condições climáticas variadas, o uso de RNA permite chegar a resultados mais assertivos quanto à estimativa de umidade no solo (CHATTERJEE; DEY; SEN, 2018).

Kaul, Hill e Walthall (2005) apresentam, em seu estudo, que a integração de dados de produtividade de milho e soja, em conjunto com dados históricos de precipitação semanais e de caracterização do solo das áreas produtivas, como parâmetros de entrada de redes neurais, permitiu alcançar taxas na ordem de 0,77 a 0,90 nas previsões de rendimento das culturas, ou seja, demonstrando-se como opções até mesmo mais precisas que modelos de regressão.

Dentre as estruturas de redes neurais e suas aplicações, podemos considerar as Redes neurais artificiais, utilizadas em processos de classificação e regressão; Redes neurais convolucionais utilizadas em questões de visão computacional; Redes neurais recorrentes para análise de series temporais; Mapas auto-organizáveis com sua eficiência na detecção de características e agrupamentos; *Botzmann machines* usadas para sistemas de recomendação, redução de dimensionalidade; Autoencoders, também aplicadas à redução de dimensionalidade e redes adversariais generativas para geração de imagens.

Quanto ao treinamento ou aprendizado de redes neurais, é realizado a partir da alteração dos pesos de conexão entre os neurônios, de forma a alcançar sua representatividade ideal quanto à variável final a ser classificada ou estimada.

As alterações de pesos podem ocorrer de forma supervisionada, com um banco de dados que representa a realidade final do dado, ou não supervisionada, em que não existe uma relação entre variáveis de entrada e saída (verdade final atribuída às variáveis), de forma que a rede atualiza seus respectivos pesos conforme a similaridade de dados analisados.

Basicamente, uma rede neural supervisionada é formada por camadas de entrada, camadas ocultas e camadas de saída, em que as camadas de entrada são as variáveis que possam vir a ter relação explicativa sobre a camada de saída; as camadas ocultas fazem a conexão com neurônios de entrada, somatória dos pesos e função de ativação, além de possuir a função de aproximar os dados de saída considerando pesos e desvios de cada conexão (STOFFEL *et al.*, 2020).

Dessa maneira, cada link, visualizado na Figura 3, tem um peso utilizado para multiplicar o valor do neurônio conectado a ele, sendo realizada essa ação a todas as outras conexões e finalmente efetivando um somatório de forma ao resultado ser inserido na função de ativação, que resultará no valor do próximo neurônio, seguindo o mesmo processo para quantas camadas existirem até alcançar a camada de saída. Alguns estudos já consideram o uso de estruturas de redes que contemplem operações recorrentes e convolucionais (convLSTM) sobre dados espaço-temporais, considerando suas arquiteturas multidimensionais aplicadas em conjunto com sensoriamento remoto principalmente na aplicação de classificações de uso e cobertura do solo (IENCO *et al.*, 2019).

Redes convLSTM foram utilizadas para modelar a produção de mapas de previsão de safras no início do cultivo, quando foi identificada uma capacidade da rede neural no aprendizado de tendências históricas comparadas a outros métodos, representando um potencial na previsão, quando utilizadas imagens obtidas por sensoriamento remoto para gerar uma base de dados histórica, dos anos de 2002 a 2016, sendo aplicados dois tipos de modelos: Rede neural profunda e Cadeia de Markov, em que a primeira se apresentou mais satisfatória na validação sobre imagens de 2018 (YARAMASU; BANDARU; PNVR, 2020).

Basicamente, a formulação do problema consiste na geração de uma janela fixa (série temporal) de forma a prever os próximos dias através de uma janela deslizante, ou seja, movendo a janela deslizante em um passo, torna-se possível a previsão do próximo valor (GAO *et al.*, 2020; XIAO *et al.*, 2019).




Figura 3 - Estrutura de rede neural artificial - Em verde, a representação da camada de entrada de dados; em azul, camadas ocultas, e, em vermelho, a camada de saída. As linhas representam as conexões entre os neurônios

Na validação dos modelos, gerados a partir de arquitetura da RNA, pode ser utilizado o método K-fold, considerado comum para avaliação de desempenho da predição de modelos de rede, que, em sua concepção, divide aleatoriamente os dados em n conjuntos de forma que, em etapas distintas, cada conjunto se torne o conjunto para avaliar o desempenho da rede, e o restante dos dados sejam utilizados para treinamento (HUANG *et al.*, 2016).

Assim, de posse da rede estruturada e com o processo de aprendizagem sendo realizado, podem ser utilizadas equações de cálculos de erro, como o MAE – *Mean absolute error* (erro médio absoluto), MSE – *Mean square error* (erro médio quadrático), MAPE – *Mean absolute percentage error* (erro percentual médio absoluto), RMSE – *Root mean square error* (raiz do erro quadrático médio), entre outros, que permitirão verificar a qualidade da rede ajustada (AHMADI *et al.*, 2020). Dessa maneira, os valores de pesos são atualizados de forma a alcançarem os valores previstos para atendimento da necessidade final, bem como também colaborar na necessidade de interpretabilidade final dos resultados, que são passos extremamente importantes para a sua aplicação, uma vez que a maioria dos processos de predição de dados necessitam de transparência quanto à sua confiabilidade (HE; MA; WANG, 2020).

Dessa maneira, é possível verificar a capacidade de obtenção de informações e estimativas a respeito do tema agricultura de precisão com o uso de técnicas de rede neural

de forma a potencializar ferramentas SIG, as quais, quando trabalhadas em conjunto, podem gerar subsídios e dados que contribuem com o agricultor e analistas na tomada de decisões para um maior desenvolvimento de sua produção, considerando aspectos econômicos e ambientais.

REFERÊNCIAS

ABBASIMEHR, H.; SHABANI, M.; YOUSEFI, M. An optimized model using LSTM network for demand forecasting. **Computers & Industrial Engineering**, [s.l.], v. 143, p. 106435, 2020.

ABUZAID, A. S.; ABDELLATIF, A. D.; FADL, M. E. Modeling soil quality in Dakahlia Governorate, Egypt using GIS techniques. **The Egyptian Journal of Remote Sensing and Space Science**, [s.l.], v. 23, n. 1, p. 57-65, jan., 2020.

ADOM, P. K.; ADAMS, S. Decomposition of technical efficiency in agricultural production in Africa into transient and persistent technical efficiency under heterogeneous technologies. **World Development**, [s.l.], v. 129, p. 104907, mai., 2020.

AHMADI, M. H. *et al.* Prediction of the pressure drop for CuO/(Ethylene glycol-water) nanofluid flows in the car radiator by means of Artificial Neural Networks analysis integrated with genetic algorithm. **Physica A: Statistical Mechanics and its Applications**, [s.l.], v. 540, p. 124008, jan., 2020,

AL-TAANI, A.; AL-HUSBAN, Y.; FARHAN, I. Land suitability evaluation for agricultural use using GIS and remote sensing techniques: The case study of Ma'an Governorate, Jordan. **The Egyptian Journal of Remote Sensing and Space Science**, [s.l.], v. 23, n. 1, p. 91-99, fev. 2020.

ALLAHYARI, M. S.; MOHAMMADZADEH, M.; NASTIS, S. A. Agricultural experts' attitude towards precision agriculture: Evidence from Guilan Agricultural Organization, Northern Iran. **Information Processing in Agriculture**, [s.l.], v. 3, n. 3, p. 183-189, set., 2016.

ALZAGHRINI, N.; SROUR, F. J.; SROUR, I. Using GIS and optimization to manage construction and demolition waste: The case of abandoned quarries in Lebanon. **Waste Management**, [s.l.], v. 95, p. 139-149, jul., 2019.

AMINI, S. *et al.* Assessment of land suitability and agricultural production sustainability using a combined approach (Fuzzy-AHP-GIS): A case study of Mazandaran province, Iran. **Information Processing in Agriculture**, [s.l.], v. 6, n. 4, p. 565-578, out. 2019.

BARBOSA, B. *et al.* Automatic detection of vegetation cover changes in urban-rural interface areas. **MethodsX**, [s.l.], v. 9, p. 101643, 2022.

BARNES, A. P. *et al.* Exploring the adoption of precision agricultural technologies: A cross regional study of EU farmers. **Land Use Policy**, [s.l.], v. 80, p. 163-174, jan., 2019.

BAZZI, C. L. *et al.* AgDataBox API – Integration of data and software in precision agriculture. **SoftwareX**, [s.l.], v. 10, p. 100327, jul., 2019.

BEGUM NASIR AHMAD, N. S. *et al.* A systematic review of soil erosion control practices on the agricultural land in Asia. **International Soil and Water Conservation Research**, [s.l.], v. 8, n. 1, p. 1-10, 2020.

BEYER, M. *et al.* Deep spatial-temporal graph modeling for efficient NDVI forecasting. **Smart Agricultural Technology**, [s.l.], v. 4, p. 100172, 2023.

BREUNIG, F. M. *et al.* Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 85, p. 102004, mar., 2020.

BROOK, A. *et al.* A smart multiple spatial and temporal resolution system to support precision agriculture from satellite images: Proof of concept on Aglianico vineyard. **Remote Sensing of Environment**, [s.l.], v. 240, p. 111679, abr., 2020.

CAMICIA, R. G. DA M. *et al.* Productivity of soybean in management zones with application of different sowing densities. **Ciência Rural**, [s.l.], v. 48, n. 12, 6 dez. 2018.

CAO, H.; WACHOWICZ, M. The design of an IoT-GIS platform for performing automated analytical tasks. **Computers, Environment and Urban Systems**, [s.l.], v. 74, p. 23–40, mar. 2019.

CASTRO, C. A. DE O. *et al.* High-performance prediction of macauba fruit biomass for agricultural and industrial purposes using Artificial Neural Networks. **Industrial Crops and Products**, [s.l.], v. 108, p. 806-813, dez., 2017.

CASTRO, F. C.; ARAÚJO, J. F.; DOS SANTOS, A. M. Susceptibility to soil salinization in the quilombola community of Cupira - Santa Maria da Boa Vista - Pernambuco – Brazil. **CATENA**, [s.l.], v. 179, p. 175-183, ago., 2019.

CHABERT, A.; SARTHOU, J.-P. Conservation agriculture as a promising trade-off between conventional and organic agriculture in bundling ecosystem services. **Agriculture, Ecosystems & Environment**, [s.l.], v. 292, p. 106815, abr., 2020.

CHATTERJEE, S.; DEY, N.; SEN, S. Soil moisture quantity prediction using optimized neural supported model for sustainable agricultural applications. **Sustainable Computing: Informatics and Systems**, [s.l.], v. 20, p. 113-121, set., 2018.

CHEN, C.; JUDGE, J.; HULSE, D. PyLUSAT: An open-source Python toolkit for GIS-based land use suitability analysis. **Environmental Modelling & Software**, [s.l.], v. 151, p. 105362, 2022.

CHEN, J. *et al.* Pattern-based circular reference detection in Python. **Science of Computer Programming**, [s.l.], v. 227, p. 102932, 2023.

CHEN, P. *et al.* Occurrence prediction of cotton pests and diseases by bidirectional long short-term memory networks with climate and atmosphere circulation. **Computers and Electronics in Agriculture**, [s.l.], v. 176, p. 105612, 2020.

DA SILVA, J. L. B. *et al.* Spatiotemporal dynamics of agricultural areas with central pivot using orbital remote sensing in the Brazilian semi-arid. **Smart Agricultural Technology**, [s.l.], v. 2, p. 100052, 2022.

DA SILVA JUNIOR, C. A. *et al.* Soybean varieties discrimination using non-imaging hyperspectral sensor. **Infrared Physics & Technology**, [s.l.], v. 89, p. 338-350, mar., 2018.

DE RANGO, F. *et al.* Scalable and lightweight bio-inspired coordination protocol for FANET in precision agriculture applications. **Computers & Electrical Engineering**, [s.l.], v. 74, p. 305-318, mar., 2019.

DEMATTÊ, J. A. M. *et al.* The Brazilian Soil Spectral Library (BSSL): A general view, application and challenges. **Geoderma**, [s.l.], v. 354, p. 113793, nov., 2019.

DONG, Y. *et al.* Precision fertilization method of field crops based on the Wavelet-BP neural network in China. **Journal of Cleaner Production**, [s.l.], v. 246, p. 118735, fev., 2020.

DOS SANTOS, G. M. A. D. A. *et al.* GIS applied to agroclimatological zoning and agrotoxin residue monitoring in tomatoes: A case study in Espírito Santo state, Brazil. **Journal of Environmental Management**, [s.l.], v. 166, p. 429-439, jan., 2016.

ELIDRISSI, S. *et al.* New application of GIS and statistical analysis in mapping the distribution of quaternary calcrete (Tensift Al Haouz area, Central Morocco). **CATENA**, [s.l.], v. 188, p. 104419, mai., 2020.

ESPINOZA, K. *et al.* Combination of image processing and artificial neural networks as a novel approach for the identification of Bemisia tabaci and Frankliniella occidentalis on sticky traps in greenhouse agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 127, p. 495-505, set., 2016.

EZENNE, G. I. *et al.* Current and potential capabilities of UAS for crop water productivity in precision agriculture. **Agricultural Water Management**, [s.l.], v. 218, p. 158-164, jun., 2019.

FAO. **FAO. How to feed the world in 2050?** [s.l.: s.n.]. Disponível em: http://www.fao.org/fileadmin/templates/wsfs/docs/expert_paper/How_to_Feed_the_World_in_2050.pdf. Acesso em: 16 abr. 2023.

FAR, S. T.; REZAEI-MOGHADDAM, K. Impacts of the precision agricultural technologies in Iran: An analysis experts' perception & their determinants. **Information Processing in Agriculture**, [s.l.], v. 5, n. 1, p. 173-184, mar., 2018.

FASTELLI, L.; ROVAI, M.; ANDREOLI, M. A Spatial Integrated Database for the Enhancement of the Agricultural Custodianship Role (SIDECAR)—Some preliminary tests using Tuscany as a case-study Region. **Land Use Policy**, [s.l.], v. 78, p. 791-802, 2018.

FENG, L. *et al.* Multi-scale change monitoring of water environment using cloud computing in optimal resolution remote sensing images. **Energy Reports**, [s.l.], v. 8, p. 13610-13620, 2022.

GAO, S. *et al.* Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. **Journal of Hydrology**, [s.l.], v. 589, p. 125188, 2020.

GHOSH, S.; KUMAR, D.; KUMARI, R. Cloud-based large-scale data retrieval, mapping, and analysis for land monitoring applications with Google Earth Engine (GEE). **Environmental Challenges**, [s.l.], v. 9, p. 100605, 2022a.

GHOSH, S.; KUMAR, D.; KUMARI, R. Google earth engine based computational system for the earth and environment monitoring applications during the COVID-19 pandemic using thresholding technique on SAR datasets. **Physics and Chemistry of the Earth, Parts A/B/C**, [s.l.], v. 127, p. 103163, 2022b.

GONZALEZ-AGUILERA, D. *et al.* From point cloud to CAD models: Laser and optics geotechnology for the design of electrical substations. **Optics & Laser Technology**, [s.l.], v. 44, n. 5, p. 1384-1392, jul., 2012.

HE, C.; MA, M.; WANG, P. Extract interpretability-accuracy balanced rules from artificial neural networks: A review. **Neurocomputing**, [s.l.], v. 387, p. 346-358, abr., 2020.
HIGGINS, S.; SCHELLBERG, J.; BAILEY, J. S. Improving productivity and increasing the efficiency of soil nutrient management on grassland farms in the UK and Ireland using precision agriculture technology. **European Journal of Agronomy**, [s.l.], v. 106, p. 67-74, mai. 2019.

HUANG, Y. W. *et al.* Modeling of chemical exergy of agricultural biomass using improved general regression neural network. **Energy**, [s.l.], v. 114, p. 1164-1175, nov., 2016.

IENCO, D. *et al.* Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v. 158, p. 11-22, 2019.

JÄGER, D. *et al.* A spatial database for landslides in northern Bavaria: A methodological approach. **Geomorphology**, [s.l.], v. 306, p. 283-291, abr., 2018.

JANSSEN, S. *et al.* A database for integrated assessment of European agricultural systems. **Environmental Science & Policy**, [s.l.], v. 12, n. 5, p. 573-587, 2009.

JHA, K. *et al.* A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, [s.l.], v. 2, p. 1-12, 2019.

JIANG, N.; LI, P.; FENG, Z. Remote sensing of swidden agriculture in the tropics: A review. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 112, p. 102876, 2022.

JUNG, D.-H. *et al.* Time-series analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. **Computers and Electronics in Agriculture**, [s.l.], v. 173, p. 105402, 2020.

KAIVOSOJA, J. *et al.* Automatic control of farming operations based on spatial web services. **Computers and Electronics in Agriculture**, [s.l.], v. 100, p. 110-115, jan., 2014.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 143, p. 23-37, dez., 2017.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, [s.l.], v. 147, p. 70-90, 2018.

KAUL, M.; HILL, R. L.; WALTHALL, C. Artificial neural networks for corn and soybean yield prediction. **Agricultural Systems**, [s.l.], v. 85, n. 1, p. 1-18, 2005.

