



**UNIVERSIDADE FEDERAL DE ALAGOAS
CAMPUS DE ENGENHARIAS E CIÊNCIAS AGRÁRIAS
CURSO DE GRADUAÇÃO AGRONOMIA**

JOÃO PEDRO DOS SANTOS VERÇOSA

**DESENVOLVIMENTO DE ALGORITMO BASEADO EM REDES
NEURAS CONVOLUCIONAIS PARA DETECÇÃO DE ERVAS
DANINHAS EM ÁREAS DE CANA-DE-AÇÚCAR**

RIO LARGO/AL

2022

JOÃO PEDRO DOS SANTOS VERÇOSA

**DESENVOLVIMENTO DE ALGORITMO BASEADO EM REDES
NEURAIS CONVOLUCIONAIS PARA DETECÇÃO DE ERVAS
DANINHAS EM ÁREAS DE CANA-DE-AÇÚCAR**

Trabalho apresentado a Universidade Federal de Alagoas, Campus de Engenharias e Ciências Agrárias, como requisito para obtenção do título de Bacharel em Agronomia.

Orientador: Prof. Dr. Arthur Costa Falcão
Tavares

Coorientador: Prof. Dr. Marcus de Barros
Braga

RIO LARGO/AL

2022

Catálogo na fonte
Universidade Federal de Alagoas
Campus de Engenharias e Ciências Agrárias – CECA
Bibliotecário Responsável: Erisson Rodrigues de Santana

V482d Verçosa, João Pedro dos Santos.

Desenvolvimento de algoritmo baseado em redes neurais convolucionais para detecção de ervas daninhas em áreas de cana-de-açúcar. / João Pedro dos Santos Verçosa. – 2022.

60 f.: il.

Orientador: Prof. Dr. Arthur Costa Falcão Tavares

Coorientador: Prof. Dr. Marcus de Barros Braga

Trabalho de Conclusão de Curso (Graduação em Agronomia) – Curso de Agronomia, Campus de Engenharias e Ciências Agrárias, Universidade Federal de Alagoas. Rio Largo, 2022.

Inclui Bibliografia

1. *Python*.
2. Imagem PlanetScope.
3. Agricultura de Precisão.
4. cana-de-açúcar.
5. Ervas daninhas

CDU:632.51:633.61

UNIVERSIDADE FEDERAL DE ALAGOAS
CAMPUS DE ENGENHARIAS E CIÊNCIAS AGRÁRIAS
CURSO DE GRADUAÇÃO AGRONOMIA

FOLHA DE APROVAÇÃO

JOÃO PEDRO DOS SANTOS VERÇOSA

**DESENVOLVIMENTO DE ALGORITMO BASEADO EM REDES
NEURAS CONVOLUCIONAIS PARA DETECÇÃO DE ERVAS
DANINHAS EM ÁREAS DE CANA-DE-AÇÚCAR**

Trabalho de conclusão de curso
apresentado como requisito parcial para
obtenção do título de Bacharel em Agronomia,
pela Universidade Federal de Alagoas.

Aprovado em: 19 de abril de 2022.

Banca Examinadora

Documento assinado digitalmente



ARTHUR COSTA FALCAO TAVARES
Data: 23/04/2022 06:44:36-0300
Verifique em <https://verificador.iti.br>

Arthur Costa Falcão Tavares, Doutor, CECA/UFAL.

Documento assinado digitalmente



REGLA TOUJAGUEZ LA ROSA MASSAHUD
Data: 23/04/2022 00:49:17-0300
Verifique em <https://verificador.iti.br>

Regla Toujaguez La Rosa Massahud, Doutora, CECA/UFAL.

Documento assinado digitalmente



FRANCISCO RAFAEL DA SILVA PEREIRA
Data: 25/04/2022 18:28:39-0300
Verifique em <https://verificador.iti.br>

Francisco Rafael da Silva Pereira, Doutor, SATUBA/IFAL

Aos meus Amados e queridos pais, Antônio Sérgio de Verçosa e Genivalda Maria dos Santos de Verçosa, pilares da minha formação como ser humano, por todo amor, afeto, dedicação, incentivo, apoio incondicional em momentos difíceis na minha vida e por acreditarem sempre no meu potencial; e a minha querida avó Maria José de Verçosa, por todos os ensinamentos, amor, alegria e por sempre me apoiar e confiar na minha vitória.

A eles minha eterna gratidão.

DEDICO

AGRADECIMENTOS

A Deus, primeiramente, por tudo que tem me proporcionado durante a minha vida, e me orientado em todas as escolhas e conquistas.

A minha amada e doce Mãe, por seus conselhos e por estar sempre presente na minha vida e acreditando em mim.

Ao meu amado Pai, por todo ensinamento e exemplo a seguir na vida, com dedicação, foco e fé.

Ao meu cachorro Coragem, por ser sempre companheiro estando ao meu lado.

Aos meus amigos, Walisson Ferreira, Iêdo Peroba, Victor Rodrigues, Marcos Antônio, Flavio Henrique, Arryson Cardoso, Lucas Galdino e Julia Omena, pela amizade e incentivo em todos os momentos vividos nestes anos de graduação.

Ao meu querido e grande orientador, Prof. Dr Arthur Costa Falcão Tavares, pela sua grande amizade, confiança, apoio em momentos difíceis, dedicação, comprometimento, incentivo, perseverança, por todos os conhecimentos transmitidos e por todos os conselhos para a minha vida acadêmica e pessoal. Sem a sua orientação certamente esse TCC não teria acontecido.

Ao meu Coorientador, Prof. Dr. Marcus de Barros Braga, pela amizade, dedicação, todo ensinamento transmitido e que, apesar das dificuldades da distância, sempre esteve presente para ajudar.

A todos os professores do Campus de Engenharias e Ciências Agrárias, em especial: Regla Toujaguez e Guilherme Lyra, por todo apoio, palavra de conforto, incentivo, disponibilidade, confiança e amizade. Que levarei para minha vida.

A todos os meus familiares, pela torcida e apoio.

A todas as pessoas que influenciaram diretamente e indiretamente na minha vida pessoal e acadêmica.

Ao Laboratório de Análises Espaciais e Ambientais (LANESA) e o Grupo de pesquisa do Cnpq CADEH (Coletivo para Aperfeiçoamento de Dados Espaciais e Humanos), por seu suporte e incentivo aos alunos, onde pude ter o privilégio de fazer parte desde a sua criação.

A todos amigos e colegas, de laboratório, todo conhecimento adquirido, ideias, amizades e palavras encorajadoras.

Aos colegas da turma de Agronomia 2017.1

MUITO OBRIGADO!

"O segredo da criatividade está em dormir bem e abrir a mente às possibilidades infinitas. O que é um homem sem sonhos?". Albert Einstein

RESUMO

Infestação por ervas daninhas é um importante fator de perda de produtividade para o cultivo da cana-de-açúcar. A utilização de dados de sensoriamento remoto, sejam oriundos de satélites ou de Aeronaves Remotamente Pilotadas (RPA), em conjunto com técnicas de Inteligência Artificial (IA), podem conduzir o cultivo da cana-de-açúcar a um novo patamar no que se refere ao controle de ervas daninhas. Com esse intuito, foi desenvolvido um algoritmo baseado em Redes Neurais Convolucionais (CNN), para detecção, quantificação e mapeamento de ervas daninhas em áreas de cana-de-açúcar no estado de Alagoas. Dados oriundos de imagens do satélite PlanetScope foram subdivididos, separados, treinados em quatro cenários diferentes, classificados e georreferenciados, sendo finalmente transformados em mapa. Os parâmetros do treinamento e teste da CNN aplicados no cenário um apresentaram o melhor resultado de acurácia (98,3%), sendo selecionado para gerar a forma geométrica a partir do algoritmo classify, a qual em seguida foi georreferenciada e transformada em um mapa das classes cana-de-açúcar, erva daninha e floresta. A comparação dos resultados de acurácia dos cenários mostrou que os valores dos resultados obtidos pelo algoritmo CNN foram superiores aos valores do coeficiente Kappa. A análise quantitativa de área (ha) infestada por erva daninha, indicou alta probabilidade de impacto negativo na produtividade da cana-de-açúcar. O orthomosaico de imagens de RPA e a colaboração dos técnicos da Usina foram primordiais para comprovar a ocorrência de infestação de ervas daninhas, assim como, o reconhecimento da espécie (*Momordica charantia* L.) preponderante na fazenda. Recomenda-se que futuramente seja realizada a adequação do algoritmo da CNN para imagens de RPA visando a diferenciação entre espécies de ervas daninhas, assim como, sua aplicação na detecção de ervas daninhas em áreas com outras culturas de grande relevância para os setores agrícola e econômico do estado de Alagoas.

Palavras-chave: CNN. Imagem PlanetScope. *Python*. Agricultura de Precisão.

ABSTRACT

Weed infestation is an important factor in productivity loss for sugarcane cultivation. The use of remote sensing data, whether coming from satellites or from Remotely Piloted Aircraft (RPA), in conjunction with Artificial Intelligence (AI) techniques, can lead the cultivation of sugarcane to a new level in terms of refers to weed control. For this purpose, an algorithm based on Convolutional Neural Networks (CNN) was developed for detection, quantification and mapping of weeds in sugarcane areas in the state of Alagoas. Data from images of the PlanetScope satellite were subdivided, separated, trained in different scenarios, Classified and georeferenced, being finally turned into a map. Scenario one of the CNN training and test presented the best accuracy result (98.3%), being selected to generate the geometric shape from the clas-sify algorithm, which was then georeferenced and transformed into a map of the sugarcane, weed and forest classes. The comparison of the accuracy results showed that the values of the results obtained by the CNN algorithm were higher than the Kappa coefficient values. The quantitative analysis of the area (ha) infested by weed indicated a high probability of a negative impact on sugarcane productivity. The orthomosaic of RPA images and the collaboration of the Plant technicians were essential to prove the occurrence of weed infestation, as well as the recognition of the species (*Momordica charantia* L.) predominant on the farm. It is recommended that, in the future, the adequacy of CNN's algorithm for RPA images be carried out, aiming at the differentiation between weed species, as well as its application in the detection of weeds in areas with other cultivars of great relevance to the sectors agricultural and economic state of Alagoas.

Key-words: CNN. PlanetScope image. Python. Precision Agriculture.

LISTAS DE FIGURAS

Figura 1 -	Mapa da Área de Estudo	31
Figura 2 -	Fluxograma com as etapas da metodologia	33
Figura 3 -	Amostras coletadas a partir do mosaico das imagens PlanetScope	34
Figura 4 -	Padronização de tamanho das amostras	35
Figura 5 -	Arquitetura da CNN no cenário 4	37
Figura 6 -	Acurácia do treinamento do cenário 1	40
Figura 7 -	Acurácia do treinamento do cenário 2	42
Figura 8 -	Acurácia do treinamento do cenário 3	44
Figura 9 -	Acurácia do treinamento do cenário 4	46
Figura 10 -	Classificação representativa da Rede	49
Figura 11 -	Orthomosaico do talhão com infestação de erva daninha	50
Figura 12 -	Gráfico Representativo da porcentagem de cada Classe na fazenda Riacho de Pedra	51

LISTAS DE GRÁFICOS

Gráfico 1 -	Acurácia da CNN no cenário 1	41
Gráfico 2 -	Perda do treinamento e da validação da CNN no cenário 1	42
Gráfico 3 -	Acurácia da CNN no cenário 2	43
Gráfico 4-	Perda do treinamento e da validação da CNN no cenário 2	44
Gráfico 5 -	Acurácia da CNN no cenário 3	45
Gráfico 6 -	Perda do treinamento e da validação da CNN no cenário 3	46
Gráfico 7 -	Acurácia da CNN no cenário 4	47
Gráfico 8 -	Perda do treinamento e da validação da CNN no cenário 4	48
Gráfico 9 -	Gráfico Representativo da porcentagem de cada Classe na fazenda Riacho de Pedra	51

LISTAS DE TABELAS

Tabela 1 -	Conjunto de dados Brutos	36
Tabela 2 -	Parametrizações utilizadas nos cenários de aplicação da CNN	37
Tabela 3 -	Matriz Confusão cenário 1	40
Tabela 4 -	Matriz Confusão cenário 2	42
Tabela 5 -	Matriz Confusão cenário 3	44
Tabela 6 -	Matriz Confusão cenário 4	46
Tabela 7 -	Acurácia da CNN e coeficiente Kappa da matriz de confusão	48
Tabela 8 -	Dados de área e porcentagem	51

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVOS	16
1.1.1	Objetivo geral	16
1.1.2	Objetivos específicos	16
2	REFERENCIAL TEÓRICO	17
2.1	CULTURA DA CANA-DE-AÇÚCAR	17
2.1.1	Impacto econômico	18
2.2	ERVAS DANINHAS	19
2.2.1	Impacto das ervas daninhas na produtividade agrícola	19
2.3	AGRICULTURA DE PRECISÃO	20
2.3.1	Geomática aplicada à cana-de-açúcar	20
2.3.2	Agricultura de precisão aplicada à erva daninha	21
2.4	SENSORIAMENTO REMOTO	22
2.4.1	Imagem de satélite	22
2.4.2	RPA	23
2.4.3	Sensoriamento aplicado a agricultura	24
2.5	INTELIGÊNCIA ARTIFICIAL: VISÃO GERAL	25
2.5.1	<i>Machine learning</i> (ML)	25
2.5.2	<i>Deep learning</i> (DL)	26
2.5.3	Aplicação de ML e DL na agricultura	27
2.5.4	Imagem de satélite e DL aplicados a agricultura de precisão	29
2.5.5	RPA aplicado a agricultura de precisão e DL	29
3	MATERIAIS E MÉTODOS	31
3.1	LOCAL DE ESTUDO	31
3.2	SOFTWARE E HARDWARE	32
3.3	DADOS E EQUIPAMENTOS GERAIS	32
3.4	METODOLOGIA	32
3.4.1	Aquisição dos dados	33
3.4.2	Criação dos bancos de dados georreferenciados	34
3.4.3	Pré-processamento (QGIS)	34
3.4.4	Algoritmo (Python)	34

3.4.5	Treinamento e teste	36
3.4.6	<i>Classify</i> (Classificação)	38
3.4.7	<i>Georeferencer</i> (Georreferenciador)	38
3.4.8	Orthomosaico (RPA)	38
3.4.9	Análise dos resultados (Métodos estatísticos)	39
4	RESULTADOS E DISCUSSÃO	40
4.1	ANÁLISE DOS CENÁRIOS DE APLICAÇÃO DA CNN	40
4.2	COMPARAÇÃO ENTRE ACURÁCIA DA CNN E COEFICIENTE KAPPA	48
4.3	REPRESENTAÇÃO VISUAL E GEORREFERENCIAMENTO	49
4.4	COMPROVAÇÃO DE PRESENÇA DE ERVA DANINHA COM ORTHOMOSAICO	49
4.5	CÁLCULO DE ÁREA DAS CLASSES	50
5	CONCLUSÃO	52
5.1	TRABALHOS FUTUROS	52
6	REFERÊNCIAS	53

1 INTRODUÇÃO

A cana-de-açúcar é uma cultura agrícola instalada aqui no Brasil entre os séculos XVI e XVIII, e que rapidamente se adaptou ao solos brasileiros, proporcionando prosperidade econômica e expansão agrícola, principalmente no bioma Mata Atlântica.