KAUR, L.; RISHI, M. S.; CHAUDHARY, B. S. Assessment of meteorological and agricultural droughts using remote sensing and their impact on groundwater in an agriculturally productive part of Northwest India. **Agricultural Water Management**, [s.l.], v. 274, p. 107956, 2022.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 139, p. 22-32, jun., 2017.

KHANNA, A.; KAUR, S. Evolution of Internet of Things (IoT) and its significant impact in the field of Precision Agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 157, p. 218-231, fev., 2019.

LIANG, J. *et al.* WS4GEE: Enhancing geospatial web services and geoprocessing workflows by integrating the Google Earth Engine. **Environmental Modelling & Software**, [s.l.], v. 161, p. 105636, 2023.

LIEGEOIS, K.; PEREGO, M.; HARTLAND, T. PyAlbany: A Python interface to the C++ multiphysics solver Albany. **Journal of Computational and Applied Mathematics**, [s.l.], v. 425, p. 115037, 2023.

LIU, H. *et al.* An overview of stability analysis and state estimation for memristive neural networks. **Neurocomputing**, [s.l.], v. 379, p. 302-316, jan., 2020a.

LIU, X. *et al.* A remote sensing and artificial neural network-based integrated agricultural drought index: Index development and applications. **CATENA**, [s.l.], v. 186, p. 104394, mar., 2020b.

LIU, Z.-W.; LIANG, F.-N.; LIU, Y.-Z. Artificial neural network modeling of biosorption process using agricultural wastes in a rotating packed bed. **Applied Thermal Engineering**, [s.l.], v. 140, p. 95-101, jul., 2018.

MAES, W. H.; STEPPE, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. **Trends in Plant Science**, [s.l.], v. 24, n. 2, p. 152-164, fev., 2019.

MAHMOODI, N. M.; TAGHIZADEH, M.; TAGHIZADEH, A. Mesoporous activated carbons of low-cost agricultural bio-wastes with high adsorption capacity: Preparation and artificial neural network modeling of dye removal from single and multicomponent (binary and ternary) systems. **Journal of Molecular Liquids**, [s.l.], v. 269, p. 217-228, 1 nov. 2018.

MAHMOODY VANOLYA, N.; JELOKHANI-NIARAKI, M.; TOOMANIAN, A. Validation of spatial multicriteria decision analysis results using public participation GIS. **Applied Geography**, [s.l.], v. 112, p. 102061, nov., 2019.

MANNA, P. *et al.* A geospatial decision support system to assist olive growing at the landscape scale. **Computers and Electronics in Agriculture**, [s.l.], v. 168, p. 105143, jan., 2020.

MARTIN, H. *et al.* Trackintel: An open-source Python library for human mobility analysis. **Computers, Environment and Urban Systems**, [s.l.], v. 101, p. 101938, 2023.

MASHALY, A. F.; ALAZBA, A. A. Thermal performance analysis of an inclined passive solar still using agricultural drainage water and artificial neural network in arid climate. **Solar Energy**, [s.l.], v. 153, p. 383-395, set., 2017.

MÉNDEZ-VÁZQUEZ, L. J. *et al.* Delineation of site-specific management zones for pest control purposes: Exploring precision agriculture and species distribution modeling approaches. **Computers and Electronics in Agriculture**, [s.l.], v. 167, p. 105101, dez., 2019.

MIGUEL LENZ, A. *et al.* Expansion of eucalyptus energy plantations under a Livestock-Forestry Integration scenario for agroindustries in Western Paraná, Brazil. **Ecological Indicators**, [s.l.], v. 98, p. 39-48, 2019.

MOHAMMED, I. *et al.* A blended census and multiscale remote sensing approach to probabilistic cropland mapping in complex landscapes. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v. 161, p. 233–245, 1 mar. 2020.

MORAIS, R. *et al.* mySense: A comprehensive data management environment to improve precision agriculture practices. **Computers and Electronics in Agriculture**, [s.l.], v. 162, p. 882-894, jul., 2019.

MUKHERJEE, A.; MISRA, S.; RAGHUWANSHI, N. S. A survey of unmanned aerial sensing solutions in precision agriculture. **Journal of Network and Computer Applications**, [s.l.], v. 148, p. 102461, dez., 2019.

MUNAWAR, A. A. *et al.* Calibration models database of near infrared spectroscopy to predict agricultural soil fertility properties. **Data in Brief**, [s.l.], v. 30, p. 105469, 2020.

MWALUPASO, G. E. *et al.* Recuperating dynamism in agriculture through adoption of sustainable agricultural technology - Implications for cleaner production. **Journal of Cleaner Production**, [s.l.], v. 232, p. 639-647, set., 2019.

NABIL, M. *et al.* Assessing factors impacting the spatial discrepancy of remote sensing based cropland products: A case study in Africa. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 85, p. 102010, mar. 2020.

NEISSI, L.; ALBAJI, M.; BOROOMAND NASAB, S. Combination of GIS and AHP for site selection of pressurized irrigation systems in the Izeh plain, Iran. **Agricultural Water Management**, [s.l.], v. 231, p. 106004, mar., 2020.

NEVAVUORI, P.; NARRA, N.; LIPPING, T. Crop yield prediction with deep convolutional neural networks. **Computers and Electronics in Agriculture**, [s.l.], v. 163, p. 104859, 2019.

NGHIA, B. P. Q. *et al.* Applying Google earth engine for flood mapping and monitoring in the downstream provinces of Mekong river. **Progress in Disaster Science**, [s.l.], v. 14, p. 100235, 2022.

NGUYEN, T. H.; NONG, D.; PAUSTIAN, K. Surrogate-based multi-objective optimization of management options for agricultural landscapes using artificial neural networks. **Ecological Modelling**, [s.l.], v. 400, p. 1-13, mai., 2019.

NGUYEN, T. T. *et al.* Monitoring agriculture areas with satellite images and deep learning. **Applied Soft Computing**, [s.l.], v. 95, p. 106565, 2020.

PERAKIS, K. *et al.* CYBELE – Fostering precision agriculture & livestock farming through secure access to large-scale HPC enabled virtual industrial experimentation environments fostering scalable big data analytics. **Computer Networks**, [s.l.], v. 168, p. 107035, fev., 2020.

PILEVAR, A. R. *et al.* Integrated fuzzy, AHP and GIS techniques for land suitability assessment in semi-arid regions for wheat and maize farming. **Ecological Indicators**, [s.l.], v. 110, p. 105887, mar., 2020.

POPOVIĆ, T. *et al.* Architecting an IoT-enabled platform for precision agriculture and ecological monitoring: A case study. **Computers and Electronics in Agriculture**, [s.l.], v. 140, p. 255-265, ago., 2017.

RADOGLU-GRAMMATIKIS, P. *et al.* A Compilation of UAV Applications for Precision Agriculture. **Computer Networks**, [s.l.], p. 107148, fev., 2020.

RAY, C. *et al.* Heterogeneous integrated dataset for Maritime Intelligence, surveillance, and reconnaissance. **Data in Brief**, [s.l.], v. 25, p. 104141, 2019.

ROBERTS, J. F. *et al.* Pyeo: A Python package for near-real-time forest cover change detection from Earth observation using machine learning. **Computers & Geosciences**, [s.l.], v. 167, p. 105192, 2022.

RUPNIK, R. *et al.* AgroDSS: A decision support system for agriculture and farming. **Computers and Electronics in Agriculture**, [s.l.], v. 161, p. 260-271, 2019.

SABU, K. M.; KUMAR, T. K. M. Predictive analytics in Agriculture: Forecasting prices of Arecanuts in Kerala. **Procedia Computer Science**, [s.l.], v. 171, p. 699-708, 2020.

SANTOS, A. R. DOS *et al.* Geotechnology and landscape ecology applied to the selection of potential forest fragments for seed harvesting. **Journal of Environmental Management**, [s.l.], v. 183, p. 1050-1063, dez., 2016.

SHARMA, R. *et al.* A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. **Computers & Operations Research**, [s.l.], v. 119, p. 104926, 2020.

SHARMA, S. K.; MISRA, S. K.; SINGH, J. B. The role of GIS-enabled mobile applications in disaster management: A case analysis of cyclone Gaja in India. **International Journal of Information Management**, [s.l.], p. 102030, nov., 2019.

SILBERGELD, E. K. One health and the agricultural transition in food animal production. **Global Transitions**, [s.l.], v. 1, p. 83-92, jan., 2019.

SOUZA, F. H. Q. *et al.* The use of vegetation index via remote sensing allows estimation of soybean application rate. **Remote Sensing Applications: Society and Environment**, [s.l.], v. 17, p. 100279, jan., 2020.

SRIVASTAVA, K. *et al.* UAVs technology for the development of GUI based application for precision agriculture and environmental research. **Remote Sensing Applications: Society and Environment**, [s.l.], v. 16, p. 100258, nov., 2019.

STOFFEL, M. *et al.* Artificial neural networks in structural dynamics: A new modular radial basis function approach vs. convolutional and feedforward topologies. **Computer Methods in Applied Mechanics and Engineering**, [s.l.], v. 364, p. 112989, jun., 2020.

SU, Y. *et al.* Quantifying the sustainability of three types of agricultural production in China: An emergy analysis with the integration of environmental pollution. **Journal of Cleaner Production**, [s.l.], v. 252, p. 119650, abr., 2020.

TAHMASEBI, P. *et al.* Machine learning in geo- and environmental sciences: From small to large scale. **Advances in Water Resources**, [s.l.], v. 142, p. 103619, 2020.

TRILLES, S. *et al.* Development of an open sensorized platform in a smart agriculture context: A vineyard support system for monitoring mildew disease. **Sustainable Computing: Informatics and Systems**, [s.l.], jan., 2019.

TROUILLET, B. Aligning with dominant interests: The role played by geo-technologies in the place given to fisheries in marine spatial planning. **Geoforum**, [s.l.], v. 107, p. 54-65, dez., 2019.

TRUMPY, E.; MANZELLA, A. Geothopica and the interactive analysis and visualization of the updated Italian National Geothermal Database. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 54, p. 28-37, fev., 2017.

USMAN, M. *et al.* Numerical modelling and remote sensing based approaches for investigating groundwater dynamics under changing land-use and climate in the agricultural region of Pakistan. **Journal of Hydrology**, [s.l.], v. 581, p. 124408, fev., 2020.

VALENCIA, J. *et al.* A GIS-based methodological framework to identify superficial water sources and their corresponding conduction paths for gravity-driven irrigation systems in developing countries. **Agricultural Water Management**, [s.l.], v. 232, p. 106048, abr., 2020.

VANDERHOOF, M. K. *et al.* High-frequency time series comparison of Sentinel-1 and Sentinel-2 satellites for mapping open and vegetated water across the United States (2017–2021). **Remote Sensing of Environment**, [s.l.], v. 288, p. 113498, 2023.

WALTERS, J. P. *et al.* Exploring agricultural production systems and their fundamental components with system dynamics modelling. **Ecological Modelling**, [s.l.], v. 333, p. 51-65, ago., 2016.

WANG, J. *et al.* Integrating remote sensing-based process model with environmental zonation scheme to estimate rice yield gap in Northeast China. **Field Crops Research**, [s.l.], v. 246, p. 107682, fev., 2020.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, [s.l.], v. 236, p. 111402, jan., 2020.

WU, Q. *et al.* Integrating LiDAR data and multi-temporal aerial imagery to map wetland inundation dynamics using Google Earth Engine. **Remote Sensing of Environment**, [s.l.], v. 228, p. 1-13, 2019.

WU, Q. geemap: A Python package for interactive mapping with Google Earth Engine. **The Journal of Open Source Software**, [s.l.], v. 5, p. 2305, 2020.

XIA, Y. *et al.* Agricultural chemicals use data access using coldfusion markup language and a relational database. **Computers and Electronics in Agriculture**, [s.l.], v. 38, n. 3, p. 217-225, 2003.

XIAO, C. *et al.* A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data. **Environmental Modelling & Software**, [s.l.], v. 120, p. 104502, 2019.

XU, X. *et al.* Application of neural network algorithm in fault diagnosis of mechanical intelligence. **Mechanical Systems and Signal Processing**, [s.l.], p. 106625, jan., 2020.

YANG, H. *et al.* Hyper-temporal remote sensing data in bare soil period and terrain attributes for digital soil mapping in the Black soil regions of China. **CATENA**, [s.l.], v. 184, p. 104259, jan. 2020.

YARAMASU, R.; BANDARU, V.; PNVR, K. Pre-season crop type mapping using deep neural networks. **Computers and Electronics in Agriculture**, [s.l.], v. 176, p. 105664, 2020.

YUE, J.; TIAN, Q. Estimating fractional cover of crop, crop residue, and soil in cropland using broadband remote sensing data and machine learning. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 89, p. 102089, jul., 2020.

YUE, Y. *et al.* Prediction of maize growth stages based on deep learning. **Computers and Electronics in Agriculture**, [s.l.], v. 172, p. 105351, 2020.

ZAHARAN, S. A. E.-S.; SAEED, R. A.-H.; ELAZIZY, I. M. Remote sensing based water resources and agriculture spatial indicators system. **The Egyptian Journal of Remote Sensing and Space Science**, [s.l.], v. 25, n. 2, p. 515-527, 2022.

ZHANG, M. *et al.* Image fusion employing adaptive spectral-spatial gradient sparse regularization in UAV remote sensing. **Signal Processing**, [s.l.], v. 170, p. 107434, mai. 2020.

ZHANG, Z.; ZHOU, Y.; HUANG, X. Applicability of GIS-based spatial interpolation and simulation for estimating the soil organic carbon storage in karst regions. **Global Ecology and Conservation**, [s.l.], v. 21, p. e00849, mar., 2020.

ZHAO, F. *et al.* Extraction of long time series wetland information based on Google Earth Engine and random forest algorithm for a plateau lake basin – A case study of Dianchi Lake, Yunnan Province, China. **Ecological Indicators**, [s.l.], v. 146, p. 109813, 2023.

ZHAO, J. *et al.* A robust spectral-spatial approach to identifying heterogeneous crops using remote sensing imagery with high spectral and spatial resolutions. **Remote Sensing of Environment**, [s.l.], v. 239, p. 111605, mar., 2020.

ZHOU, B.; OKIN, G. S.; ZHANG, J. Leveraging Google Earth Engine (GEE) and machine learning algorithms to incorporate in situ measurement from different times for rangelands monitoring. **Remote Sensing of Environment**, [s.l.], v. 236, p. 111521, 2020.

ARTIGO 1 – INFRAESTRUTURA DE DADOS ESPACIAIS COM PROCESSOS DE ANÁLISES AUTOMATIZADAS PARA A AGRICULTURA

RESUMO: A atividade agrícola no Brasil necessita de soluções que permitam monitorar ou prever condições que favoreçam seu desenvolvimento, considerando dados que venham a interpretar possíveis necessidades de correções ou ações mais assertivas durante o processo produtivo. Usualmente, índices relacionados ao solo, clorofila e umidade podem contribuir no diagnóstico de produtividade de áreas cultiváveis, sendo utilizados por analistas na avaliação local de forma a contribuir em ações mais assertivas relacionadas a essa produção. O levantamento dessas informações normalmente é oneroso, necessitando da realização de vários procedimentos e processamentos que tornam dispendiosa a realização de análises. Dessa maneira, este artigo tem como objetivo automatizar processos para geração de índices relevantes à agricultura com a utilização de imagens Sentinel 2 - MSI, uso da fonte de dados disponibilizada na plataforma Google Earth Engine, em conjunto com linguagem Python e banco de dados Postgres. Foi verificado que os processos de automatização permitiram gerar base de dados históricas com todos os valores de índices para uma área delimitada, facilitando, assim, a utilização dessas informações históricas para análises e uso em outros processamentos que possam avaliar as condições atuais com a interpretação histórica dos índices. A base de dados consistiu na consolidação de scripts Python que permitem a busca, download e processamento de imagens, armazenando, em banco de dados, produtos consolidados de 16 índices relacionados à umidade, solo e clorofila, contemplando suas respectivas médias e uma estrutura (dashboard) que permite a busca e interpretação facilitada das informações por seus usuários.

Palavras-chave: Python. PostgreSQL. Índices para agricultura.

SPATIAL DATA INFRASTRUCTURE WITH AUTOMATED ANALYSIS PROCESSES FOR AGRICULTURE

ABSTRACT: The agricultural activity in Brazil needs solutions that allow monitoring or predicting conditions that favor its development, considering data that will interpret possible needs for corrections or more assertive actions during the production process. Usually, indexes related to soil, chlorophyll, and humidity can contribute to the diagnosis of productivity in cultivable areas, used by analysts in local evaluation to contribute to more assertive actions related to this production. The collection of this information is usually onerous, requiring the performance of several procedures and processes that make the analysis expensive. Thus, this paper aims to automate processes for generating relevant indices to agriculture using Sentinel 2 - MSI images, using the data source available on the Google Earth Engine platform, in conjunction with Python language and Postgres database. Results showed that the automation processes allowed the generation of a historical database with all index values for a delimited area, thus facilitating the use of this historical information for analysis and use in other processes that can evaluate current conditions with the historical interpretation of the indices. The database consisted of the consolidation of Python scripts that allow the search, download, and processing of images, storing in consolidated database products of 16 indexes related to moisture, soil, and chlorophyll, contemplating their respective averages, and a dashboard that allows easy search and interpretation of the information by its users.

Keywords: Python. PostgreSQL. Indices for agriculture.

1 INTRODUÇÃO

A atividade agrícola e seu constante crescimento necessita de soluções que permitam monitorar ou prever condições que favoreçam seu desenvolvimento, considerando dados que venham a interpretar possíveis necessidades de correções ou ações mais assertivas durante o processo de cultivo.

Um exemplo são processos de erosão do solo, considerado um dos elementos que geram impacto para os resultados da agricultura, os quais, em sua maioria, ocorrem devido a práticas agrícolas realizadas de maneira inadequada, que resultam em perda excessiva do solo (desagregação ou compactação de partículas, devido à exposição do solo ou manejo inadequado), ou até mesmo à geração de impactos ocasionados por causa do carreamento de nutrientes e sedimentos sobre o corpo hídrico. Isso prejudica, assim, a qualidade de águas e ecossistemas (BEGUM NASIR AHMAD *et al.*, 2020).

Dessa forma, ações de monitoramento de qualidade do solo, bem como características que venham a contribuir para o desenvolvimento de culturas são primordiais para manter a saúde e qualidade do solo às práticas agrícolas, consequentemente, melhorando as condições para alcançar melhores resultados nos processos produtivos (MUNAWAR *et al.*, 2020).

Quanto ao monitoramento das variáveis relacionadas à agricultura (umidade, solo e clorofila), um dos gargalos consiste na integração dessa base de dados, que, devido às diversas fontes existentes e distribuídas sobre diferentes formas dificultam o monitoramento ágil, uma vez que tal monitoramento deve considerar interpretações, estatísticas e indicadores de diversas informações (JANSSEN *et al.*, 2009).

Uma base de dados consolidada das variáveis relevantes ao setor agrícola, sendo analisada com ferramentas GIS, é de extrema importância, uma vez que diversos elementos competem ou interagem com o uso da terra. Diante disso, a partir de análises detalhadas sobre as variáveis levantadas, torna-se possível avaliar as questões econômicas que podem ser influenciadas por possíveis alterações, permitindo, assim, realizar estratégias agrícolas diferenciadas para aceitação pelo mercado (FASTELLI; ROVAI; ANDREOLI, 2018).

A consolidação dessa base pode ser realizada com a utilização de banco de dados, ou seja, estruturas usadas atualmente para o desenvolvimento de sistemas de informação na agricultura, em que a relação de cada elemento é representada por tabelas com os respectivos dados da variável de interesse, podendo ser consultada por outras ferramentas que potencializam a análise do dado armazenado (XIA *et al.*, 2003).

Além disso, com a grande quantidade de dados que pode ser armazenada nessa estrutura, sua análise pode ser realizada com a utilização de ferramentas de aprendizagem

de máquinas, permitindo uma análise avançada, com a identificação de padrões nos dados que permitem utilização na potencialização de informações que contribuam para o processo produtivo (SHARMA *et al.*, 2020).

Quanto a fonte de dados, uma grande variedade de ferramentas é disponibilizada para obtenção de informações. Dentre as fontes conhecidas, sensores orbitais disponibilizam informações a nível de refletância de alvos, que, com seus devidos tratamentos e processamentos, permitem gerar informações relevantes a usuários. Todavia, cabe ressaltar que, atualmente, o processo de obtenção a partir dessas fontes de dados é oneroso, exigindo grandes tempos de processamento, além de considerar o download de imagens e, em alguns casos, pré-processamento, visando de fato alcançar resultados que são de interesse para a produção de uma determinada área agrícola.

A análise de dados de sensores orbitais teve grande evolução nos últimos anos, com pré-processamentos realizados em imagens e sua disponibilização em formatos, que já atendem a realização de diversas análises em plataformas específicas, como o caso do Google Earth Engine, em que é só possível verificar o banco de dados nele existente, como também realizar alguns processamentos utilizando seus algoritmos e seu poder de infraestrutura (ZHOU; OKIN; ZHANG, 2020).

Dessa maneira, este artigo tem por objetivo estruturar um ambiente de obtenção de dados, utilizando as ferramentas Google Earth Engine e sua api disponibilizada, linguagem Python e Banco de Dados Postgres, de forma a estabelecer uma base de dados temporal de índices que contemplem os aspectos de umidade, solo e clorofila que possa ser utilizada para realização de análises e relações entre eles, consideradas relevantes ao processo produtivo de determinada área agrícola. Isso contribui, assim, para o monitoramento da região, bem como ao possível aumento de produtividade com ações assertivas relacionadas ao manejo da área de interesse, quando visualizadas alterações no comportamento de tendências, ou seja, indicando anomalias que necessitem de atenção.

2 MATERIAIS E MÉTODOS

A área de estudo para levantamento prioritário de informações está localizada na região sul do Brasil, no Município de Céu Azul, próximo ao limite do Parque Nacional do Iguaçu, coordenadas $25^{\circ} 06'32.7''\text{S}$ $53^{\circ} 49'57.8''\text{W}$, com aproximadamente 22 ha de área, como evidenciado na Figura 4.




Figura 4 - a) Localização Município de Céu Azul b) Localização área experimental Aldo Tasca

A região da área de estudo é caracterizada pelo sistema de plantio direto de culturas de soja, milho, trigo e aveia, apresentando algumas áreas ocupadas por pastagens e com clima classificado como úmido subtropical, com precipitações e temperaturas que variam em 1850 mm e 22°C durante o ano (CAMICIA *et al.*, 2018; MIGUEL LENZ *et al.*, 2019).

A elaboração e implantação considerou três etapas, a saber: a) Implantação de banco de dados geográficos para dados de agricultura obtidas por sensoriamento remoto (imagens Sentinel 2) de uma área previamente delimitada; b) Utilização de linguagem python e plataforma Google Earth Engine integradas para download de informações; c) Alimentação de banco de dados geográficos e uso de módulos python para análise de dados incorporados 1.




Figura 5 - Fluxo e ferramentas utilizadas na construção do banco

2.1. Implantação de banco de dados geográficos para dados de agricultura obtidas por sensoriamento remoto

O banco de dados armazena as informações de diferentes fontes de dados, bem como viabiliza a execução de tarefas e apresentação de resultados a partir da relação entre o conjunto de dados armazenados em sua estrutura com o uso de outras ferramentas e linguagens de programação (RUPNIK *et al.*, 2019).

Assim, um banco de dados PostgreSQL versão 12.14 foi criado, denominado “agriculture”, e sua implantação efetivou-se pela instalação da extensão espacial Postgis; os planos de informações foram armazenados no banco de dados por meio do schema “public”, possibilitando maior organização dos dados e facilidade na inserção e recuperação.

O banco de dados possui como padrão esse schema “public”, em que foram criadas tabelas denominadas stats e stats_estimated para armazenar as informações obtidas da área de estudo.




Figura 6 - Estrutura criada em banco de dados PostgreSQL

Com a implementação da estrutura de banco de dados PostgreSQL + Postgis, não é possível somente o armazenamento dos dados, mas também o tratamento de todos os dados com recursos para análise espacial a partir de sua extensão, por meio do processamento de dados diretamente no sistema de gerenciamento do banco (RAY *et al.*, 2019). Logo, a integração do banco com outra linguagem de programação permitiu seu uso para os tratamentos e processamentos de dados inerentes ao estudo.

2.2. Utilização de linguagem Python e plataforma Google Earth Engine

Para realização de integração entre a plataforma Google Earth Engine e linguagem Python, foi utilizado o módulo Python ee - earth-engine, que se trata de uma api que permite acesso aos dados da plataforma, bem como trabalhar seus dados diretamente com o uso de outros módulos da linguagem Python, consequentemente, aumentando a liberdade sobre o processamento dessa base para geração de resultados finais relevantes para a agricultura quando armazenados em uma estrutura de controle próprio do usuário, como o banco de dados Postgres.

Para a execução das ferramentas citadas, foi criado um ambiente virtual, que permite a execução de códigos Python com a utilização do módulo “ee” da Google.

Cabe ressaltar que, dentre os passos para execução dos códigos, utilizando a plataforma, é necessário que o usuário possua uma conta registrada na plataforma Google Earth Engine, de forma que possa acessá-la a partir da autenticação do módulo.

Essa etapa considerou os seguintes passos para a execução:

- Importação do módulo: Módulo que permite acesso às funcionalidades e dados da api Google Earth Engine;
- Autenticação de usuário: A partir de um token disponibilizado pela Earth engine, é autorizado o acesso do usuário;
- Estruturação do código para variáveis relevantes: implementação de códigos que permitam a obtenção de informações de forma automatizada na plataforma Google Earth Engine;
- Apresentação das informações: Utilização de bibliotecas python para apresentação dos resultados.

2.2.1. Importação de módulos e autenticação de usuário

A implementação das funcionalidades contempladas na pesquisa considerou, além do uso de módulos nativos, a utilização de outros módulos desenvolvidos por terceiros.

O módulo geemap foi utilizado de forma que possibilitasse o carregamento de um mapa base que permitisse, por meio da feição de um polígono, gerar o bounding box da área de busca de imagens na plataforma Earth Engine.

As informações e funcionalidades do módulo geemap podem ser acessadas em <https://github.com/giswqs/geemap/tree/master/geemap> (WU, 2020; WU *et al.*, 2019).

Para a leitura e processamento de rasters, foi utilizado o módulo rasterio (<https://pypi.org/project/rasterio/>), que tem como principal característica a capacidade de organizar e armazenar os dados raster, possibilitando a realização de processos que consideram as bandas durante sua importação.

2.2.2. Estruturação de códigos para variáveis relevantes

Considerando a área de estudo, foi realizado um levantamento dos índices possíveis de serem gerados a partir do sensor MSI – MultiSpectral Instrumet, que trabalha passivamente.

A estruturação de códigos contemplou a definição de uma área de estudo, para que, a partir disso, pudesse gerar uma base de dados consistente, considerando os índices apresentados na Tabela 1, obtidos a partir da fonte sentinel hub custom scripts (<https://custom-scripts.sentinel-hub.com/#sentinel-2>).

Tabela 1 - Índices utilizados no levantamento de base de dados

Abreviação	Nome	Equação
ATSAVI	Adjusted transformed soil-adjusted VI	$1.22 * (b08 - 1.22 * b04 - 0.03) / (1.22 * b08 + b04 - 1.22 * 0.03 + 0.08 * (1.0 + 1.22^{**2}))$
ARI	Anthocyanin reflectance index	$1.0 / b03 - 1.0 / b05$
AVI	Ashburn Vegetation Index	$2.0 * b09 - b04$
ARVI	Atmospherically Resistant Vegetation Index	$(b09 - b04 - 0.106 * (b04 - b02)) / (b09 + b04 - 0.106 * (b04 - b02))$
CHLGREEN	Chlorophyll Green	$(b07/b03)^{-1}$
Fe3+	Ferric iron	$b04/b03$
Fo	Ferric oxides	$b11/b08$
GVM	Global vegetation Moisture Index	$((b08 + 0.1) - (b12 + 0.02)) / ((b08 + 0.1) + (b12 + 0.02))$
GNDVI	Green normalized Difference Vegetation Index	$(b8 - b3) / (b8 + b3)$
LCI	Leaf chlorophyll index	$(b08 - b05) / (b08 + b04)$
NDMI	Normalize difference Moisture index	$(b08 - b11) / (b08 + b11)$
EVI	Enhanced Vegetation Index	$2.5 * (b08 - b04) / ((b08 + 6 * b04 - 7.5 * b02) + 1)$
NDVI	Normalized Difference Vegetation Index	$(b08 - b04) / (b08 + b04)$
SCI	Soil composition index	$(b11 - b08) / (b11 + b08)$
SAVI	Soil adjusted Vegetation Index	$(b08 - b04) / (b08 + b04 + 0.428) * (1.0 + 0.428)$
CTVI	Corrected Transformed Vegetation Index	$((((b04 - b03) / (b04 + b03)) + 0.5) / \text{abs}(((b04 - b03) / (b04 + b03)) + 0.5)) * \sqrt{\text{abs}(((b04 - b03) / (b04 + b03)) + 0.5))$

Os índices selecionados consideraram o levantamento de informações quanto às variáveis direta ao solo (composição, umidade) e índices que pudessem indicar a quantidade de clorofila presente (proporcionando o vigor da vegetação).

Os códigos para obtenção da informação e geração de visualizações dos índices são demonstrados no Anexo 1.

2.2.3. Alimentação de banco de dados geográficos e uso de módulos Python para análise

Todos os índices obtidos permanecem em memória de execução, existindo a necessidade de armazenar em um ambiente que permita o resgate e análise de tais séries históricas. Assim, foi estabelecida uma função Python que realizasse uma conexão com banco de dados PostgreSQL, alimentando-o em suas tabelas específicas, a fim de manter uma relação entre a feição analisada e a data de levantamento de informações.

Esse processo permite o resgate de informações por outras ferramentas, foco do **Erro! Fonte de referência não encontrada.**, **Erro! Fonte de referência não encontrada.** que utilizará tal possibilidade para a realização de análises estatísticas e de uso de redes neurais para caracterização da produção ou realização de prognósticos futuros.

3 RESULTADOS E DISCUSSÃO

Considerando todos os procedimentos metodológicos realizados, bem como as rotinas criadas, o estudo priorizou a geração de uma base de dados consistente para a área amostral contemplando a temporalidade entre 17/12/2018 até 15/04/2022, o que totalizou 238 imagens sem aplicação de filtros para porcentagem de nuvens. O período em questão compreende o funcionamento do Satélite Sentinel 2 com imagens disponibilizadas com correção atmosférica já processada e adequadas para a geração da base de dados de índices.

Os procedimentos consistiram na geração de área de interesse, em que, no script, foi adicionada uma camada vetorial, de forma a utilizar o *bounding box* da área para obtenção das imagens do sensor para geração dos índices, como mostra a Figura 7.



Figura 7 - Delimitação da área de estudo do Aldo Tasca para obtenção dos dados de sensoriamento remoto disponibilizados na plataforma Google Earth Engine

A geração da base a partir dos códigos estruturados (Anexo 1) considerou o levantamento de informações disponibilizado pelo google earth engine, em que, para cada data disponibilizada, os dados foram baixados, realizada a geração dos 16 índices contemplados neste estudo e armazenados no banco de dados na tabela “stats”, com os parâmetros de data, array dos valores de refletância, estatísticas zonais contendo mínima, máxima e média de cada índice, além de parâmetros de estrutura do raster, considerando a delimitação de estudo, como evidencia a Figura 8.

id [PK] Integer	data date	index text	raster_array real[]	zonal_stats json	raster_profile json
1	2021-01-30	atsavi	{{0.68347776,0.68347776}}	{'min': 0.4510633051395416, 'max': 0.85020...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
2	2021-08-28	ndmi	{{0.053632643,0.053632643}}	{'min': -0.09614919126033783, 'max': 0.2580...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
3	2020-06-24	atsavi	{{0.6002337,0.6002337}}	{'min': 0.11347295343875885, 'max': 0.7805...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
4	2020-09-02	lci	{{0.50784314,0.50784314}}	{'min': 0.15170279145240784, 'max': 0.6374...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
5	2019-08-19	gvmi	{{0.18975773,0.18975773}}	{'min': -0.0785238966345787, 'max': 0.28476...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
6	2019-09-23	sci	{{-0.24169116,-0.24169116}}	{'min': 0.06618181616067886, 'max': 0.2787...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
7	2021-11-21	ndmi	{{0.35110435,0.35110435}}	{'min': 0.02923046238720417, 'max': 0.4796...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
8	2021-04-10	fo	{{0.4622093,0.4622093}}	{'min': 0.4206642210483551, 'max': 0.79635...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
9	2021-10-02	savi	{{-0.005775065,-0.005775065}}	{'min': -0.010584122501313686, 'max': -0.00...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
10	2021-02-19	fe3	{{0.6260388,0.6260388}}	{'min': 0.4266666769981384, 'max': 1.29940...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
11	2021-03-26	fe3	{{0.85470086,0.85470086}}	{'min': 0.7015418410301208, 'max': 1.07072...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
12	2019-05-01	fo	{{0.30233175,0.30233175}}	{'min': 0.29963332414627075, 'max': 0.4245...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
13	2020-02-15	savi	{{0.10518451,0.10518451}}	{'min': 0.06458138674497604, 'max': 0.1092...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
14	2020-07-14	chlgreen	{{0.20299402,0.20299402}}	{'min': 0.07964786887168884, 'max': 0.3593...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
15	2020-10-17	evi	{{0.20806798,0.20806798}}	{'min': 0.038291797041893005, 'max': 0.218...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
16	2021-03-31	ndmi	{{0.42801973,0.42801973}}	{'min': 0.07824591547250748, 'max': 0.3792...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
17	2020-11-06	ctvi	{{0.58909416,0.58909416}}	{'min': 0.6758415102958679, 'max': 0.92171...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
18	2021-01-20	avi	{{2.3116,2.3116}}	{'min': 2.2453999519348145, 'max': 2.49440...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...
19	2020-03-31	savi	{{0.25416818,0.25416818}}	{'min': 0.0232344102114439, 'max': 0.22574...	{'driver': 'GTiff', 'dtype': 'float32', 'nodata': null, 'width': 7...