A instalação da cana-de-açúcar no estado de Alagoas aconteceu no período em que o estado pertencia a capitania de Pernambuco, sendo bastante presente no município de Porto Calvo, onde acabaram se estabelecendo os primeiros engenhos e posteriormente usinas de açúcar.

A cana-de-açúcar é uma das culturas agrícolas que mais impactam positivamente no produto interno bruto (PIB) nacional, entorno de 2%, através do setor sucroalcooleiro baseado principalmente na produção de açúcar ou álcool. No estado de Alagoas o plantio da cana-de-açúcar tem impacto econômico de 27% na geração de riqueza, sendo a principal cultura do estado e contribuindo enormemente para geração de empregos.

Como a cana-de-açúcar é uma cultura de grande importância, existem diversos fatores, entre eles a infestação de talhões por ervas daninhas, que podem levar a uma perda drástica na sua produtividade. Para tanto, novas tecnologias baseadas na agricultura de precisão vem sendo desenvolvidas, e aliadas as técnicas tradicionais de controle de ervas daninhas, trazendo ótimos resultados no aumento da produtividade e diminuição dos impactos ambientais.

A utilização de dados de sensoriamento remoto, sejam eles oriundos de imagens de satélites, para grandes áreas de plantio, ou de imagens obtidas por Aeronaves Remotamente Pilotadas (RPA), para áreas menores, para criar grandes bancos de dados geoespaciais em conjunto com técnicas de Inteligência Artificial (IA), mais especificamente Aprendizado Profundo ou *Deep Learning* podem conduzir o cultivo da cana-de-açúcar no estado de Alagoas a um novo patamar no que se refere a detecção, classificação, mapeamento e controle de ervas daninhas.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Desenvolver um algoritmo baseado em Redes Neurais Convolucionais (CNN), para detecção, quantificação e mapeamento de ervas daninhas em áreas de cana-de-açúcar de plantada no estado de Alagoas, a partir de imagens de satélite.

1.1.2 Objetivos específicos

- Criar banco de dados oriundos de imagens do satélite PlanetScope;
- Separar amostras de dados referentes a cana-de-açúcar e ervas daninhas, em pastas diferentes;
- Desenvolver algoritmo para o treinamento da CNN;
- Treinar o algoritmo para detectar cana-de-açúcar e ervas daninhas;
- Desenvolver algoritmo para identificar e classificar ervas daninhas por imagens de satélite;
- Identificar, classificar, mapear e quantificar áreas infestadas por ervas daninhas;
- Classificar, em campo, família da erva daninha detectada pelo algoritmo.

2 REFERENCIAL TEÓRICO

2.1 CULTURA DA CANA-DE-AÇÚCAR

A cana de açúcar tem importante função e impacto na economia mundial e, para chegar a isso, conta com fatores importantes como a adoção de práticas agrícolas de precisão, planejamento, cronogramas de moagem e a utilização de softwares e tecnologias para aumentar sua produtividade. (RAHMAN, 2010).

A cana-de-açúcar é uma cultura que quando processada industrialmente serve de alimento para os seres humanos e “in natura” para animais, além de ser matéria prima para a produção de biocombustível, o qual atualmente tem sido utilizado em esfera global. Portanto, trata-se de uma cultura agrícola que merece uma atenção especial, e que tem sido dotada de tecnologias inovadoras para melhoria da produtividade agrícola e minimização de riscos ambientais. (BORDONAL, et al., 2018)

A cultura canavieira foi um fator importante de formação e desenvolvimento regional no estado de Alagoas. A influência da cultura canavieira vai além dos imensos canaviais que predominam dos tabuleiros costeiros, pois se estendem também temporalmente. (SANTOS, 2011)

Os métodos utilizados na área agrícola e industrial do setor sucroalcooleiro alagoano passaram de rudimentares para altamente tecnificados e informatizados. (ANDRADE, 2010)

A expansão da cana-de-açúcar tanto para a produção do açúcar quanto para a produção do biocombustível, tem trazido desenvolvimento socioeconômico para as regiões produtoras, e conseqüentemente, aumentado a qualidade de vida da população e impactado a economia local. (MARQUES POSTAL, et al., 2020)

O deslocamento dos canaviais para as áreas de tabuleiros e interflúvios fizeram com que as usinas alcançassem uma produção bastante expressiva no estado de Alagoas. A Usina Coruripe, que está entre as principais produtoras de cana-de-açúcar, vem se destacando como uma das maiores do nordeste devido ao uso de geotecnologias para aumentar sua produtividade. Porém, até a década de sessenta mantinha uma produção modesta, necessitando expandir seu cultivo de cana-de-açúcar para os tabuleiros. (ANDRADE, 2010)

A crescente demanda do mercado “AGRO”, que cada vez mais necessita da inserção de novas tecnologias que favoreçam o agronegócio, se dá principalmente pelo processo da mecanização do trabalho. (GONÇALVES, 2017)

No entanto, há fatores importantes como a adoção de práticas agronômicas, planejamento, cronogramas de moagem e a utilização de softwares e tecnologias para obter um maior rendimento e aumento de produtividade da cana. (RAHMAN, 2010)

2.1.1 Impacto econômico

Na safra de 2020/21 o Brasil produziu cerca de 39,5 milhões de toneladas de açúcar, o que equivale a 21% da produção mundial, podendo em suas melhores condições gerar um ganho econômico de R\$ 161,75 milhões na região Centro-Sul e R\$ 33,06 milhões no Nordeste. (GARCIA, et al., 2020)

De acordo com os dados do CONAB (2020) a produção de cana-de-açúcar no ciclo 2020/21 totalizou 654,8 milhões de toneladas, 1,8% superior ao da safra 2019/20. A região maior produtora é a do sudeste alcançando 428,6 milhões de toneladas colhidas, indicando acréscimo de 3,3% em comparação a 2019/20 sendo destaque o Estado de São Paulo e Minas Gerais.

A região nordeste ao todo, colheu 48,4 milhões de toneladas, representando redução de 1,4%. O estado de Alagoas obteve 17 milhões de toneladas de cana-de-açúcar, simbolizando redução de 2,5% em relação a 2019/20. (CONAB, 2020)

A cana de açúcar é responsável por aproximadamente 27% do Produto Interno Bruto (PIB) do Estado de Alagoas, o que representou em 2018 um valor de R\$ 54,413 bilhões, além de proporcionar 120 mil empregos diretos e 270 mil empregos indiretos. (SEPLAG/AL, 2020; SANTOS, 2011)

Foram utilizadas técnicas de agricultura de precisão voltados a cultura da cana-de-açúcar, como o uso de geoprocessamento para analisar a produtividade, que vêm apresentando resultados econômicos positivos. Com aplicação da agricultura de precisão, observou-se um aumento de US\$ 6.5827 (US\$ 563 ha¹) nos últimos 5 anos, comparando-se ao uso de técnicas convencionais. (COX, et al., 2015)