Figura 8 - Parâmetros armazenados em banco de dados - data: data de obtenção da imagem; index: índice gerado por meio dos processamento; raster_array: estrutura com valores de refletância dos rasters; zonal_stats: valores de mínimo, máximo e média do índice para a data; raster_profile: parâmetros para reconstrução do raster

Para realização do download de imagens, geração dos índices e inserção em banco de dados, foi criado um módulo python denominado “sentinel downloader”, contendo as seguintes classes:

- SentinelHandler: classe de apoio com métodos compartilhados entre outras classes;
- SentinelDownloader: classe com métodos responsáveis para realização de download de imagens no google earth engine, considerando as datas estabelecidas;
- SentinelIndexes: responsável pela composição das bandas sentinel e álgebras de mapas de forma a serem obtidos os 16 índices estabelecidos no material e métodos;
- Postgresql: classe responsável por estruturar as tabelas no banco de dados e truncar tabelas quando da inserção de novos limites para análise;
- Statistics: classe responsável por gerar as estatísticas zonais do raster e inserir nas tabelas criadas no banco de dados;

Além das classes acima mencionadas, foi criada uma classe denominada PlotHtml com métodos que permitem a busca de informações no banco de dados para subsidiar o módulo “dashboard” para visualização dos dados.

Com isso, a partir do dashboard, é possível aplicar filtro de datas e índices para obtenção de valores plotados em gráficos.

A funcionalidade de plotagem de gráfico permite ao usuário selecionar os índices que pretende comparar para analisar o seu comportamento durante determinado período da área, ou seja, é possível comparar todos os índices gerados com o NDVI, identificando se possuem ou não relação direta com a média geral do índice obtido, como explana a Figura 9.




Figura 9 - Recuperação de valores do índice NDVI presente em banco de dados. Esquerda: valores mínimo, máximo e médio de NDVI para período de anos determinado na área do talhão; Direita superior: Comparação entre índices NDVI e AVI histórico; Direita inferior: recuperação da imagem do índice especificado e data presente no banco de dados.

Como exemplo, podemos analisar o comportamento do índice NDVI e índice de $fe3+$ obtido pelo sensor na área analisada, em que, interpretando a Figura 9, pode-se identificar que existe um comportamento oposto entre eles. Tal comportamento pode ser considerado devido ao solo da área monitorada ser rico em $fe3+$, quando temos uma menor cobertura vegetal, favorecendo a identificação do solo pelo sensor, ou seja, nesse caso, existe o indício de uma maior presença de um solo mais exposto.




Figura 10 - Comparação entre índices NDVI (vermelho) e $fe3+$ (azul) demonstrando a correlação negativa entre os dois.




Figura 11 - Comparação entre índices SCI (vermelho) e NDVI (azul) demonstrando a correlação negativa entre os dois.

Da mesma forma, quando comparamos o NDVI com o índice sci – *soil composition index*, também se verifica uma característica inversa, uma vez que o sci está relacionado às condições de mudanças do solo, ou seja, sua exposição, início de processos erosivos ou operações que causem o revolvimento da camada superficial; esses são fatores que não ocorrem durante o processo de desenvolvimento das culturas nos estágios mais avançados, mas sim durante o início e final dos processos culturais, como mostra a Figura 10.

Assim, a partir da ferramenta gerada, é possível monitorar o histórico de desenvolvimento de culturas, considerando os índices contemplados durante o desenvolvimento da ferramenta. Isso permite, dessa forma, identificar possíveis variações históricas que possam ser utilizadas no entendimento do comportamento da produção da área e em tomadas de decisões futuras para adequações na região monitorada, com uma resolução espacial considerável ao utilizar imagens de sensores Sentinel.

4 CONCLUSÕES

O uso de linguagem python com a importação de módulos específicos e sua integração com banco de dados Postgres permitiu gerar de maneira ágil uma base de dados histórica, considerando a utilização de sensores de satélite sentinel 2, de forma estruturada. Isso permitiu aos seus utilizadores possuírem acesso às informações já processadas, possibilitando cruzá-las e interpretá-las em ambiente amigável, o que torna essa etapa menos custosa, uma vez que antes poderiam consumir grande etapa de tempo de produção científica ou em situações de tomadas de decisões assertivas sobre determinada área analisada.

AGRADECIMENTOS

À Unioeste, ao Geolab – Laboratório de Topografia e Geoprocessamento, e ao Parque Tecnológico de Itaipu, que disponibilizaram apoio técnico e estrutura para o desenvolvimento da pesquisa.

ANEXOS

Anexo 1: Código Python para download, tratamento e visualização de índices Sentinel

2

https://github.com/newmarwegner/doutorado

REFERÊNCIAS

- ABBASIMEHR, H.; SHABANI, M.; YOUSEFI, M. An optimized model using LSTM network for demand forecasting. **Computers & Industrial Engineering**, [s.l.], v. 143, p. 106435, 2020.
- ABUZAID, A. S.; ABDELLATIF, A. D.; FADL, M. E. Modeling soil quality in Dakahlia Governorate, Egypt using GIS techniques. **The Egyptian Journal of Remote Sensing and Space Science**, [s.l.], jan., 2020.
- ADOM, P. K.; ADAMS, S. Decomposition of technical efficiency in agricultural production in Africa into transient and persistent technical efficiency under heterogeneous technologies. **World Development**, [s.l.], v. 129, p. 104907, mai., 2020.
- AHMADI, M. H. *et al.* Prediction of the pressure drop for CuO/(Ethylene glycol-water) nanofluid flows in the car radiator by means of Artificial Neural Networks analysis integrated with genetic algorithm. **Physica A: Statistical Mechanics and its Applications**, [s.l.], p. 124008, jan., 2020.
- AL-TAANI, A.; AL-HUSBAN, Y.; FARHAN, I. Land suitability evaluation for agricultural use using GIS and remote sensing techniques: The case study of Ma'an Governorate, Jordan. **The Egyptian Journal of Remote Sensing and Space Science**, [s.l.], fev., 2020.
- ALLAHYARI, M. S.; MOHAMMADZADEH, M.; NASTIS, S. A. Agricultural experts' attitude towards precision agriculture: Evidence from Guilan Agricultural Organization, Northern Iran. **Information Processing in Agriculture**, [s.l.], v. 3, n. 3, p. 183-189, set., 2016.
- ALZAGHRINI, N.; SROUR, F. J.; SROUR, I. Using GIS and optimization to manage construction and demolition waste: The case of abandoned quarries in Lebanon. **Waste Management**, [s.l.], v. 95, p. 139-149, jul., 2019.
- AMINI, S. *et al.* Assessment of land suitability and agricultural production sustainability using a combined approach (Fuzzy-AHP-GIS): A case study of Mazandaran province, Iran. **Information Processing in Agriculture**, [s.l.], out., 2019.
- BARBOSA, B. *et al.* Automatic detection of vegetation cover changes in urban-rural interface areas. **MethodsX**, [s.l.], v. 9, p. 101643, 2022.
- BARNES, A. P. *et al.* Exploring the adoption of precision agricultural technologies: A cross regional study of EU farmers. **Land Use Policy**, [s.l.], v. 80, p. 163-174, jan., 2019.
- BAZZI, C. L. *et al.* AgDataBox API – Integration of data and software in precision agriculture. **SoftwareX**, [s.l.], v. 10, p. 100327, jul., 2019.
- BEGUM NASIR AHMAD, N. S. *et al.* A systematic review of soil erosion control practices on the agricultural land in Asia. **International Soil and Water Conservation Research**, [s.l.], v. 8, n. 2, p. 173-182, jun., 2020.
- BEYER, M. *et al.* Deep spatial-temporal graph modeling for efficient NDVI forecasting. **Smart Agricultural Technology**, [s.l.], v. 4, p. 100172, 2023.
- BREUNIG, F. M. *et al.* Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 85, p. 102004, mar., 2020.

BROOK, A. *et al.* A smart multiple spatial and temporal resolution system to support precision agriculture from satellite images: Proof of concept on Aglianico vineyard. **Remote Sensing of Environment**, [s.l.], v. 240, p. 111679, abr., 2020.

CAMICIA, R. G. DA M. *et al.* Productivity of soybean in management zones with application of different sowing densities. **Ciência Rural**, [s.l.], v. 48, n. 12, dez., 2018.

CAO, H.; WACHOWICZ, M. The design of an IoT-GIS platform for performing automated analytical tasks. **Computers, Environment and Urban Systems**, [s.l.], v. 74, p. 23-40, mar., 2019.

CASTRO, C. A. DE O. *et al.* High-performance prediction of macauba fruit biomass for agricultural and industrial purposes using Artificial Neural Networks. **Industrial Crops and Products**, [s.l.], v. 108, p. 806-813, dez., 2017.

CASTRO, F. C.; ARAÚJO, J. F.; DOS SANTOS, A. M. Susceptibility to soil salinization in the quilombola community of Cupira - Santa Maria da Boa Vista - Pernambuco – Brazil. **CATENA**, [s.l.], v. 179, p. 175-183, ago., 2019.

CHABERT, A.; SARTHOU, J.-P. Conservation agriculture as a promising trade-off between conventional and organic agriculture in bundling ecosystem services. **Agriculture, Ecosystems & Environment**, [s.l.], v. 292, p. 106815, abr., 2020.

CHATTERJEE, S.; DEY, N.; SEN, S. Soil moisture quantity prediction using optimized neural supported model for sustainable agricultural applications. **Sustainable Computing: Informatics and Systems**, [s.l.], v. 20, p. 178-190, set. 2018.

CHEN, C.; JUDGE, J.; HULSE, D. PyLUSAT: An open-source Python toolkit for GIS-based land use suitability analysis. **Environmental Modelling & Software**, [s.l.], v. 151, p. 105362, mar. 2022.

CHEN, J. *et al.* Pattern-based circular reference detection in Python. **Science of Computer Programming**, [s.l.], v. 227, p. 102932, fev., 2023.

CHEN, P. *et al.* Occurrence prediction of cotton pests and diseases by bidirectional long short-term memory networks with climate and atmosphere circulation. **Computers and Electronics in Agriculture**, [s.l.], v. 176, p. 105612, 2020.

DA SILVA, J. L. B. *et al.* Spatiotemporal dynamics of agricultural areas with central pivot using orbital remote sensing in the Brazilian semiarid. **Smart Agricultural Technology**, [s.l.], v. 2, p. 100052, 2022.

DA SILVA JUNIOR, C. A. *et al.* Soybean varieties discrimination using non-imaging hyperspectral sensor. **Infrared Physics & Technology**, [s.l.], v. 89, p. 338-350, mar., 2018.

DE RANGO, F. *et al.* Scalable and lightweight bio-inspired coordination protocol for FANET in precision agriculture applications. **Computers & Electrical Engineering**, [s.l.], v. 74, p. 305-318, mar., 2019.

DEMATTE, J. A. M. *et al.* The Brazilian Soil Spectral Library (BSSL): A general view, application and challenges. **Geoderma**, [s.l.], v. 354, p. 113793, nov., 2019.

DONG, Y. *et al.* Precision fertilization method of field crops based on the Wavelet-BP neural network in China. **Journal of Cleaner Production**, [s.l.], v. 246, p. 118735, fev., 2020.

DOS SANTOS, G. M. A. D. A. *et al.* GIS applied to agriclimatological zoning and agrotoxin residue monitoring in tomatoes: A case study in Espírito Santo state, Brazil. **Journal of Environmental Management**, [s.l.], v. 166, p. 429-439, jan., 2016.

ELIDRISSI, S. *et al.* New application of GIS and statistical analysis in mapping the distribution of quaternary calcrete (Tensift Al Haouz area, Central Morocco). **CATENA**, [s.l.], v. 188, p. 104419, mai., 2020.

ESPINOZA, K. *et al.* Combination of image processing and artificial neural networks as a novel approach for the identification of Bemisia tabaci and Frankliniella occidentalis on sticky traps in greenhouse agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 127, p. 495-505, set., 2016.

EZENNE, G. I. *et al.* Current and potential capabilities of UAS for crop water productivity in precision agriculture. **Agricultural Water Management**, [s.l.], v. 218, p. 158-164, jun., 2019.

FAO. **FAO. How to feed the world in 2050?** [s.l: s.n.]. Disponível em: http://www.fao.org/fileadmin/templates/wsfs/docs/expert_paper/How_to_Feed_the_World_in_2050.pdf. Acesso em: 17 abril. 2023.

FAR, S. T.; REZAEI-MOGHADDAM, K. Impacts of the precision agricultural technologies in Iran: An analysis experts' perception & their determinants. **Information Processing in Agriculture**, [s.l.], v. 5, n. 1, p. 173-184, mar., 2018.

FASTELLI, L.; ROVAI, M.; ANDREOLI, M. A Spatial Integrated Database for the Enhancement of the Agricultural Custodianship Role (SIDE CAR)—Some preliminary tests using Tuscany as a case-study Region. **Land Use Policy**, [s.l.], v. 78, p. 791-802, 2018.

FENG, L. *et al.* Multi-scale change monitoring of water environment using cloud computing in optimal resolution remote sensing images. **Energy Reports**, [s.l.], v. 8, p. 13610-13620, 2022.

GAO, S. *et al.* Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. **Journal of Hydrology**, [s.l.], v. 589, p. 125188, 2020.

GHOSH, S.; KUMAR, D.; KUMARI, R. Cloud-based large-scale data retrieval, mapping, and analysis for land monitoring applications with Google Earth Engine (GEE). **Environmental Challenges**, [s.l.], v. 9, p. 100605, 2022a.

GHOSH, S.; KUMAR, D.; KUMARI, R. Google earth engine based computational system for the earth and environment monitoring applications during the COVID-19 pandemic using thresholding technique on SAR datasets. **Physics and Chemistry of the Earth, Parts A/B/C**, [s.l.], v. 127, p. 103163, 2022b.

GONZALEZ-AGUILERA, D. *et al.* From point cloud to CAD models: Laser and optics geotechnology for the design of electrical substations. **Optics & Laser Technology**, [s.l.], v. 44, n. 5, p. 1384-1392, jul., 2012.

HE, C.; MA, M.; WANG, P. Extract interpretability-accuracy balanced rules from artificial neural networks: A review. **Neurocomputing**, [s.l.], v. 387, p. 346-358, abr., 2020.

HIGGINS, S.; SCHELLBERG, J.; BAILEY, J. S. Improving productivity and increasing the efficiency of soil nutrient management on grassland farms in the UK and Ireland using

precision agriculture technology. **European Journal of Agronomy**, [s.l.], v. 106, p. 67-74, mai., 2019.

HUANG, Y. W. *et al.* Modeling of chemical exergy of agricultural biomass using improved general regression neural network. **Energy**, [s.l.], v. 114, p. 1164-1175, nov., 2016.

IENCO, D. *et al.* Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v. 158, p. 11-22, 2019.

JÄGER, D. *et al.* A spatial database for landslides in northern Bavaria: A methodological approach. **Geomorphology**, [s.l.], v. 306, p. 283-291, abr., 2018.

JANSSEN, S. *et al.* A database for integrated assessment of European agricultural systems. **Environmental Science & Policy**, [s.l.], v. 12, n. 5, p. 573-587, 2009.

JHA, K. *et al.* A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, [s.l.], v. 2, p. 1-12, 2019.

JIANG, N.; LI, P.; FENG, Z. Remote sensing of swidden agriculture in the tropics: A review. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 112, p. 102876, 2022.

JUNG, D.-H. *et al.* Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. **Computers and Electronics in Agriculture**, [s.l.], v. 173, p. 105402, 2020.

KAIVOSOJA, J. *et al.* Automatic control of farming operations based on spatial web services. **Computers and Electronics in Agriculture**, [s.l.], v. 100, p. 110-115, jan., 2014.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 143, p. 23-37, dez., 2017.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, [s.l.], v. 147, p. 70-90, 2018.

KAUL, M.; HILL, R. L.; WALTHALL, C. Artificial neural networks for corn and soybean yield prediction. **Agricultural Systems**, [s.l.], v. 85, n. 1, p. 1-18, 2005.

KAUR, L.; RISHI, M. S.; CHAUDHARY, B. S. Assessment of meteorological and agricultural droughts using remote sensing and their impact on groundwater in an agriculturally productive part of Northwest India. **Agricultural Water Management**, [s.l.], v. 274, p. 107956, 2022.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 139, p. 22-32, jun., 2017.

KHANNA, A.; KAUR, S. Evolution of Internet of Things (IoT) and its significant impact in the field of Precision Agriculture. **Computers and Electronics in Agriculture**, [s.l.], v. 157, p. 218-231, fev., 2019.

LIANG, J. *et al.* WS4GEE: Enhancing geospatial web services and geoprocessing workflows by integrating the Google Earth Engine. **Environmental Modelling & Software**, [s.l.], v. 161, p. 105636, 2023.

LIEGEOIS, K.; PEREGO, M.; HARTLAND, T. PyAlbany: A Python interface to the C++ multiphysics solver Albany. **Journal of Computational and Applied Mathematics**, [s.l.], v. 425, p. 115037, 2023.

LIU, H. *et al.* An overview of stability analysis and state estimation for memristive neural networks. **Neurocomputing**, [s.l.], jan., 2020a.

LIU, X. *et al.* A remote sensing and artificial neural network-based integrated agricultural drought index: Index development and applications. **CATENA**, [s.l.], v. 186, p. 104394, mar., 2020b.

LIU, Z.-W.; LIANG, F.-N.; LIU, Y.-Z. Artificial neural network modeling of biosorption process using agricultural wastes in a rotating packed bed. **Applied Thermal Engineering**, [s.l.], v. 140, p. 95-101, jul., 2018.

MAES, W. H.; STEPPE, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. **Trends in Plant Science**, [s.l.], v. 24, n. 2, p. 152-164, fev., 2019.

MAHMOODI, N. M.; TAGHIZADEH, M.; TAGHIZADEH, A. Mesoporous activated carbons of low-cost agricultural bio-wastes with high adsorption capacity: Preparation and artificial neural network modeling of dye removal from single and multicomponent (binary and ternary) systems. **Journal of Molecular Liquids**, [s.l.], v. 269, p. 217-228, nov., 2018.

MAHMOODY VANOLYA, N.; JELOKHANI-NIARAKI, M.; TOOMANIAN, A. Validation of spatial multicriteria decision analysis results using public participation GIS. **Applied Geography**, [s.l.], v. 112, p. 102061, nov., 2019.

MANNA, P. *et al.* A geospatial decision support system to assist olive growing at the landscape scale. **Computers and Electronics in Agriculture**, [s.l.], v. 168, p. 105143, jan., 2020.

MARTIN, H. *et al.* Trackintel: An open-source Python library for human mobility analysis. **Computers, Environment and Urban Systems**, [s.l.], v. 101, p. 101938, 2023.

MASHALY, A. F.; ALAZBA, A. A. Thermal performance analysis of an inclined passive solar still using agricultural drainage water and artificial neural network in arid climate. **Solar Energy**, [s.l.], v. 153, p. 383-395, set., 2017.

MÉNDEZ-VÁZQUEZ, L. J. *et al.* Delineation of site-specific management zones for pest control purposes: Exploring precision agriculture and species distribution modeling approaches. **Computers and Electronics in Agriculture**, [s.l.], v. 167, p. 105101, dez., 2019.

MIGUEL LENZ, A. *et al.* Expansion of eucalyptus energy plantations under a Livestock-Forestry Integration scenario for agroindustries in Western Paraná, Brazil. **Ecological Indicators**, [s.l.], v. 98, p. 39-48, 2019.

MOHAMMED, I. *et al.* A blended census and multiscale remote sensing approach to probabilistic cropland mapping in complex landscapes. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v. 161, p. 233-245, mar., 2020.

MORAIS, R. *et al.* mySense: A comprehensive data management environment to improve precision agriculture practices. **Computers and Electronics in Agriculture**, [s.l.], v. 162, p. 882-894, jul., 2019.

MUKHERJEE, A.; MISRA, S.; RAGHUWANSHI, N. S. A survey of unmanned aerial sensing solutions in precision agriculture. **Journal of Network and Computer Applications**, [s.l.], v. 148, p. 102461, dez., 2019.

MUNAWAR, A. A. *et al.* Calibration models database of near infrared spectroscopy to predict agricultural soil fertility properties. **Data in Brief**, [s.l.], v. 30, p. 105469, 2020.

MWALUPASO, G. E. *et al.* Recuperating dynamism in agriculture through adoption of sustainable agricultural technology - Implications for cleaner production. **Journal of Cleaner Production**, [s.l.], v. 232, p. 639-647, set., 2019.

NABIL, M. *et al.* Assessing factors impacting the spatial discrepancy of remote sensing based cropland products: A case study in Africa. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 85, p. 102010, 1 mar. 2020.

NEISSI, L.; ALBAJI, M.; BOROOMAND NASAB, S. Combination of GIS and AHP for site selection of pressurized irrigation systems in the Izeh plain, Iran. **Agricultural Water Management**, [s.l.], v. 231, p. 106004, mar., 2020.

NEVAVUORI, P.; NARRA, N.; LIPPING, T. Crop yield prediction with deep convolutional neural networks. **Computers and Electronics in Agriculture**, [s.l.], v. 163, p. 104859, 2019.

NGHIA, B. P. Q. *et al.* Applying Google earth engine for flood mapping and monitoring in the downstream provinces of Mekong river. **Progress in Disaster Science**, [s.l.], v. 14, p. 100235, 2022.

NGUYEN, T. H.; NONG, D.; PAUSTIAN, K. Surrogate-based multi-objective optimization of management options for agricultural landscapes using artificial neural networks. **Ecological Modelling**, [s.l.], v. 400, p. 1-13, mai., 2019.

NGUYEN, T. T. *et al.* Monitoring agriculture areas with satellite images and deep learning. **Applied Soft Computing**, [s.l.], v. 95, p. 106565, 2020.

PERAKIS, K. *et al.* CYBELE – Fostering precision agriculture & livestock farming through secure access to large-scale HPC enabled virtual industrial experimentation environments fostering scalable big data analytics. **Computer Networks**, [s.l.], v. 168, p. 107035, fev., 2020.

PILEVAR, A. R. *et al.* Integrated fuzzy, AHP and GIS techniques for land suitability assessment in semi-arid regions for wheat and maize farming. **Ecological Indicators**, [s.l.], v. 110, p. 105887, mar., 2020.

POPOVIĆ, T. *et al.* Architecting an IoT-enabled platform for precision agriculture and ecological monitoring: A case study. **Computers and Electronics in Agriculture**, [s.l.], v. 140, p. 255-265, ago., 2017.

RADOGLU-GRAMMATIKIS, P. *et al.* A Compilation of UAV Applications for Precision Agriculture. **Computer Networks**, [s.l.], p. 107148, fev., 2020.

RAY, C. *et al.* Heterogeneous integrated dataset for Maritime Intelligence, surveillance, and reconnaissance. **Data in Brief**, [s.l.], v. 25, p. 104141, 2019.

- ROBERTS, J. F. *et al.* Pyeo: A Python package for near-real-time forest cover change detection from Earth observation using machine learning. **Computers & Geosciences**, [s.l.], v. 167, p. 105192, 2022.
- RUPNIK, R. *et al.* AgroDSS: A decision support system for agriculture and farming. **Computers and Electronics in Agriculture**, [s.l.], v. 161, p. 260-271, 2019.
- SABU, K. M.; KUMAR, T. K. M. Predictive analytics in Agriculture: Forecasting prices of Arecanuts in Kerala. **Procedia Computer Science**, [s.l.], v. 171, p. 699-708, 2020.
- SANTOS, A. R. DOS *et al.* Geotechnology and landscape ecology applied to the selection of potential forest fragments for seed harvesting. **Journal of Environmental Management**, [s.l.], v. 183, p. 1050-1063, dez., 2016.
- SHARMA, R. *et al.* A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. **Computers & Operations Research**, [s.l.], v. 119, p. 104926, 2020.
- SHARMA, S. K.; MISRA, S. K.; SINGH, J. B. The role of GIS-enabled mobile applications in disaster management: A case analysis of cyclone Gaja in India. **International Journal of Information Management**, [s.l.], p. 102030, nov., 2019.
- SILBERGELD, E. K. One health and the agricultural transition in food animal production. **Global Transitions**, [s.l.], v. 1, p. 83-92, jan., 2019.
- SOUZA, F. H. Q. *et al.* The use of vegetation index via remote sensing allows estimation of soybean application rate. **Remote Sensing Applications: Society and Environment**, [s.l.], v. 17, p. 100279, jan., 2020.
- SRIVASTAVA, K. *et al.* UAVs technology for the development of GUI based application for precision agriculture and environmental research. **Remote Sensing Applications: Society and Environment**, [s.l.], v. 16, p. 100258, nov., 2019.
- STOFFEL, M. *et al.* Artificial neural networks in structural dynamics: A new modular radial basis function approach vs. convolutional and feedforward topologies. **Computer Methods in Applied Mechanics and Engineering**, [s.l.], v. 364, p. 112989, jun., 2020.
- SU, Y. *et al.* Quantifying the sustainability of three types of agricultural production in China: An emergy analysis with the integration of environmental pollution. **Journal of Cleaner Production**, [s.l.], v. 252, p. 119650, abr., 2020.
- TAHMASEBI, P. *et al.* Machine learning in geo- and environmental sciences: From small to large scale. **Advances in Water Resources**, [s.l.], v. 142, p. 103619, 2020.
- TRILLES, S. *et al.* Development of an open sensorized platform in a smart agriculture context: A vineyard support system for monitoring mildew disease. **Sustainable Computing: Informatics and Systems**, [s.l.], jan., 2019.
- TROUILLET, B. Aligning with dominant interests: The role played by geo-technologies in the place given to fisheries in marine spatial planning. **Geoforum**, [s.l.], v. 107, p. 54-65, dez., 2019.
- TRUMPY, E.; MANZELLA, A. Geothopica and the interactive analysis and visualization of the updated Italian National Geothermal Database. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 54, p. 28-37, fev., 2017.

- USMAN, M. *et al.* Numerical modelling and remote sensing based approaches for investigating groundwater dynamics under changing land-use and climate in the agricultural region of Pakistan. **Journal of Hydrology**, [s.l.], v. 581, p. 124408, fev., 2020.
- VALENCIA, J. *et al.* A GIS-based methodological framework to identify superficial water sources and their corresponding conduction paths for gravity-driven irrigation systems in developing countries. **Agricultural Water Management**, [s.l.], v. 232, p. 106048, abr., 2020.
- VANDERHOOF, M. K. *et al.* High-frequency time series comparison of Sentinel-1 and Sentinel-2 satellites for mapping open and vegetated water across the United States (2017–2021). **Remote Sensing of Environment**, [s.l.], v. 288, p. 113498, 2023.
- WALTERS, J. P. *et al.* Exploring agricultural production systems and their fundamental components with system dynamics modelling. **Ecological Modelling**, [s.l.], v. 333, p. 51-65, ago., 2016.
- WANG, J. *et al.* Integrating remote sensing-based process model with environmental zonation scheme to estimate rice yield gap in Northeast China. **Field Crops Research**, [s.l.], v. 246, p. 107682, fev., 2020.
- WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, [s.l.], v. 236, p. 111402, jan., 2020.
- WU, Q. *et al.* Integrating LiDAR data and multi-temporal aerial imagery to map wetland inundation dynamics using Google Earth Engine. **Remote Sensing of Environment**, [s.l.], v. 228, p. 1-13, 2019.
- WU, Q. geemap: A Python package for interactive mapping with Google Earth Engine. **The Journal of Open Source Software**, [s.l.], v. 5, p. 2305, 2020.
- XIA, Y. *et al.* Agricultural chemicals use data access using coldfusion markup language and a relational database. **Computers and Electronics in Agriculture**, [s.l.], v. 38, n. 3, p. 217-225, 2003.
- XIAO, C. *et al.* A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data. **Environmental Modelling & Software**, [s.l.], v. 120, p. 104502, 2019.
- XU, X. *et al.* Application of neural network algorithm in fault diagnosis of mechanical intelligence. **Mechanical Systems and Signal Processing**, [s.l.], p. 106625, jan., 2020.
- YANG, H. *et al.* Hyper-temporal remote sensing data in bare soil period and terrain attributes for digital soil mapping in the Black soil regions of China. **CATENA**, [s.l.], v. 184, p. 104259, jan., 2020.
- YARAMASU, R.; BANDARU, V.; PNVR, K. Pre-season crop type mapping using deep neural networks. **Computers and Electronics in Agriculture**, [s.l.], v. 176, p. 105664, 2020.
- YUE, J.; TIAN, Q. Estimating fractional cover of crop, crop residue, and soil in cropland using broadband remote sensing data and machine learning. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v. 89, p. 102089, jul., 2020.
- YUE, Y. *et al.* Prediction of maize growth stages based on deep learning. **Computers and Electronics in Agriculture**, [s.l.], v. 172, p. 105351, 2020.

ZAHARAN, S. A. E.-S.; SAEED, R. A.-H.; ELAZIZY, I. M. Remote sensing based water resources and agriculture spatial indicators system. **The Egyptian Journal of Remote Sensing and Space Science**, [s.l.], v. 25, n. 2, p. 515-527, 2022.

ZHANG, M. *et al.* Image fusion employing adaptive spectral-spatial gradient sparse regularization in UAV remote sensing. **Signal Processing**, [s.l.], v. 170, p. 107434, mai., 2020.

ZHANG, Z.; ZHOU, Y.; HUANG, X. Applicability of GIS-based spatial interpolation and simulation for estimating the soil organic carbon storage in karst regions. **Global Ecology and Conservation**, [s.l.], v. 21, p. e00849, mar., 2020.

ZHAO, F. *et al.* Extraction of long time series wetland information based on Google Earth Engine and random forest algorithm for a plateau lake basin – A case study of Dianchi Lake, Yunnan Province, China. **Ecological Indicators**, [s.l.], v. 146, p. 109813, 2023.

ZHAO, J. *et al.* A robust spectral-spatial approach to identifying heterogeneous crops using remote sensing imagery with high spectral and spatial resolutions. **Remote Sensing of Environment**, [s.l.], v. 239, p. 111605, mar., 2020.

ZHOU, B.; OKIN, G. S.; ZHANG, J. Leveraging Google Earth Engine (GEE) and machine learning algorithms to incorporate in situ measurement from different times for rangelands monitoring. **Remote Sensing of Environment**, [s.l.], v. 236, p. 111521, 2020.

ARTIGO 2 – USO DE REDES NEURAIS EM PROGNÓSTICOS DE ÍNDICE NDVI PARA AGRICULTURA

RESUMO: Atualmente, a agricultura tem se desenvolvido de forma a aumentar produtividade e diminuir impactos visando à sua sustentabilidade. Dentre as tecnologias utilizadas, há de se destacar o uso de sensoriamento remoto para avaliar a variabilidade de produtividade, visando sempre definir ações que possam vir a melhorar o desempenho de produção, alcançando, assim, melhor rentabilidade com menor impacto ambiental e econômico. Este artigo apresenta automatizações de processos que utilizam dados de sensoriamento remoto em conjunto com técnicas de redes neurais, de modo que possa ser avaliado o índice NDVI para agricultura, obtido pela composição das bandas espectrais de imagens sentinel 2, bem como utilizá-los considerando seu histórico para treinamento de redes neurais convolucionais e recorrentes, gerando prognósticos de índices NDVI's. Dessa maneira, a partir da rede ConvLSTM implementada, os trabalhos alcançaram resultados nas previsões de NDVI para 3 diferentes grupos de datasets de treinamento, na ordem de erros médios absolutos de 0.16 e 0.17, utilizando uma janela de 5 datas passadas dos índices gerados para prever uma janela futura. Assim, apresenta tendências ao longo dos períodos estimados e contribui inclusive para momentos em que não existiam imagens para datas específicas devido à porcentagem de nuvens presentes.

Palavras-chave: Python. PostgreSQL. Índices para agricultura.

USE OF NEURAL NETWORKS IN NDVI INDEX FORECASTING FOR AGRICULTURE

ABSTRACT: Agriculture has been developed to increase productivity and reduce impacts aiming at sustainability. Among the technologies used, remote sensing evaluates the variability of productivity, always aiming to define actions that can improve production performance, thus achieving better profitability with less environmental and economic impact. This paper presents the automation of processes that use remote sensing data in conjunction with neural network techniques so that the NDVI index for agriculture, obtained by the composition of spectral bands of Sentinel-2 images, can be evaluated, as well as using them considering its history for the training of convolutional and recurrent neural networks, generating predictions of NDVI indices. Thus, from the implemented ConvLSTM network, the work achieved results in NDVI predictions for three groups of training datasets, in the order of average absolute errors of 0.16 and 0.17, using a window of 5 past dates of the generated indices to predict a future window. Thus, it shows trends over the estimated periods and even contributes to times when no images were available for specific dates due to the percentage of clouds present.

Keywords: Python. PostgreSQL. Indices for agriculture.

1. INTRODUÇÃO

Desafios, como aumento de produtividade, impactos ambientais, segurança alimentar, sustentabilidade, são apenas algumas das preocupações que estão inerentes em processos produtivos agrícolas, que tornam necessária a prática de uma agricultura inteligente, cada vez mais moderna e com técnicas que permitam alcançar sua sustentabilidade (KAMILARIS; PRENAFETA-BOLDÚ, 2018).

A atividade agrícola, ao longo dos anos, vem trabalhando com as questões de variabilidade de produtividade, considerando seu histórico; atualmente, o monitoramento dessa variabilidade melhorou consideravelmente com o uso de ferramentas de sensoriamento remoto, que permitem a geração de informações a partir de sensores embarcados em satélites, como o Sentinel 2, além do uso de redes neurais que proporcionam a obtenção de informações relevantes para tomadas de decisão (NEVAVUORI; NARRA; LIPPING, 2019).

Com seu constante crescimento e necessidade de aumento de produção, soluções que permitam monitorar ou prever condições continuamente tornam-se necessárias, de forma que agricultores possam realizar ações que venham a contribuir para o aumento de suas respectivas produtividades, ou até mesmo evitar perdas econômicas ao identificar um comportamento não desejável do desenvolvimento de suas culturas.