2.2 ERVAS DANINHAS

O termo planta daninha é antropocêntrico e tem a intenção explícita de refletir uma espécie que vai contra os interesses humanos, isto porque essas plantas têm como característica intrínseca o impacto negativo em áreas de plantio. Além disso, causam problemas ao seu entorno, tais como dificuldade para manutenção de reservas ambientais, aumento de acidentes em rodovias, risco em ambientes aquáticos, entre outros. (PITELLI, 2015)

O emprego da terminologia invasoras não se enquadra a plantas daninhas, pois ela se limita a dispersão de espécies, ou seja, a forma como irá se distribuir geograficamente em vários lugares onde não é nativa, e não gera impactos negativos ao ser humano. (MORO, et al., 2012)

As plantas daninhas são plantas pioneiras de sucessão secundária, acarretando em diversos fatores como capacidade de germinação irregular, disseminação a curta e longa distância, rápido crescimento vegetativo e florescimento, e utilizam agentes de polinização não específicos (Ex.: vento), que dificultam o seu controle. (PITELLI, 1987)

As ervas daninhas competem com as culturas por recursos como luz, nutrientes, água e espaço. Quando em estágio fenológico de senescência, as ervas daninhas produzem de milhares a centenas de milhares de sementes que podem sobreviver durante muito tempo representando uma grande ameaça a produtividade das culturas. (LIANG, et al., 2019)

2.2.1 Impacto das ervas daninhas na produtividade agrícola

Avaliações visuais de cobertura de espécies de ervas daninhas são realizadas para sua detecção em talhões de cana-de-açúcar, sendo possível se agrupar de acordo com o grau de infestação. Porém, pode-se realizar avaliações fitossociológicas com uma melhor precisão utilizando técnicas de estatística multivariada. (FERREIRA, et al., 2011)

A aplicação convencional de herbicidas tende a ocasionar impactos negativos como poluição de recursos ambientais e de alimentos, resistência da planta daninha, além de, impactos financeiros devido a gastos desnecessários de herbicida,

de combustível para máquinas aplicadoras e de diárias para aplicadores manuais. (ISLAM, et al., 2018)

No sistema de mudas pré-brotadas de cana-de-açúcar, para obter uma maior produtividade e qualidade, o controle de plantas daninhas deve ser um dos principais focos do manejo integrado, afim de evitar perdas significativas, já que são comuns essas ocorrências em práticas de plantio convencional. (SILVA, et al., 2018)

2.2 AGRICULTURA DE PRECISÃO

A agricultura de precisão tem como principal objetivo diminuir os impactos causados pela agricultura convencional, e para isso utiliza tecnologias inovadoras afim de minimizar os danos ao meio ambiente e proporcionar maiores ganhos econômicos. (LIMA, 2020)

A utilização eficiente da agricultura de precisão necessita de uma grande quantidade de dados sobre as áreas de cultivo, sendo também dependente de uma mão de obra especializada e conhecedora do sistema de produção local. (REETZ & FIXEN, 1999; DOERGE, 1999)

A agricultura de precisão vem se destacando nos meios rurais através de várias técnicas dentre elas está a utilização do GPS junto com dados oriundos de SIG. Com isso é possível prever rendimento da cultura, melhoria na conservação do ambiente junto com um aumento de produtividade. (PALANISWAMI, et al., 2011)

A agricultura de precisão utiliza técnicas computacionais para elaborar mapas em tempo real utilizando dados coletados por GPS geodésico, e tem sido largamente aplicada para avaliar o rendimento e produtividade da cultura de cana-de-açúcar. (MOMIN, et al., 2019; DRIEMEIER, et al., 2016)

2.3.1 Geomática aplicada à cana-de-açúcar

A ferramenta SIG é muito utilizada para critérios de adequação da terra durante a implantação da cana-de-açúcar. No distrito de Bijnor na Índia, o mapa de adequação demonstrou que na área de estudo 61% da área foi altamente adequada, seguida por 24% moderadamente adequada, 7% marginalmente adequada e 8%

inadequada para cana-de-açúcar. As áreas que demonstraram ser inadequadas são devido a inclinação do terreno, solos rasos e risco de erosão. (JAMIL, et al., 2018)

A partir da localização e comparação de dados espaciais é possível realizar os mapeamentos multitemporais possibilitando criar e aferir um modelo que amplie o conhecimento dos fatores responsáveis pelas mudanças de uso da terra, com ênfase, no processo de expansão canavieira. (MACEDO, et al., 2013).

O uso do sensoriamento remoto por satélite, utilizando técnicas de SIG, foi fundamental para estimar a produtividade de cana-de-açúcar permitindo aos produtores aumentarem sua produção para o cumprimento da exigência da fábrica de açúcar na Eslovênia. (YAWSON, et al., 2018)

Utilização de RPA em conjunto com as tecnologias Lidar (Light Detection and Ranging) e SfM (structure from motion), no monitoramento para controle de crescimento da cana-de-açúcar, permitiu fazer uma modelagem para estimar a biomassa em áreas de plantio, sendo a técnica Sfm a mais rentável devido ao seu menor custo para pequenos produtores. (SOFONIA, et al., 2019)

2.3.2 Agricultura de precisão aplicada à erva daninha

Foram utilizados equipamentos para o mapeamento de ervas daninhas em áreas de plantio de milho, sendo elas feitas por amostragem sistemática em grade, que apresentaram um grande potencial de uso na agricultura devido a facilidade na execução realizando com a colheita monitorada. (SHIRATSUCHI, et al., 2004)

Os SIG`s são responsáveis por combinar e analisar as informações obtidas em campo por sensores acoplados nos equipamentos de mecanização agrícola, o que possibilita a criação de mapas de infestações de ervas daninhas em locais de plantio, facilitando uma aplicação mais precisa de herbicidas. (WEIS, et al., 2008)

Através da visão computacional composta por algoritmos desenvolvidos a partir da biblioteca opencv aplicada a imagens RGB, foi possível criar um protótipo para detectar ervas daninhas e identificar a melhor aplicação de herbicidas gerando uma economia média de 68,95% nos custos, comparando-se com outros métodos baseados em agricultura de precisão. (COLTRO, 2017)

2.4 SENSORIAMENTO REMOTO

O sensoriamento remoto é uma técnica de captação de imagens à distância que são obtidas através de radiação eletromagnética gerada por fontes de diferentes tipos sensores: passivo (Sol), ou ativo (radar). O mesmo tem sido constantemente aplicado nos meios urbano e rural, além dos recursos ambientais. (BAPTISTA, 2021)

A definição de sensoriamento remoto está diretamente ligada aos seguintes princípios: 1) exigência: ausência de matéria no espaço entre o objeto e o sensor; 2) consequência: a informação do objeto é possível de ser transportada pelo espaço vazio; 3) processo: o elo de comunicação entre o objeto e o sensor é a radiação eletromagnética, a única forma de energia capaz de se transportar pelo espaço. (MENESES, et al., 2012)

O sensoriamento remoto envolve a forma como a radiação é absorvida, transmitida ou refletida pelos alvos terrestres, o que possibilita a realização de análises agrícolas a partir da refletância emitida pelas folhas das plantas e a partir de dados climatológicos. (LIMA, 2020)

2.4.1 Imagem de satélite

Toda imagem de satélite é formada por pequenos elementos (pixels) de mesmo tamanho que representam uma área imageada no terreno e independentemente do sensor caracterizam uma propriedade importante chamada de resolução espacial. Sendo assim, um objeto só poderá ser identificado se sua dimensão for igual ou maior que a resolução espacial. (MENESES, et al., 2012)

Para aplicações agrícolas observa-se alta correlação espacial entre os alvos, o que indica baixa variabilidade, não necessitando o uso de imagens de alta resolução espacial. (MENESES, et al., 2012)

Os satélites apresentam características fundamentais nos seus sensores (câmeras) que permitem a obtenção de imagens em diferentes bandas espectrais. O termo resolução espectral engloba os seguintes parâmetros: a) número de bandas que o sensor possui; b) a largura em comprimento de onda das bandas; c) as posições que as bandas estão situadas no espectro eletromagnético. (MENESES, et al., 2012)

Os detectores que medem a intensidade de radiância de cada pixel determina a resolução radiométrica de uma imagem de satélite. Quanto maior for a

capacidade do detector para medir as diferenças de intensidades dos níveis de radiação maior será a resolução radiométrica. (MENESES, et al., 2012)

O número de vezes que o sensor imageia uma mesma área para coletar imagens ao longo de sua vida útil caracteriza a resolução temporal de um satélite. A resolução temporal permite monitorar e detectar a evolução ou mudanças territoriais, como o ciclo fenológico de culturas. (MENESES, et al., 2012)

O Earth Resources Technology Satellite (ERTS-1), foi primeiro satélite a permitir análises significativas de recursos terrestres utilizando sensoriamento remoto, sendo desenvolvido em 23 de julho de 1972 pelo programa ERTS, o qual posteriormente foi renomeado como Landsat. A foto tomada por esse satélite tinha capacidade de imagear uma área mínima de 900m². (BAPTISTA, 2021)

O satélite PlanetScope é composto por uma constelação de 130 satélites com capacidade de imageamento de 340 milhões de km² por dia, possuindo uma resolução espacial de 3 metros e área das cenas individuais com aproximadamente 24 km x 7 km. (PLANET LABS, 2019)

O satélite PlanetScope é composto por um telescópio e um sensor de matriz de área CCD de 6600 x 4400 pixel compostos por bandas vermelho-verde-azul e infravermelho próximo (NIR), além de um receptor GNSS. (OLIVEIRA, 2019)

2.4.2 RPA

A terminologia da palavra Aeronave Remotamente Pilotada (RPA), que vem da tradução do inglês *Remotely Piloted Aircraft*, não é a única empregada para esse tipo de aeronave já que são utilizadas várias outras palavras com o mesmo significado, sendo drone a mais popular. (PRUDKIN & BREUNIG, 2019)

Conforme dados históricos, a primeira utilização de RPA ocorreu em 1849 pelo exército austríaco que usou balões carregados de explosivos para atacar a cidade de Veneza, Itália. Ao que se conhece até hoje a autoria da invenção é do israelita Abe Karem, quando criou um protótipo chamado Albatross que tinha autonomia de 56 horas no ar e era operado por apenas três pessoas. (PRUDKIN & BREUNIG, 2019)

As RPA's tiveram grande avanço a partir do ataque aos Estados Unidos no dia 11 de setembro de 2001, quando foi estabelecido que o país deveria investir nestas tecnologias para uso em combate. (GUALAZZI, et al., 2018)

A Agência Nacional de Aviação (ANAC) classifica as RPA's de acordo com sua finalidade, seja ela recreativa ou não recreativa. Conforme a regra do artigo 261 do Código Penal, é cabível a aplicação de pena de reclusão para aqueles que expõem pessoas ao perigo através da aeronave ou praticam qualquer ato capaz de impedir ou dificultar o tráfego aéreo. (VASCONCELOS & MELLO, 2019)

2.4.3 Sensoriamento aplicado a agricultura

O sensoriamento remoto tem demonstrado ser uma técnica para o mapeamento de plantas daninhas em culturas agrícolas e pastagem, porém tem-se utilizado imagens multiespectrais com maior nível de detalhamento espacial (SARTORI, et al., 2009)

A partir das imagens de RPA foi possível fazer uma mineração de dados com o modelo wondercane capaz de prever o rendimento antes da colheita da cana-de-açúcar obtendo uma alta acurácia de 98,69%. (TANUT, et al., 2021)

A partir de imagens de RPA foi possível estimar a altura de diversas culturas como, café, cana-de-açúcar e milho em seus estádios fenológicos sendo possível analisar o tamanho em que a folha pode chegar, obtendo erros de até 5 cm para períodos mais curtos de plantio. (ORÉ, et al., 2020)

Estudos utilizando dados de imagens de satélites para realizar análises de reflectância hiperespectrais através do pixel, permitiram distinguir variedades de diferentes culturas, incluindo a de algodão, arroz e cana-de-açúcar, com destaque para as variedades de cultivo de algodão que foram discriminadas com a maior precisão. (RAO, 2008)

A ausência de mapas atualizados em grandes escalas de representação tem impulsionado a utilização de Aeronave Remotamente Pilotada (RPA) quando usado comercialmente, para a geração de mapas bastante utilizados pela agricultura de precisão. (SHENDRYK, et al., 2019).

A utilização de Índice de Vegetação da Diferença Normalizada (NDVI) a partir de correções com dados de sensor de mão GreenSeeker e estimativas de rendimento na estação (INSEY), permitiu estimar a biomassa em áreas de plantio de cana-de-açúcar e diferenciar variedades de baixa densidade. (LOFTON, et al., 2012)

A utilização de RPA com câmera RGB, produz imagens com potencial para gerar produtos 2D e 3D, que podem ser utilizados para análises vegetativas de

algumas doenças, infestações de ervas daninhas, altura da planta e modelo digital de terreno. (DEL-CAMPO-SANCHEZ, et al., 2019)

2.5 INTELIGÊNCIA ARTIFICIAL: VISÃO GERAL

O significado de inteligência artificial (IA) é muito ambíguo visto que diversos autores se dividem em: forma de pensar como humanos e simples pensamento racional de percepção e ação. (NORVIG & RUSSELL, 2013)

Em 1943 os pesquisadores Warren McCulloch e Walter Pitts realizaram testes de IA utilizando neurônios para analisar a possibilidade de interação entre eles, baseando-se no conhecimento da fisiologia e da função do cérebro humano. (NORVIG & RUSSELL, 2013)

Contudo, os desenvolvedores da IA foram bastante ousados para prever a aplicação do seu sistema, porém só foi comprovada a sua importância com a criação do programa DENDRAL o qual representou o primeiro sistema bem-sucedido derivado de um grande número de regras. (GOMES, 2010)

A inteligência Artificial pode ser agrupada em quatro ramos: sistemas que pensam como seres humanos, sistemas que atuam como seres humanos, sistemas que pensam de forma racional e sistemas que atuam racionalmente. Sendo assim, devido ao conjunto de várias ciências, principalmente a computação e a matemática, foi possível inserir em uma máquina a capacidade de raciocínio. (SILVA & MAIRINK, 2019)

2.5.1 *Machine learning* (ML)

Machine Learning (ML), ou aprendizado de máquina, é um ramo da IA capaz de automatizar e aprender a identificar padrões, sendo exposto várias vezes a um conjunto de dados robustos que possui exemplos de identificação. (ALPAYDIN, 2016)

O aprendizado de máquina pode ser dividido em supervisionado e não supervisionado. Considera-se supervisionado quando é feito a partir de um algoritmo chamado indutor, o qual possibilita adesão de exemplos não rotulados a uma classe, sendo que, para rótulos de classes discretas são chamados de classificação e valores contínuos, de regressão. Para o aprendizado não supervisionado, o indutor analisa exemplos e os agrupa para depois analisar e determinar os exemplos agrupados. (MONARD & BARANAUSKAS, 2003)