Beyer *et al.* (2023) apresentaram a dificuldade de previsão de NDVI como um dos grandes problemas e consequente oportunidade para o desenvolvimento de técnicas e soluções no âmbito da agricultura. O uso de redes neurais para alcançar esses resultados permite resolver problemas complexos, de maneira rápida e ágil, aumentando a precisão das classificações, bem como reduzindo erros de regressão a partir de um conjunto de dados suficientes para descrição do problema em conjunto com arquiteturas de redes específicas para cada tipo de dado de entrada (KAMILARIS; PRENAFETA-BOLDÚ, 2018).

Diversos são os estudos do uso de redes neurais na agricultura, destacando-se aplicações para predição de ervas daninhas, previsão de variáveis de recursos hídricos, nutrição de plantas, crescimento de lavouras, aconselhamento de pulverização, previsão de colheita, entre outros (JHA *et al.*, 2019).

Em culturas de algodão, o monitoramento de comportamentos climáticos permite diagnosticar possíveis desenvolvimentos de pragas ou doenças e, atualmente, o uso de redes neurais recorrentes (*LSTM- Long Short Term Memory*), treinadas a partir do histórico ocorrido relacionando com sua variável a ser prevista, tem alcançado bons resultados no controle e na prevenção de elementos indesejáveis na cultura do algodão (CHEN *et al.*, 2020).

Tais técnicas também foram aplicadas no monitoramento de culturas de arroz, em que a necessidade de identificação de áreas durante seu ciclo produtivo é importante para a

agricultura no contexto de segurança alimentar e previsão de produção, gerando resultados que superaram 93% de efetividade no mapeamento da cultura com a utilização de índices de vegetação e uso de redes neurais (NGUYEN *et al.*, 2020).

Beyer *et al.* (2023) mencionam também que modelos de rede neural estruturados em ConvLSTM foram realizados para efetivar a previsão de índice NDVI em culturas de soja, nas quais há um maior desempenho de velocidade para grandes áreas comparado a outros métodos, devido às suas características de diminuição de dimensionalidade dos dados de entrada, além de alcançar resultados de RMSE na ordem de 0.0589.

Em milho, modelos de ConvSLTM foram realizados para obtenção de prognósticos para fatores meteorológicos, a fim de, posteriormente, serem utilizados em combinação em outro modelo de rede neural para previsão de estágios de crescimento da cultura. Os resultados demonstram uma capacidade preditiva para previsão das fases de crescimento, que podem proporcionar ao produtor antecipação de ações referente a plantio, cultivo e colheita (YUE *et al.*, 2020).

Redes LSTM são consideradas uma extensão das redes neurais recorrentes, em que, com a utilização dessa arquitetura, é possível armazenar e mapear dados de entrada e saída de tempos a longo prazo, sendo consideradas técnicas adequadas aos processos de previsões com base de dados histórica (ABBASIMEHR; SHABANI; YOUSEFI, 2020).

As vantagens do uso de redes neurais recorrentes são atribuídas às suas estruturas com fortes interdependências que preservam informações de ocorrências de etapas anteriores, ou seja, um histórico dos fatos que permitem gerar prognósticos sobre padrões de comportamentos passados, sempre considerando um número grande de dados para o aprendizado da máquina (JUNG *et al.*, 2020). Na China, estudos também foram realizados com o objetivo de utilizar redes neurais para desenvolvimento de um índice de seca agrícola, chegando a resultados potencialmente capazes de descobrir condições de déficit hídrico, que influenciam diretamente a produtividade agrícola (LIU *et al.*, 2020b).

Cabe ressaltar ainda que o uso de redes neurais pode atingir funcionalidades relacionadas à predição da flutuação de preços de commodities, considerando o uso de várias técnicas de *datamining* para construção de base de dados que permitem possuir um histórico de variáveis para treinar a rede e obter informações sobre a flutuação de preços futuros (SABU; KUMAR, 2020).

As redes neurais convolucionais possuem, como dados de entrada, estruturas semelhantes a um grid, que podem ser compostas por dados de entrada 1, 2 ou 3D, em que, de modo geral, uma das camadas convolucionais recebem a aplicação de um filtro, gerando uma unidade em uma dimensão muito menor que a camada de entrada, mas representativa à classificação. Assim, é posteriormente ainda aplicado um *polling*, com o objetivo de reduzir

a resolução espacial dos mapas de características, diminuindo possíveis distorções, sendo finalmente conectadas a uma rede neural (TAHMASEBI *et al.*, 2020).

Dessa maneira, este artigo tem por objetivo estruturar uma arquitetura de rede neural convolucional em conjunto com redes recorrentes (LSTM), que possibilite prever o comportamento futuro de índice NDVI de áreas agrícolas monitoradas. Isso deve considerar, como camadas de entradas, os índices NDVI's obtidos a partir de séries históricas, disponibilizadas na plataforma Google Earth Engine, utilizando técnicas e algoritmos automatizados para a realização de prognósticos e análise de tendências sobre o índice em questão. Dessa forma, é possível contribuir para o monitoramento da área, gerando informações que possam subsidiar ações futuras de manejo.

MATERIAIS E MÉTODOS

Com o objetivo de utilizar redes neurais para estimar comportamentos em áreas agrícolas, o estudo em questão estabeleceu o uso do índice NDVI para monitorar esse comportamento em conjunto com técnicas de uso de rede neural, visando não somente à visualização de comportamentos passados, mas sim verificando a sua capacidade de estimar comportamentos futuros em áreas agrícolas. Dessa maneira, o processo de desenvolvimento deste estudo foi dividido em quatro etapas, a saber: Levantamento de imagens, processamento e geração de índices NDVI; Estruturação da Rede Neural; Treinamento da rede Neural e Validação.

Levantamento de imagens, processamento e geração de índices NDVI

A obtenção de imagens foi realizada a partir da aplicação Google Earth Engine, utilizando a base de imagens Sentinel2, no período entre 2018 e 2022, ignorando a porcentagem de nuvens presentes, uma vez que o filtro e retirada de imagens com coberturas de nuvens foi realizado de forma visual para composição do dataset de treinamento.

Inicialmente, foram obtidas as bandas RGB+NIR e, então, processadas de forma que pudesse ser gerado o índice NDVI.

O índice de vegetação por diferença normalizada é obtido por meio da relação entre a diferença da faixa do infravermelho próximo e vermelho e a soma dessas bandas conforme apresentado abaixo:

$$(NIR - RED / (NIR + RED))$$

Após o levantamento e processamento, foi possível obter um total de 133 imagens a serem utilizadas no processo de treinamento da rede neural.

Estruturação da Rede Neural

A estruturação da Rede Neural utilizou redes LSTM Convolucionais, usualmente consideradas para previsão, com um conjunto de dados anteriores como entrada após o treinamento.

A construção da rede considerou a inicialização de um tensor Keras (pacote utilizado para definição de redes neurais), para, então, possibilitar as definições das próximas camadas da rede. Nesse contexto, é definido o tamanho do lote de entrada para o treinamento, de forma que sejam passadas as outras definições às camadas subsequentes. Posteriormente a isso, foram criadas 4 camadas ConvLstm2D com camadas de normalização das entradas entre elas para ajustar a média e dimensionamento das ativações, minimizando, assim, a necessidade de utilização de camadas de dropout para evitar processos de overfitting.

Finalmente, como última camada, foi estruturada uma saída convolucional 3D de forma a produzir um tensor de saída (previsão), como mostrado na Figura 12.




Figura 12 - Estrutura das camadas da rede neural ConvLSTM

A estrutura de compilação do modelo utilizou como função, para encontrar os desvios e erros no processo de aprendizagem, o *MSE – Mean Square Error* (erro médio quadrático). Tal escolha foi dada devido aos valores presentes nos rasters de entrada poderem sofrer com as presenças de valores discrepantes, gerando, assim, estimativas que necessitam ser penalizadas durante o treinamento; isso mantém normalmente os dados de saída de forma distribuída, considerando os valores médios.

Quanto à validação do modelo, a métrica utilizada foi a *MAE – Mean Absolute Error* (erro médio absoluto), demonstrando de fato os erros absolutos, além de considerar os valores reais e estimados obtidos por meio da rede neural.

Treinamento da Rede Neural

Para execução do treinamento de rede neural, foi considerado o treinamento de 3 modelos, sendo um global, com todas as imagens obtidas relacionadas aos meses de cultivo

(setembro a março), e outros dois modelos considerando a rotação e período de culturas realizadas na área de estudo, onde o proprietário realiza essa rotação plantando milho e soja em anos distintos.

Dessa maneira, os dados de entrada para a geração dos 3 treinamentos consideraram a população descrita abaixo:

Tabela 2 - População de imagens utilizadas para treinamento e suas respectivas datas

Períodos	Global	Milho	Soja
17/12/2018 a 15/04/2022	133		
17/12/2018 a 27/03/2019		21	
02/11/2019 a 31/03/2020			31
01/11/2020 a 31/03/2021		28	
01/11/2021 a 31/03/2022			31
Total imagens	133	49	62

Em cada modelo, foram realizados treinamentos, considerando diferentes tamanhos de janelas de previsão, como evidenciado na Figura 13, ou seja, os dados foram preparados estabelecendo janelas temporais de imagens de 5, 10 e 15 amostras (ressaltando que imagens Sentinel possuem resolução temporal de 5 dias), que correspondem à temporalidade passada de imagens existentes para, então, realizar o prognóstico da próxima imagem (índice da próxima data em que seria disponibilizada uma nova imagem).




Figura 13 - Funcionamento de janelas temporais fixas e deslizantes para realização de prognósticos de NDVI's

Com a janela fixa determinada, os padrões são identificados a partir de imagens inseridas sob a mesma configuração de janela deslizante, com tamanho determinado pelo analista na criação do modelo.

Inicialmente, as imagens (índices) passam por um processo de redução de dimensionalidade com a operação entre duas matrizes, sendo a matriz de entrada e um kernel, espacialmente menor que percorrerá a camada de entrada, reduzindo a dimensionalidade ao estabelecer valores representativos da região durante a varredura. Dessa maneira, gera-se um mapa de características que pode ser utilizado em conexão com uma rede neural escolhida, neste caso, a LSTM, que tem por objetivo estabelecer, em cada neurônio de entrada, o respectivo índice considerando a temporalidade.

Validação

Para validação dos prognósticos obtidos para os índices, foram utilizados, como referência de medição do desempenho, o erro quadrático médio (RMSE) e erro absoluto médio (MAE) (XIAO *et al.*, 2019).

Inicialmente, a rede neural será treinada considerando, em sua população de dados, um total de 70% deles para treinamento e 30% para validação, em que, a partir do parâmetro MAE, poderemos identificar a diferença existente entre o valor real e estimado.

Quanto ao RMSE, será utilizado na função de perda (loss function) do modelo Keras, de forma a otimizar o processo de identificação da distância entre o valor atual e esperado de saída do algoritmo.

O erro quadrático médio será dado pela equação:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n d^2}{n}} \quad (1)$$

Em que:

d = diferença entre o valor real e estimado

n = número de amostras

Quanto ao MAE, será obtido pela seguinte equação:

$$MAE = \frac{1}{n} \sum_{i=1}^n (|y_i - \hat{y}|) \quad (2)$$

Em que:

y_i = valor real

$\hat{y}$ = valor estimado

n = número de amostras

A partir da aplicação das equações, espera-se obter resultados que, em conjunto com a interpretação dos gráficos, que explanam o comportamento do treinamento dos modelos (loss e acurácia), será possível identificar os modelos que apresentam menores valores de MAE e Loss, bem como aqueles em que o gráfico não apresente tendências de divergências entre as curvas, sugerindo um modelo com características de *over* ou *underfitting*.



Figura 14 - Histórico de valores de NDVI na área de estudo

RESULTADOS E DISCUSSÕES

A partir da avaliação do comportamento dos valores médios históricos de índice de vegetação, normalizada na área de estudo, como mostra a Figura 14, podemos verificar picos negativos do valor do índice diretamente influenciados pela presença de nuvens durante a coleta do sensor.

Considerando esse histórico, o trabalho em questão utilizou redes neurais convolucionais e LSTM, com o objetivo de gerar prognósticos futuros do índice de forma a verificar sua capacidade de estimação de datas futuras. Assim, foram estruturados e treinados 9 modelos de redes neurais, divididos em três grupos de populações de dados (global, soja e milho), atribuindo as imagens aos seus respectivos grupos, com a consideração da cultura presente em determinados meses e também o uso de todo o histórico (dados globais) sem a realização do filtro, considerando os meses e tipo de cultivo. Além disso, foram atribuídos hiperparâmetros para a estrutura da rede neural, com a finalidade de refinar ainda mais o modelo. Dessa maneira, são observados parâmetros, como batch size, que define o número de amostras a serem utilizadas antes de atualizar os parâmetros do modelo; epochs, que corresponde ao número de vezes em que o treinamento ocorrerá em todo o conjunto de dados, o tamanho da janela de imagens passadas a ser utilizada em uma previsão futura; e learning rate ou taxa de aprendizado, na qual a velocidade de aprendizado do modelo foi aplicada para otimizar os resultados.

O comportamento do treinamento foi monitorado a partir dos resultados de validação das perdas e avaliação da acurácia. O primeiro, a perda ao longo do tempo (loss), demonstra que, quanto maior o seu decréscimo ao longo do tempo, melhor será o desempenho do modelo; o segundo está relacionado à precisão do modelo de fato; em nosso caso, ao utilizar o MAE, estamos considerando o erro absoluto médio dos valores.

Tabela 3 - Treinamentos de modelos realizados com diferentes grupos datasets e 800 epochs

Dados	Learning Rate	batch	epochs	mae	loss	window
global	0,001	5	800	0,0992	0,0224	5x5
global				0,0695	0,0142	10x10
global				0,0596	0,0104	15x15
milho				0,0973	0,0232	5x5
milho				0,0874	0,0189	10x10
milho				0,0549	0,0107	15x15
soja				0,0942	0,0211	5x5
soja				0,0616	0,012	10x10
soja				0,0555	0,0123	15x15

Conforme é apresentado na Tabela 3, foram realizados 3 grupos de treinamentos, em que, para cada grupo, os melhores resultados foram obtidos considerando a avaliação dos valores de erro médio absoluto, loss e avaliação do comportamento do desenvolvimento do treinamento, nos gráficos a seguir:




Figura 15 - Curvas do comportamento da função de perda utilizando grupo de dados Global e janela de 5 imagens e 800 epochs




Figura 16 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados Global e janela de 5 imagens e 800 epochs




Figura 17 - Curvas do comportamento da função de perda utilizando grupo de dados Global e janela de 10 imagens e 800 epochs




Figura 18 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados Global e janela de 10 imagens e 800 epochs




Figura 19 - Curvas do comportamento da função de perda utilizando grupo de dados Global e janela de 15 imagens e 800 epochs




Figura 20 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados Global e janela de 15 imagens e 800 epochs




Figura 21 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janelas de 5 imagens e 800 epochs




Figura 22 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janelas de 5 imagens e 800 epochs




Figura 23 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janelas de 10 imagens e 800 epochs




Figura 24 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janelas de 10 imagens e 800 epochs




Figura 25 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janelas de 15 imagens e 800 epochs




Figura 26 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janelas de 15 imagens e 800 epochs




Figura 27 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janelas de 5 imagens e 800 épocas




Figura 28 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janelas de 5 imagens e 800 épocas




Figura 29 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janelas de 10 imagens e 800 épocas




Figura 30 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janelas de 10 imagens e 800 épocas




Figura 31 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janelas de 15 imagens e 800 épocas




Figura 32 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janelas de 15 imagens e 800 épocas

A análise gráfica possui papel fundamental na validação dos resultados, uma vez que, no momento em que as linhas começam a divergir entre si, podemos ter indícios de *under* ou *overfitting* sobre os dados.

Assim, a partir da análise dos resultados apresentados, é possível verificar um comportamento das curvas de treinamento e validação que demonstram um distanciamento entre elas em média de 100 épocas. Tal comportamento nas curvas sugere um processo de overfitting a partir desse momento, sendo necessária a realização de novo treinamento, considerando um máximo de 100 épocas, minimizando, assim, essa questão.

Dessa maneira, um novo treinamento foi realizado atingindo os seguintes resultados:

Tabela 4 - Treinamentos de modelos realizados com diferentes datasets e 100 epochs

Dados	Learning Rate	batch	epochs	mae	loss	window
global	0,001	5	100	0,1711	0,0459	5x5
global				0,1306	0,0343	10x10
global				0,1096	0,0258	15x15
milho				0,1737	0,049	5x5
milho				0,1502	0,0458	10x10
milho				0,1545	0,0394	15x15
soja				0,161	0,045	5x5
soja				0,1422	0,0389	10x10
soja				0,0948	0,0205	15x15

Com isso, novos gráficos para avaliação de comportamento foram gerados, permitindo, assim, uma avaliação dos modelos que melhor se ajustaram ao processo de treinamento.




Figura 33 - Curvas do comportamento da função de perda utilizando grupo de dados global e janela de 5 imagens e 100 epoch




Figura 34 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados global e janela de 5 imagens e 100 epochs




Figura 35 - Curvas do comportamento da função de perda utilizando grupo de dados global e janela de 10 imagens e 100 epoch




Figura 36 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados global e janela de 10 imagens e 100 epochs




Figura 37 - Curvas do comportamento da função de perda utilizando grupo de dados global e janela de 15 imagens e 100 epoch




Figura 38 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados global e janela de 15 imagens e 100 epochs

Como é possível visualizar, para o caso do conjunto de imagens globais, o modelo que melhor se adaptou foi o que utilizou uma janela de 5 imagens para treinamento, uma vez que atingiu um patamar de estabilização e ajuste entre curvas de treinamento e validação.