Os principais algoritmos de aprendizado supervisionada são: Regressão Linear, Regressão Logística, Redes Neurais Artificiais, Máquina de Vetor de Suporte, k-Vizinhos Mais Próximos, e *Naive Bayes*. Entretanto, no aprendizado não supervisionado, os principais algoritmos são: Agrupamento (*clusterização*) Hierárquico, Agrupamento de k-Médias, Agrupamento Difuso, Modelos de Mistura Gaussiana, Análise de Componentes Principais e Mapas de Kohonen. (THEOBALD, 2017)

2.5.2 Deep learning (DL)

Uma importante subárea do aprendizado de máquina é conhecida como *Deep Learning* (DL), ou aprendizado profundo. Nesta abordagem, as redes neurais artificiais, que têm a capacidade de organizar estruturas conhecidas como neurônios, de forma similar ao cérebro humano, são utilizadas para o reconhecimento e controle de padrões e percepções, de forma mais rápida. (HAYKIN, 2001)

As Redes Neurais são compostas por vários neurônios e neles estão contidos os pesos sinápticos onde está armazenado o conhecimento adquirido através do treinamento aplicado a eles. (HAYKIN, 2001)

Nesta última década, as ferramentas de *Deep Learning* têm causado uma verdadeira reviravolta na área de visão computacional. Alguns dos motivos principais para isso são: disponibilidade de bases de dados com milhares de imagens e de computadores capazes de reduzir o tempo para processar essas bases de dados. (PONTI & COSTA, 2017)

Dentre as técnicas de aprendizado profundo, as Redes Neurais Convolucionais, do inglês *Convolutional Neural Network* (CNN), demonstraram uma alta precisão comparando-se com outras técnicas existentes de processamento de imagem, sendo aplicadas para resolver diversos problemas de alta complexidade na agricultura como classificação e predição, de forma eficaz quando se dispõe de conjunto de dados de alta qualidade e quantidade para treinamento do modelo. (KAMILARIS & PRENAFETA-BOLDÚ, 2018)

Para o treinamento da rede neural, é necessário ter uma boa organização de dados já que suas aplicações incluem a construção de relações empíricas complexas para recuperar variáveis de culturas agrícolas, e de emuladores de modelos. Apesar de ser uma técnica para classificação e precisão de dados, a rede

neural é limitada pelo seu banco de dados, que deve ter variabilidade espacial e temporal. (WEISSA, et al., 2020; ZHANG, et al., 2018)

2.5.3 Aplicação de ML e DL na agricultura

A partir de um conjunto de dados agrícolas constituído por 20.000 imagens de plântulas do cultivar e ervas daninhas obtidas por um robô em campo, em diferentes estádios fenológicos e ângulos das fotos, com a utilização de processamento de imagens foi possível aplicar uma R-CNN para a detecção dos cultivares e das ervas daninhas chegando a uma ótima acurácia. (QUAN, et al., 2019; SHAH, et al., 2021)

Comparações de modelos de algoritmos de *Deep Learning* demonstraram uma maior velocidade e acurácia na aplicação de R-CNN para identificação de ervas daninhas em parcelas de plantas cultivadas. (ESPINOZA, et al., 2020)

Apesar da similaridade fenotípica uma CNN pode ser aplicada em imagens RGB possibilitando a distinção entre culturas cultivadas e ervas daninhas em um mesmo talhão, alcançando uma acurácia de 89,3%. (XU, et al., 2021)

Modelos computacionais oriundos de diferentes redes neurais, tais como Single Shot Detection (SSD), You Only Look Once (YOLO) e DL-CNN, apresentaram alta acurácia para distinguir ervas daninhas de culturas agrícolas, o que diminuiu a aplicação de herbicidas nocivos ao meio ambiente. (YU, et al., 2019)

O uso da plataforma YOLO, baseada em CNN, detectou e delimitou classes de plantio e ervas daninhas com alta acurácia permitindo a realização do controle de infestação, e evitando perdas significativas de produção e qualidade. (JIN, et al., 2022)

Uma CNN utilizando o método k-FLBPCM (Filtros de Padrões Binários Locais com máscaras de contorno e coeficiente k) quando aplicada a um grande banco de dados compostos por imagens de plantas com diferentes estádios fenológico, tamanho de folha e altura, diferenciaram ervas daninhas de culturas cultivadas atingindo uma acurácia de 99%. (LE, et al., 2020)

É possível detectar múltiplas espécies de ervas daninhas na agricultura com um conjunto de dados da plataforma da YOLO composta por uma CNN que possibilita o uso da aplicação em dispositivos portáteis de memória limitada. (CZYMMEK, et al., 2019)

Modelos alternativos de RCNN tem tornado mais precisa e rápida, a distinção de ervas daninhas pois consegue combinar múltiplos modelos treinados com Dropout. (SARKER & KIM, 2021)

Uma CNN pode ser aplicada para detectar ervas daninhas a partir de imagens obtidas “in loco” em ambientes controlados com cultura cultivada, distinguindo os diferentes tipos e obtendo uma acurácia de 99,44%, ou seja, muito próxima de uma avaliação real realizada por um especialista em campo. (ANUL HAQ, 2022)

A utilização de técnicas de *Machine e Deep Learning* como *Random Forest* e Redes Neurais Convolucionais, tem apresentado alta eficiência para a classificação de ervas daninhas por imagem, podendo assim ser utilizadas na agricultura de precisão. (JUNIOR & COVOLAN, 2018)

O reconhecimento de ervas daninhas e a distinção das mesmas com relação as culturas cultivadas utilizando CNN permitem alcançar até 99,37% de acurácia. (JIANG, et al., 2020)

Alguns modelos de redes neurais conseguem cumprir as exigências para a classificação de espécies de plantas daninhas mesmo com a ocorrência de variação da luminosidade, presença de nuvens e ângulo solar durante a obtenção das imagens, e atingir uma acurácia de 96,7%. (BURKS, et al., 2005).

Comparada com métodos tradicionais, a identificação de ervas daninhas realizada por CNN, através de um conjunto de imagens RGB obtidas por imageamento com RPA, apresentou uma alta acurácia (98,8%), viabilizando assim uma maior economia para os agricultores por utilizar equipamento de baixo custo e aumentar a precisão do controle de infestações. (LIANG, et al., 2019)

Técnicas de aprendizado de máquina aplicadas a um conjunto de dados oriundos do Sentinel-1 SAR, permitiu a detecção de padrões de cultivares (calendários e sistemas de cultivo), identificação de variedades precoces e tardias e elaboração de mapas de rotação de culturas. (USEYA & CHEN, 2019)

A erva daninha apresenta características específicas de cor, forma, textura e espectro as quais são identificadas em imagem de câmera fotográfica, podendo ser treinadas e reconhecidas por algoritmos de *Deep Learning*, apresentando uma ótima acurácia. (TANG, et al., 2017)

A R-CNN se adequa muito bem as tarefas de detectar e diferenciar ervas daninhas de culturas agrícolas obtendo alta acurácia em aplicações na agricultura de precisão. (MORA-FALLAS, et al., 2020)

A CNN aplicada a um banco de dados com amostras de imagens de alta qualidade, é capaz de extrair informações de cores e texturas permitindo classificar os diferentes níveis de qualidade fisiológica da cana-de-açúcar, apresentando uma alta acurácia. (PHAM & GOLDIN, 2019; DIANA PUTRI, et al., 2013)

Redes neurais aplicadas aos dados de sensoriamento remoto oriundos de imagens de satélite são capazes de estimar a evapotranspiração de referência (ET₀), a partir de modelos de decisão binária com funções de regressão linear (M5), em locais onde não há dados meteorológicos disponíveis. (RAHIMIKHOOB, 2016)

Para o reconhecimento das plantas daninhas em campo, deve-se atentar para a ocorrência de um padrão nas formações vegetativas diferente do padrão de plantio, sendo essas características promissoras para serem utilizadas no treinamento de CNN. (CAMARGO, et al., 2021).

Na agricultura de precisão, é necessário distinguir a cultura de plantio da erva daninha para aplicação dos herbicidas, com isso vem se tornando cada vez mais frequente a aplicação da inteligência artificial, a qual deve ser aplicada em um conjunto de dados com aproximadamente 7000 imagens para alcançar uma acurácia de 98%, melhorando a eficiência de aplicação e evitando o desperdício de herbicidas. (ALAM, et al., 2022)

2.5.4 Imagem de satélite e DL aplicados a agricultura de precisão

A aplicação de técnica de geo-parcelas em imagens multitemporais de média resolução forneceu um banco de dados para ser utilizado em aprendizado profundo, o que possibilitou a classificação do solo com alta precisão. (SUN, et al., 2020)

O sensoriamento remoto tem sido muito utilizado na agricultura dado sua vasta possibilidade de produção e análises de dados espaciais, para mapeamento de culturas, previsão de rendimento, entre outras, e atualmente, utilizando técnicas de *Deep Learning* para processamento em tempo real desses dados que são armazenados em nuvens. (WEISS, et al., 2020)

O uso do satélite PlanetScope possibilitou gerar um grande banco de dados de imagens com alta resolução, e através da aplicação de algoritmos de *Machine*

Learning e CNN, classificar áreas de queimadas, apresentando alta acurácia. (OLIVEIRA, 2019)

2.5.5 RPA aplicado a agricultura de precisão e DL

O reconhecimento das plantas daninhas em imagens de RPA é possível devido a sua apresentação em forma de manchas no campo, sendo, portanto, promissora a aplicação de CNNs para esse objetivo. (PETEINATOS, et al., 2020; CAMARGO, et al., 2021)

A identificação de Plantas daninhas em imagens RGB capturadas com RPAs através da criação de modelos específicos em algoritmos de RNA (Redes neurais artificiais), apresentaram uma boa precisão com índice Kappa variando entre 0,65 a 0,72. (YANO, 2018)

Sistemas de Sensoriamento Aerotransportado para obtenção de imagens multiespectrais, permitem a identificação de áreas com altos níveis de infestação de plantas daninhas através de algoritmos de RNA (redes neurais Artificiais), resultando em alto valor da exatidão global e do coeficiente Kappa. (SARTORI, et al., 2009)

Com o auxílio da CNN é possível distinguir as ervas daninhas da cultura cultivada com alta precisão, e, a partir do desenvolvimento de um sistema para aplicação de herbicidas utilizando equipamentos de pulverização acoplados a RPA, promover uma redução na quantidade de produtos químicos aplicados. (KHAN, et al., 2021)

3 MATERIAIS E MÉTODOS

3.1 LOCAL DE ESTUDO

A área de estudo está localizada na mesorregião Leste Alagoana, e abrange os municípios de Rio Largo e Satuba. Representa uma área de 2064,66 km² compreendida entre as coordenadas geográficas de Latitude -9.66625, Longitude -35.7351, a 9° 39' 59" Sul e 35° 44' 6" Oeste (Figura 1). O quadro geográfico desses municípios é dominado pelas culturas da cana-de-açúcar (tabuleiros costeiros e várzeas), do coco (tabuleiros costeiros, cordões litorâneos e paleofeixes de dunas deltaicas), e por vegetação litorânea (mangue, restinga, terraços fluviais). (CALHEIROS, et al., 2013)

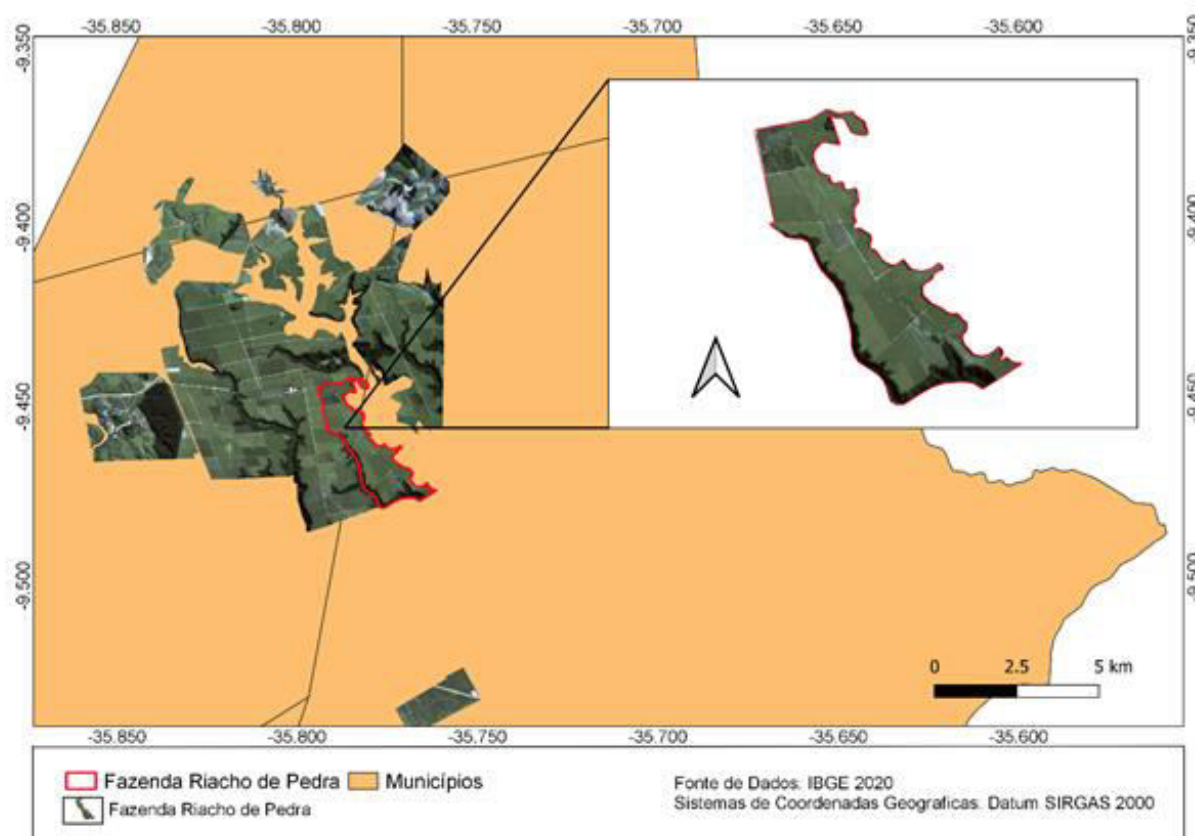


Figura 1. Mapa da Área de Estudo. Fonte: Autor, 2022

3.2 SOFTWARE E HARDWARE

Os algoritmos computacionais foram desenvolvidos utilizando a linguagem de programação *Python*. Para as implementações da CNN, utilizou-se as bibliotecas *Keras* e *TensorFlow*.