Figura 39 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 5 imagens e 100 epoch




Figura 40 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 5 imagens e 100 epochs




Figura 41 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 10 imagens e 100 epoch




Figura 42 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 10 imagens e 100 epochs




Figura 43 - Curvas do comportamento da função de perda utilizando grupo de dados milho e janela de 15 imagens e 100 epoch




Figura 44 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados milho e janela de 15 imagens e 100 epochs

Para o caso do conjunto de imagens específico para temporada de milho, o modelo que melhor se adaptou, também, foi o que utilizou uma janela de 5 imagens para treinamento, uma vez que atingiu um patamar de estabilização e ajuste entre curvas de treinamento e validação, além de apresentar menores ruídos na curva de validação.




Figura 45 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 5 imagens e 100 epoch




Figura 46 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 5 imagens e 100 epochs




Figura 47 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 10 imagens e 100 epoch




Figura 48 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 10 imagens e 100 epochs




Figura 49 - Curvas do comportamento da função de perda utilizando grupo de dados soja e janela de 15 imagens e 100 epoch




Figura 50 - Curvas de treinamento e Acurácia (MAE) utilizando grupo de dados soja e janela de 15 imagens e 100 epochs

Quanto ao conjunto de imagens específico para temporada de soja, o modelo que melhor se adaptou foi o com uma janela de 5 imagens para treinamento, uma vez que atingiu um patamar de estabilização e ajuste entre curvas de treinamento e validação. Apesar do modelo com 15 imagens apresentar um ajuste, verifica-se um maior tempo para estabilização e aparente não estabilização em um plato, sugerindo a não finalização desse ajuste.

Dessa maneira, os modelos que apresentaram os melhores resultados, considerando as curvas analisadas e seu comportamento de ajuste, foram os com o uso de uma janela de 5 imagens apresentando os valores de MAE para global de 0,1711, milho 0,1737, e, soja 0,161.

A partir dos modelos estabelecidos, foi utilizado o código disponibilizado em Anexo 2: Código para geração de prognóstico, com o objetivo de gerar prognósticos para os 30% das imagens destinadas à validação do treinamento e também imagens posteriores às utilizadas para realizar o treinamento, que datam até 31/03/2023. Seu processo de execução considerou a utilização das 5 imagens anteriores para geração do prognóstico posterior com a aplicação dos 3 modelos treinados (global, soja e milho).

O resultado foi particionado com linhas verticais (períodos) de modo a demonstrar as culturas existentes e comparar o resultado do modelo específico para cultura analisada, como evidencia a Figura 51.




Figura 51 - Prognósticos de NDVI utilizando janela de 5 imagens anteriores, aplicação dos 3 modelos gerados para 30% das imagens de validação em conjunto com dados até 31/03/2023.

Como é possível verificar na Figura 51, em alguns momentos, os dados reais de NDVI são inconclusos devido à presença de nuvens (imagens apresentadas logo abaixo do gráfico), o que impossibilitaria ao analista verificar como está o comportamento da cultura quanto ao índice em questão. Com a aplicação da rede treinada, é possível visualizar que os prognósticos apresentaram uma tendência de acompanhamento dos dados reais e, nos casos em que existem pontos discrepantes nos dados reais (devido às nuvens), a curva mantém o comportamento de tendência, considerando a diferença já apresentada pelos valores obtidos no erro absoluto médio dos treinamentos dos modelos para soja e milho.

Considerando tais resultados, podemos concluir que os modelos apresentados não somente contribuem com a análise de tendências do comportamento NDVI na propriedade, mas podem também contribuir para a estimativa de valores médios de NDVI para a área quando da impossibilidade de obter o dado devido à presença de nuvens na região.

5 CONCLUSÕES

Com o uso em conjunto de linguagem python, redes neurais convolucionais e LSTM, foi possível estruturar códigos que possibilitem, em um futuro, realizar treinamentos com

populações maiores de imagens de entrada, agilizando processos onerosos de desenvolvimentos de códigos para realização de novos modelos. Apesar do resultado ainda apresentar um erro médio absoluto, na ordem de 0.16 a 0,17, para os modelos treinados, verificou-se, no período de validação, que, para a janela de 5 imagens, o modelo inicia seu processo de ajuste com os valores médios de imagens reais, sugerindo que a presença de um dataset maior contribuirá para alcançar melhores resultados na previsão de índice NDVI's futuros e em momentos nos quais exista cobertura de nuvem na área analisada. Dessa maneira, orienta-se que trabalhos futuros para o treinamento de modelos de redes neurais convolucionais utilizem datasets maiores que o montante utilizado neste estudo a fim de alcançar precisões maiores.

Outra questão relevante, que pode ser abordada em trabalhos futuros, é a verificação de viabilidade desta proposta com o uso de imagens para resoluções menores (ex: Modis 250 metros), que poderiam ser utilizadas para grandes áreas agricultáveis devido à não necessidade de uma resolução no nível deste trabalho, contribuindo significativamente para o tamanho do dataset, uma vez que seu tempo de revisita é maior.

AGRADECIMENTOS

À Unioeste, ao Geolab – Laboratório de Topografia e Geoprocessamento e ao Parque Tecnológico de Itaipu, que disponibilizaram apoio técnico e estrutura para o desenvolvimento da pesquisa.

CONCLUSÃO DA TESE

Devido à preocupação e necessidade de se produzir mais alimentos com uma mesma quantidade de área, esta tese teve por objetivo utilizar tecnologias que viabilizassem o monitoramento de áreas agrícolas e geração de prognósticos que pudessem contribuir com analistas ou proprietários, de forma a tomarem decisões mais assertivas a respeito de seus processos produtivos. Para isso, foram determinados procedimentos para coleta de informações de sensoriamento remoto, de forma a serem estruturados gerando 16 índices que possam contribuir para a análise da região e disponibilizados de maneira facilitada ao usuário final, considerando apenas, neste primeiro momento, o histórico passado da propriedade analisada.

Além disso, a tese preocupou-se em gerar modelos que contribuíssem para o processo de prognósticos de índice NDVI médio da área agricultável, considerando também possíveis dias que ficassem impossibilitados de obter tal informação devido à presença de nuvens na região. Para tanto, o uso de redes neurais Convolucionais e LSTM contribuíram significativamente, uma vez que possibilitou a geração de modelos de previsão do índice com erro médio absoluto na ordem de 0,16 a 0,17, que também apresentaram resultados satisfatórios em momentos de ausência de imagens de qualidade.

Cabe ressaltar que o dataset, utilizado para treinamento neste estudo, ainda é escasso devido à disponibilidade de imagens do sensor utilizado e que, assim que disponível, mais imagens ou a utilização de outros sensores podem contribuir significativamente para alcançar resultados de precisão ainda melhores do que os alcançados nesta tese.

ANEXOS

Anexo 2: Código para geração de prognóstico

```
import numpy as np
import matplotlib.pyplot as plt

def split_sequence_2(sequence, n_steps_in, n_steps_out):
    X, y = list(), list()
    for i in range(len(sequence)):
        end_ix = i + n_steps_in
        out_end_ix = 1 + end_ix
        if out_end_ix > len(sequence):
            break
        seq_x, seq_y = sequence[i:end_ix], sequence[i+1:out_end_ix]
        X.append(seq_x)
        y.append(seq_y)
    return np.array(X), np.array(y)

def gen_dataset(window):
    dataset = np.load('./agriculture/templates/dados_global.npy')
    dataset, b = split_sequence_2(dataset, window, window)
    dataset = np.expand_dims(dataset, axis=-1)
    indexes = np.arange(dataset.shape[0])
    np.random.shuffle(indexes)
    train_index = indexes[: int(0.75 * dataset.shape[0])]
    val_index = indexes[int(0.75 * dataset.shape[0]) :]
    train_dataset = dataset[train_index]
    val_dataset = dataset[val_index]
    def create_shifted_frames(data):
        x = data[:, 0 : data.shape[1] - 1, :, :]
        y = data[:, 1 : data.shape[1], :, :]
        return x, y

    x_train, y_train = create_shifted_frames(train_dataset)
    x_val, y_val = create_shifted_frames(val_dataset)

    return dataset, x_val.shape[0]

def prognosis(n_model, dataset):
    model = keras.models.load_model(f"./agriculture/templates/{n_model}")

    medias = []
    for i in range(-2, -34, -1):
        medido = model.predict(np.expand_dims(dataset[i], axis=1))
        medias.append(medido.mean())

    real = []
    for i in range(-1, -33, -1):
        real.append(dataset[i].mean())

    return medias, real

def plot_estimate(eixo, window):
    dataset, win = gen_dataset(window)
    estimado_global, real = prognosis(f'global_{window}', dataset)
    estimado_milho, real = prognosis(f'milho_{window}', dataset)
    estimado_soja, real = prognosis(f'soja_{window}', dataset)
    x = eixo
    y = real
    plt.figure(figsize=(20, 10))
    plt.title("Line graph")
    plt.xlabel("X axis")
    plt.ylabel("Y axis")
    plt.title(f"Prognósticos de NDVI em área de estudo considerando janela de {window} imagens")
    plt.plot(x, y, marker='o', color="red", label='Real')
    plt.plot(x, estimado_global, marker='o', color="blue", label='Estimado Global')
    plt.plot(x, estimado_milho, marker='o', color="brown", label='Estimado Milho')
    plt.plot(x, estimado_soja, marker='o', color="orange", label='Estimado Soja')
    plt.xlabel("Data de valores reais e estimados")
    plt.ylabel("Índice NDVI")
    plt.legend(loc="lower right")
    plt.xticks(rotation=45)
```

```
plt.show()  
plot_estimate(datas,15)
```


REFERÊNCIAS

- ABBASIMEHR, H.; SHABANI, M.; YOUSEFI, M. An optimized model using LSTM network for demand forecasting. **Computers & Industrial Engineering**, v. 143, p. 106435, 2020.
- ABUZAID, A. S.; ABDELLATIF, A. D.; FADL, M. E. Modeling soil quality in Dakahlia Governorate, Egypt using GIS techniques. **The Egyptian Journal of Remote Sensing and Space Science**, 14 jan. 2020.
- ADOM, P. K.; ADAMS, S. Decomposition of technical efficiency in agricultural production in Africa into transient and persistent technical efficiency under heterogeneous technologies. **World Development**, v. 129, p. 104907, 1 maio 2020.
- AHMADI, M. H. et al. Prediction of the pressure drop for CuO/(Ethylene glycol-water) nanofluid flows in the car radiator by means of Artificial Neural Networks analysis integrated with genetic algorithm. **Physica A: Statistical Mechanics and its Applications**, p. 124008, 3 jan. 2020.
- AL-TAANI, A.; AL-HUSBAN, Y.; FARHAN, I. Land suitability evaluation for agricultural use using GIS and remote sensing techniques: The case study of Ma'an Governorate, Jordan. **The Egyptian Journal of Remote Sensing and Space Science**, 25 fev. 2020.
- ALLAHYARI, M. S.; MOHAMMADZADEH, M.; NASTIS, S. A. Agricultural experts' attitude towards precision agriculture: Evidence from Guilan Agricultural Organization, Northern Iran. **Information Processing in Agriculture**, v. 3, n. 3, p. 183–189, 1 set. 2016.
- ALZAGHRINI, N.; SROUR, F. J.; SROUR, I. Using GIS and optimization to manage construction and demolition waste: The case of abandoned quarries in Lebanon. **Waste Management**, v. 95, p. 139–149, 15 jul. 2019.
- AMINI, S. et al. Assessment of land suitability and agricultural production sustainability using a combined approach (Fuzzy-AHP-GIS): A case study of Mazandaran province, Iran. **Information Processing in Agriculture**, 11 out. 2019.
- BARBOSA, B. et al. Automatic detection of vegetation cover changes in urban-rural interface areas. **MethodsX**, v. 9, p. 101643, 2022.
- BARNES, A. P. et al. Exploring the adoption of precision agricultural technologies: A cross regional study of EU farmers. **Land Use Policy**, v. 80, p. 163–174, 1 jan. 2019.
- BAZZI, C. L. et al. AgDataBox API – Integration of data and software in precision agriculture. **SoftwareX**, v. 10, p. 100327, 1 jul. 2019.
- BEGUM NASIR AHMAD, N. S. et al. A systematic review of soil erosion control practices on the agricultural land in Asia. **International Soil and Water Conservation Research**, 2020.
- BEYER, M. et al. Deep spatial-temporal graph modeling for efficient NDVI forecasting. **Smart Agricultural Technology**, v. 4, p. 100172, 2023.
- BREUNIG, F. M. et al. Delineation of management zones in agricultural fields using cover–crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, p. 102004, 1 mar. 2020.

BROOK, A. et al. A smart multiple spatial and temporal resolution system to support precision agriculture from satellite images: Proof of concept on Aglianico vineyard. **Remote Sensing of Environment**, v. 240, p. 111679, 1 abr. 2020.

CAMICIA, R. G. DA M. et al. Productivity of soybean in management zones with application of different sowing densities. **Ciência Rural**, v. 48, n. 12, 6 dez. 2018.

CAO, H.; WACHOWICZ, M. The design of an IoT-GIS platform for performing automated analytical tasks. **Computers, Environment and Urban Systems**, v. 74, p. 23–40, 1 mar. 2019.

CASTRO, C. A. DE O. et al. High-performance prediction of macauba fruit biomass for agricultural and industrial purposes using Artificial Neural Networks. **Industrial Crops and Products**, v. 108, p. 806–813, 1 dez. 2017.

CASTRO, F. C.; ARAÚJO, J. F.; DOS SANTOS, A. M. Susceptibility to soil salinization in the quilombola community of Cupira - Santa Maria da Boa Vista - Pernambuco – Brazil. **CATENA**, v. 179, p. 175–183, 1 ago. 2019.

CHABERT, A.; SARTHOU, J.-P. Conservation agriculture as a promising trade-off between conventional and organic agriculture in bundling ecosystem services. **Agriculture, Ecosystems & Environment**, v. 292, p. 106815, 15 abr. 2020.

CHATTERJEE, S.; DEY, N.; SEN, S. Soil moisture quantity prediction using optimized neural supported model for sustainable agricultural applications. **Sustainable Computing: Informatics and Systems**, 14 set. 2018.

CHEN, C.; JUDGE, J.; HULSE, D. PyLUSAT: An open-source Python toolkit for GIS-based land use suitability analysis. **Environmental Modelling & Software**, v. 151, p. 105362, 2022.

CHEN, J. et al. Pattern-based circular reference detection in Python. **Science of Computer Programming**, v. 227, p. 102932, 2023.

CHEN, P. et al. Occurrence prediction of cotton pests and diseases by bidirectional long short-term memory networks with climate and atmosphere circulation. **Computers and Electronics in Agriculture**, v. 176, p. 105612, 2020.

DA SILVA, J. L. B. et al. Spatiotemporal dynamics of agricultural areas with central pivot using orbital remote sensing in the Brazilian semiarid. **Smart Agricultural Technology**, v. 2, p. 100052, 2022.

DA SILVA JUNIOR, C. A. et al. Soybean varieties discrimination using non-imaging hyperspectral sensor. **Infrared Physics & Technology**, v. 89, p. 338–350, 1 mar. 2018.

DE RANGO, F. et al. Scalable and lightweight bio-inspired coordination protocol for FANET in precision agriculture applications. **Computers & Electrical Engineering**, v. 74, p. 305–318, 1 mar. 2019.

DEMATTE, J. A. M. et al. The Brazilian Soil Spectral Library (BSSL): A general view, application and challenges. **Geoderma**, v. 354, p. 113793, 15 nov. 2019.

DONG, Y. et al. Precision fertilization method of field crops based on the Wavelet-BP neural network in China. **Journal of Cleaner Production**, v. 246, p. 118735, 10 fev. 2020.

DOS SANTOS, G. M. A. D. A. et al. GIS applied to agriclimatological zoning and agrototoxin residue monitoring in tomatoes: A case study in Espírito Santo state, Brazil. **Journal of Environmental Management**, v. 166, p. 429–439, 15 jan. 2016.

ELIDRISSI, S. et al. New application of GIS and statistical analysis in mapping the distribution of quaternary calcrete (Tensift Al Haouz area, Central Morocco). **CATENA**, v. 188, p. 104419, 1 maio 2020.

ESPINOZA, K. et al. Combination of image processing and artificial neural networks as a novel approach for the identification of Bemisia tabaci and Frankliniella occidentalis on sticky traps in greenhouse agriculture. **Computers and Electronics in Agriculture**, v. 127, p. 495–505, 1 set. 2016.

EZENNE, G. I. et al. Current and potential capabilities of UAS for crop water productivity in precision agriculture. **Agricultural Water Management**, v. 218, p. 158–164, 1 jun. 2019.

FAO. **FAO. How to feed the world in 2050?** [s.l: s.n.]. Disponível em: http://www.fao.org/fileadmin/templates/wsfs/docs/expert_paper/How_to_Feed_the_World_in_2050.pdf.

FAR, S. T.; REZAEI-MOGHADDAM, K. Impacts of the precision agricultural technologies in Iran: An analysis experts' perception & their determinants. **Information Processing in Agriculture**, v. 5, n. 1, p. 173–184, 1 mar. 2018.

FASTELLI, L.; ROVAI, M.; ANDREOLI, M. A Spatial Integrated Database for the Enhancement of the Agricultural Custodianship Role (SIDE CAR)—Some preliminary tests using Tuscany as a case-study Region. **Land Use Policy**, v. 78, p. 791–802, 2018.

FENG, L. et al. Multi-scale change monitoring of water environment using cloud computing in optimal resolution remote sensing images. **Energy Reports**, v. 8, p. 13610–13620, 2022.

GAO, S. et al. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. **Journal of Hydrology**, v. 589, p. 125188, 2020.

GHOSH, S.; KUMAR, D.; KUMARI, R. Cloud-based large-scale data retrieval, mapping, and analysis for land monitoring applications with Google Earth Engine (GEE). **Environmental Challenges**, v. 9, p. 100605, 2022a.

GHOSH, S.; KUMAR, D.; KUMARI, R. Google earth engine based computational system for the earth and environment monitoring applications during the COVID-19 pandemic using thresholding technique on SAR datasets. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 127, p. 103163, 2022b.

GONZALEZ-AGUILERA, D. et al. From point cloud to CAD models: Laser and optics geotechnology for the design of electrical substations. **Optics & Laser Technology**, v. 44, n. 5, p. 1384–1392, 1 jul. 2012.

HE, C.; MA, M.; WANG, P. Extract interpretability-accuracy balanced rules from artificial neural networks: A review. **Neurocomputing**, v. 387, p. 346–358, 28 abr. 2020.

HIGGINS, S.; SCHELLBERG, J.; BAILEY, J. S. Improving productivity and increasing the efficiency of soil nutrient management on grassland farms in the UK and Ireland using precision agriculture technology. **European Journal of Agronomy**, v. 106, p. 67–74, 1 maio 2019.

HUANG, Y. W. et al. Modeling of chemical exergy of agricultural biomass using improved general regression neural network. **Energy**, v. 114, p. 1164–1175, 1 nov. 2016.

IENCO, D. et al. Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 158, p. 11–22, 2019.

JÄGER, D. et al. A spatial database for landslides in northern Bavaria: A methodological approach. **Geomorphology**, v. 306, p. 283–291, 1 abr. 2018.

JANSSEN, S. et al. A database for integrated assessment of European agricultural systems. **Environmental Science & Policy**, v. 12, n. 5, p. 573–587, 2009.

JHA, K. et al. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, v. 2, p. 1–12, 2019.

JIANG, N.; LI, P.; FENG, Z. Remote sensing of swidden agriculture in the tropics: A review. **International Journal of Applied Earth Observation and Geoinformation**, v. 112, p. 102876, 2022.

JUNG, D.-H. et al. Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. **Computers and Electronics in Agriculture**, v. 173, p. 105402, 2020.

KAIVOSOJA, J. et al. Automatic control of farming operations based on spatial web services. **Computers and Electronics in Agriculture**, v. 100, p. 110–115, 1 jan. 2014.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, v. 143, p. 23–37, 1 dez. 2017.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, p. 70–90, 2018.

KAUL, M.; HILL, R. L.; WALTHALL, C. Artificial neural networks for corn and soybean yield prediction. **Agricultural Systems**, v. 85, n. 1, p. 1–18, 2005.

KAUR, L.; RISHI, M. S.; CHAUDHARY, B. S. Assessment of meteorological and agricultural droughts using remote sensing and their impact on groundwater in an agriculturally productive part of Northwest India. **Agricultural Water Management**, v. 274, p. 107956, 2022.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v. 139, p. 22–32, 15 jun. 2017.

KHANNA, A.; KAUR, S. Evolution of Internet of Things (IoT) and its significant impact in the field of Precision Agriculture. **Computers and Electronics in Agriculture**, v. 157, p. 218–231, 1 fev. 2019.

LIANG, J. et al. WS4GEE: Enhancing geospatial web services and geoprocessing workflows by integrating the Google Earth Engine. **Environmental Modelling & Software**, v. 161, p. 105636, 2023.

LIEGEOIS, K.; PEREGO, M.; HARTLAND, T. PyAlbany: A Python interface to the C++ multiphysics solver Albany. **Journal of Computational and Applied Mathematics**, v. 425, p. 115037, 2023.

LIU, H. et al. An overview of stability analysis and state estimation for memristive neural networks. **Neurocomputing**, 25 jan. 2020a.

LIU, X. et al. A remote sensing and artificial neural network-based integrated agricultural drought index: Index development and applications. **CATENA**, v. 186, p. 104394, 1 mar. 2020b.

LIU, Z.-W.; LIANG, F.-N.; LIU, Y.-Z. Artificial neural network modeling of biosorption process using agricultural wastes in a rotating packed bed. **Applied Thermal Engineering**, v. 140, p. 95–101, 25 jul. 2018.

MAES, W. H.; STEPPE, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. **Trends in Plant Science**, v. 24, n. 2, p. 152–164, 1 fev. 2019.

MAHMOODI, N. M.; TAGHIZADEH, M.; TAGHIZADEH, A. Mesoporous activated carbons of low-cost agricultural bio-wastes with high adsorption capacity: Preparation and artificial neural network modeling of dye removal from single and multicomponent (binary and ternary) systems. **Journal of Molecular Liquids**, v. 269, p. 217–228, 1 nov. 2018.

MAHMOODY VANOLYA, N.; JELOKHANI-NIARAKI, M.; TOOMANIAN, A. Validation of spatial multicriteria decision analysis results using public participation GIS. **Applied Geography**, v. 112, p. 102061, 1 nov. 2019.

MANNA, P. et al. A geospatial decision support system to assist olive growing at the landscape scale. **Computers and Electronics in Agriculture**, v. 168, p. 105143, 1 jan. 2020.

MARTIN, H. et al. Trackintel: An open-source Python library for human mobility analysis. **Computers, Environment and Urban Systems**, v. 101, p. 101938, 2023.

MASHALY, A. F.; ALAZBA, A. A. Thermal performance analysis of an inclined passive solar still using agricultural drainage water and artificial neural network in arid climate. **Solar Energy**, v. 153, p. 383–395, 1 set. 2017.

MÉNDEZ-VÁZQUEZ, L. J. et al. Delineation of site-specific management zones for pest control purposes: Exploring precision agriculture and species distribution modeling approaches. **Computers and Electronics in Agriculture**, v. 167, p. 105101, 1 dez. 2019.

MIGUEL LENZ, A. et al. Expansion of eucalyptus energy plantations under a Livestock-Forestry Integration scenario for agroindustries in Western Paraná, Brazil. **Ecological Indicators**, v. 98, p. 39–48, 2019.

MOHAMMED, I. et al. A blended census and multiscale remote sensing approach to probabilistic cropland mapping in complex landscapes. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 161, p. 233–245, 1 mar. 2020.

MORAIS, R. et al. mySense: A comprehensive data management environment to improve precision agriculture practices. **Computers and Electronics in Agriculture**, v. 162, p. 882–894, 1 jul. 2019.

MUKHERJEE, A.; MISRA, S.; RAGHUWANSHI, N. S. A survey of unmanned aerial sensing solutions in precision agriculture. **Journal of Network and Computer Applications**, v. 148, p. 102461, 15 dez. 2019.

MUNAWAR, A. A. et al. Calibration models database of near infrared spectroscopy to predict agricultural soil fertility properties. **Data in Brief**, v. 30, p. 105469, 2020.

MWALUPASO, G. E. et al. Recuperating dynamism in agriculture through adoption of sustainable agricultural technology - Implications for cleaner production. **Journal of Cleaner Production**, v. 232, p. 639–647, 20 set. 2019.

NABIL, M. et al. Assessing factors impacting the spatial discrepancy of remote sensing based cropland products: A case study in Africa. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, p. 102010, 1 mar. 2020.

NEISSI, L.; ALBAJI, M.; BORROOMAND NASAB, S. Combination of GIS and AHP for site selection of pressurized irrigation systems in the Izeh plain, Iran. **Agricultural Water Management**, v. 231, p. 106004, 31 mar. 2020.

NEVAVUORI, P.; NARRA, N.; LIPPING, T. Crop yield prediction with deep convolutional neural networks. **Computers and Electronics in Agriculture**, v. 163, p. 104859, 2019.

NGHIA, B. P. Q. et al. Applying Google earth engine for flood mapping and monitoring in the downstream provinces of Mekong river. **Progress in Disaster Science**, v. 14, p. 100235, 2022.

NGUYEN, T. H.; NONG, D.; PAUSTIAN, K. Surrogate-based multi-objective optimization of management options for agricultural landscapes using artificial neural networks. **Ecological Modelling**, v. 400, p. 1–13, 24 maio 2019.

NGUYEN, T. T. et al. Monitoring agriculture areas with satellite images and deep learning. **Applied Soft Computing**, v. 95, p. 106565, 2020.

PERAKIS, K. et al. CYBELE – Fostering precision agriculture & livestock farming through secure access to large-scale HPC enabled virtual industrial experimentation environments fostering scalable big data analytics. **Computer Networks**, v. 168, p. 107035, 26 fev. 2020.

PILEVAR, A. R. et al. Integrated fuzzy, AHP and GIS techniques for land suitability assessment in semi-arid regions for wheat and maize farming. **Ecological Indicators**, v. 110, p. 105887, 1 mar. 2020.

POPOVIĆ, T. et al. Architecting an IoT-enabled platform for precision agriculture and ecological monitoring: A case study. **Computers and Electronics in Agriculture**, v. 140, p. 255–265, 1 ago. 2017.

RADOGLU-GRAMMATIKIS, P. et al. A Compilation of UAV Applications for Precision Agriculture. **Computer Networks**, p. 107148, 13 fev. 2020.

RAY, C. et al. Heterogeneous integrated dataset for Maritime Intelligence, surveillance, and reconnaissance. **Data in Brief**, v. 25, p. 104141, 2019.

ROBERTS, J. F. et al. Pyeo: A Python package for near-real-time forest cover change detection from Earth observation using machine learning. **Computers & Geosciences**, v. 167, p. 105192, 2022.

RUPNIK, R. et al. AgroDSS: A decision support system for agriculture and farming. **Computers and Electronics in Agriculture**, v. 161, p. 260–271, 2019.

SABU, K. M.; KUMAR, T. K. M. Predictive analytics in Agriculture: Forecasting prices of Arecanuts in Kerala. **Procedia Computer Science**, v. 171, p. 699–708, 2020.

SANTOS, A. R. DOS et al. Geotechnology and landscape ecology applied to the selection of potential forest fragments for seed harvesting. **Journal of Environmental Management**, v. 183, p. 1050–1063, 1 dez. 2016.

SHARMA, R. et al. A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. **Computers & Operations Research**, v. 119, p. 104926, 2020.

SHARMA, S. K.; MISRA, S. K.; SINGH, J. B. The role of GIS-enabled mobile applications in disaster management: A case analysis of cyclone Gaja in India. **International Journal of Information Management**, p. 102030, 19 nov. 2019.

SILBERGELD, E. K. One health and the agricultural transition in food animal production. **Global Transitions**, v. 1, p. 83–92, 1 jan. 2019.

SOUZA, F. H. Q. et al. The use of vegetation index via remote sensing allows estimation of soybean application rate. **Remote Sensing Applications: Society and Environment**, v. 17, p. 100279, 1 jan. 2020.

SRIVASTAVA, K. et al. UAVs technology for the development of GUI based application for precision agriculture and environmental research. **Remote Sensing Applications: Society and Environment**, v. 16, p. 100258, 1 nov. 2019.

STOFFEL, M. et al. Artificial neural networks in structural dynamics: A new modular radial basis function approach vs. convolutional and feedforward topologies. **Computer Methods in Applied Mechanics and Engineering**, v. 364, p. 112989, 1 jun. 2020.

SU, Y. et al. Quantifying the sustainability of three types of agricultural production in China: An emergy analysis with the integration of environmental pollution. **Journal of Cleaner Production**, v. 252, p. 119650, 10 abr. 2020.

TAHMASEBI, P. et al. Machine learning in geo- and environmental sciences: From small to large scale. **Advances in Water Resources**, v. 142, p. 103619, 2020.

TRILLES, S. et al. Development of an open sensorized platform in a smart agriculture context: A vineyard support system for monitoring mildew disease. **Sustainable Computing: Informatics and Systems**, 24 jan. 2019.

TROUILLET, B. Aligning with dominant interests: The role played by geo-technologies in the place given to fisheries in marine spatial planning. **Geoforum**, v. 107, p. 54–65, 1 dez. 2019.
TRUMPY, E.; MANZELLA, A. Geothopica and the interactive analysis and visualization of the updated Italian National Geothermal Database. **International Journal of Applied Earth Observation and Geoinformation**, v. 54, p. 28–37, 1 fev. 2017.

USMAN, M. et al. Numerical modelling and remote sensing based approaches for investigating groundwater dynamics under changing land-use and climate in the agricultural region of Pakistan. **Journal of Hydrology**, v. 581, p. 124408, 1 fev. 2020.

VALENCIA, J. et al. A GIS-based methodological framework to identify superficial water sources and their corresponding conduction paths for gravity-driven irrigation systems in developing countries. **Agricultural Water Management**, v. 232, p. 106048, 1 abr. 2020.

VANDERHOOF, M. K. et al. High-frequency time series comparison of Sentinel-1 and Sentinel-2 satellites for mapping open and vegetated water across the United States (2017–2021). **Remote Sensing of Environment**, v. 288, p. 113498, 2023.

WALTERS, J. P. et al. Exploring agricultural production systems and their fundamental components with system dynamics modelling. **Ecological Modelling**, v. 333, p. 51–65, 10 ago. 2016.

WANG, J. et al. Integrating remote sensing-based process model with environmental zonation scheme to estimate rice yield gap in Northeast China. **Field Crops Research**, v. 246, p. 107682, 1 fev. 2020.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 236, p. 111402, 1 jan. 2020.

WU, Q. et al. Integrating LiDAR data and multi-temporal aerial imagery to map wetland inundation dynamics using Google Earth Engine. **Remote Sensing of Environment**, v. 228, p. 1–13, 2019.

WU, Q. geemap: A Python package for interactive mapping with Google Earth Engine. **The Journal of Open Source Software**, v. 5, p. 2305, 2020.

XIA, Y. et al. Agricultural chemicals use data access using coldfusion markup language and a relational database. **Computers and Electronics in Agriculture**, v. 38, n. 3, p. 217–225, 2003.

XIAO, C. et al. A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data. **Environmental Modelling & Software**, v. 120, p. 104502, 2019.

XU, X. et al. Application of neural network algorithm in fault diagnosis of mechanical intelligence. **Mechanical Systems and Signal Processing**, p. 106625, 25 jan. 2020.

YANG, H. et al. Hyper-temporal remote sensing data in bare soil period and terrain attributes for digital soil mapping in the Black soil regions of China. **CATENA**, v. 184, p. 104259, 1 jan. 2020.

YARAMASU, R.; BANDARU, V.; PNVR, K. Pre-season crop type mapping using deep neural networks. **Computers and Electronics in Agriculture**, v. 176, p. 105664, 2020.

YUE, J.; TIAN, Q. Estimating fractional cover of crop, crop residue, and soil in cropland using broadband remote sensing data and machine learning. **International Journal of Applied Earth Observation and Geoinformation**, v. 89, p. 102089, 1 jul. 2020.

YUE, Y. et al. Prediction of maize growth stages based on deep learning. **Computers and Electronics in Agriculture**, v. 172, p. 105351, 2020.

ZAHARAN, S. A. E.-S.; SAEED, R. A.-H.; ELAZIZY, I. M. Remote sensing based water resources and agriculture spatial indicators system. **The Egyptian Journal of Remote Sensing and Space Science**, v. 25, n. 2, p. 515–527, 2022.

ZHANG, M. et al. Image fusion employing adaptive spectral-spatial gradient sparse regularization in UAV remote sensing. **Signal Processing**, v. 170, p. 107434, 1 maio 2020.

ZHANG, Z.; ZHOU, Y.; HUANG, X. Applicability of GIS-based spatial interpolation and simulation for estimating the soil organic carbon storage in karst regions. **Global Ecology and Conservation**, v. 21, p. e00849, 1 mar. 2020.

ZHAO, F. et al. Extraction of long time series wetland information based on Google Earth Engine and random forest algorithm for a plateau lake basin – A case study of Dianchi Lake, Yunnan Province, China. **Ecological Indicators**, v. 146, p. 109813, 2023.

ZHAO, J. et al. A robust spectral-spatial approach to identifying heterogeneous crops using remote sensing imagery with high spectral and spatial resolutions. **Remote Sensing of Environment**, v. 239, p. 111605, 15 mar. 2020.

ZHOU, B.; OKIN, G. S.; ZHANG, J. Leveraging Google Earth Engine (GEE) and machine learning algorithms to incorporate in situ measurement from different times for rangelands monitoring. **Remote Sensing of Environment**, v. 236, p. 111521, 2020.