O conjunto de hardware e software aplicados neste trabalho para o desenvolvimento da CNN foram os seguintes:

a) Hardware:

- processador: Intel i5-8265U, 1.6 - 3.9 GHz;
- placa gráfica: NVIDIA Geforce MX130 com 2GB VRAM;
- memória RAM: 8 GB DDR4; e
- HD: 1 TB

b) Software:

- Google Earth Pro (7.1.8) - software gratuito;
- QGIS (versão 3.22.5) - software livre;
- LibreOffice (versão 6.4.3) - software livre;
- Python (versão 3.7.5) - software livre;
- OpenDroneMap (versão da API: 1.5.1 e versão de Engenharia: 0.9.8) - software livre;

3.3 DADOS E EQUIPAMENTOS GERAIS

Foram utilizados os seguintes dados digitais e equipamentos para a realização deste trabalho:

a) Dados digitais georreferenciados:

- Arquivos vetoriais (SHP) do IBGE – gratuitos;
- Arquivos vetoriais (KML) fornecidos pela Usina Santa Clotilde – gratuitos; e
- Arquivos matriciais (GEOTIFF) fornecidos pela PlanetScope – gratuito/convênio.

b) Equipamentos:

- RPA: modelo Phantom 4 Advanced – DJI.

3.4 METODOLOGIA

A metodologia seguiu as etapas descritas no fluxograma apresentado abaixo (Figura 2).

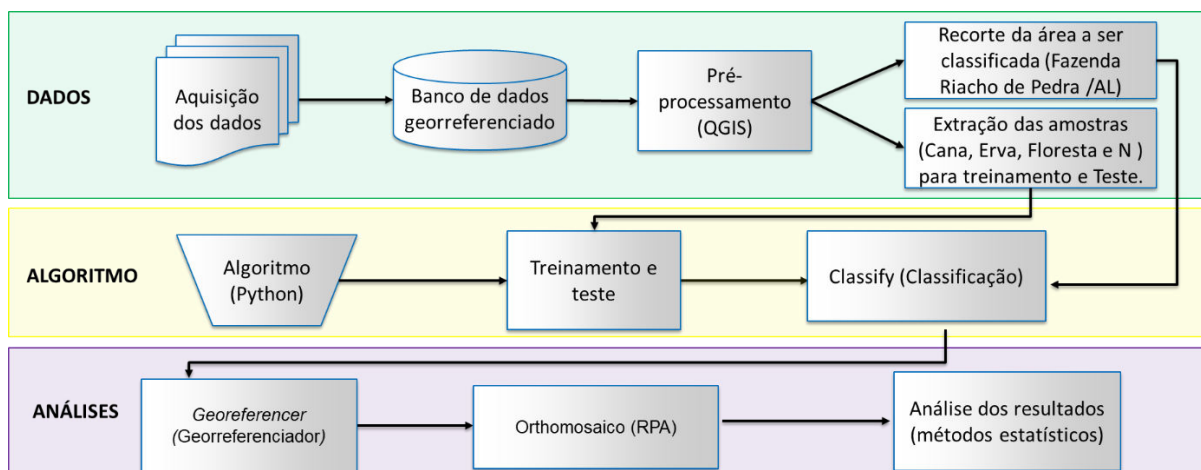


Figura 2 – Fluxograma com as etapas da metodologia. Autor, 2022.

3.4.1 Aquisição dos dados

Foram acessadas fontes de dados digitais, georreferenciados e disponibilizados gratuitamente via internet. Inicialmente foi realizada uma pesquisa para obtenção de arquivos vetoriais que representassem os limites oficiais dos municípios de Maceió e Rio Largo, dentro do estado de Alagoas. Para isso foi utilizado o Portal de Mapas do IBGE (IBGE, 2020), a partir do qual foi realizado o *download* do arquivo *al_municipios.zip*, contendo dados vetoriais (SHP) referentes a Malha municipal 2018 de Alagoas.

Os dados vetoriais produzidos pela usina Santa Clotilde com informações dos limites talhões e fazendas, foram fornecidos em formato Kml. Com o *software* Qgis, foi possível converter esses dados Kml para formato SHP, que é o formato padrão para a utilização deste software.

Foram obtidas imagens do satélite PlanetScope cobrindo a área de estudo, além de grande parte de toda a área plantada de cana utilizada pela usina. Essas imagens são disponibilizadas já ortorretificadas, compostas por quatro bandas multiespectrais e têm resolução espacial de 3 m. Para este trabalho, foram selecionadas cinco cenas que se sobrepõem cobrindo a área de estudo, sendo uma do dia 22/08/2020 e quatro do dia 28/06/2020, adquiridas de forma gratuita, por meio de um convênio entre o LANESA (Laboratório de Análises Espaciais e Ambientais) e a empresa através do programa de educação e pesquisa da plataforma Planet.

3.4.2 Criação dos bancos de dados georreferenciados

Foram criados, portanto, dois bancos de dados georreferenciados: 1) banco de dados vetoriais com arquivos *shapefiles*; e 2) banco de dados matriciais com arquivos *geotiff*.

3.4.3 Pré-processamento (QGIS)

Nesta etapa utilizou-se o *software* QGIS para criar o mosaico com as cenas do satélite PlanetScope, considerando a data de imageamento de 22/08/2020, através da ferramenta Miscelânea. A partir do mosaico utilizou-se a ferramenta recortar raster para separar duas áreas de plantio de cana, sendo uma para extrair amostras para treinamento e testes, e o outra para classificação, a partir da CNN. Para recortar a área classificada ou de estudo utilizou-se o arquivo vetorial fornecido pela usina Santa Clotilde. Com a mesma ferramenta de recorte de dados raster foram extraídas as amostras das classes de interesse (Cana-de-açúcar, Floresta, Erva daninha e não definido), a partir da imagem recortada para treinamento e teste (Figura 3). A classe não definido, foi utilizada para retirar a borda da imagem que não contempla a área de interesse para a aplicação da CNN.



Figura 3. Amostras coletadas a partir do mosaico das imagens PlanetScope. Autor 2022

3.4.4 Algoritmos

Dentro da linguagem de programação Python (versão 3.7.5), utilizou-se as seguintes ferramentas computacionais para desenvolvimento da CNN e do Georreferenciador:

a) CNN:

- bibliotecas de visão computacional: OpenCV, versão 4.1.0.25;
- funções e operações de cálculos numéricos para interação com sistema operacional: Numpy, versão 1.21.5;
- interpretador: Os e Sys, versão 1.9.3;
- padrão especificado: Glob, versão 0.7;

- processador de imagem:(Pillow, versão 9.1.0;
- criação de gráficos e visualização de dados: Matplotlib, versão 3.5.1;
- aprendizagem de máquina: Keras, versão 2.2.4, Scikit-learn versão 1.21.5 e Tensorflow, versão 1.14.

b) Georreferenciador:

- processamento de dados raster em ambiente SIG (Sistemas de Informações Geográficas): GDAL, versão 3.2.3;
- auxílio no processamento de dados raster, expressando o modelo de dados da biblioteca GDAL: Rasterio, versão1.2.10.

A partir das ferramentas supracitadas foram desenvolvidos os algoritmos de treinamento, classificação e georreferenciamento das imagens, baseados em técnicas de aprendizagem profunda de máquina. Além disso, também foi desenvolvido um script em Python para padronizar as amostras que serviram como entrada do algoritmo. Essa padronização permitiu dimensionar os pixels das imagens no tamanho 5x5, o que gerou um aumento no número das amostras apresentadas na figura 3. Ou seja, a partir da divisão de 11 amostras, com tamanhos irregulares, na proporção 5x5, foram criadas 17185 subamostras oriundas de uma imagem com resolução espacial de 3 m, e cada subamostra recobrindo uma área de 225m² (Figura 4). As subamostras foram separadas em 4 pastas de diferentes classes, o que possibilitou analisar as classes cana-de-açúcar com 3694 subamostras, Ervas Daninhas com 3318 subamostras, Floresta com 3393 subamostras e Não definida com 6780 subamostras (Tabela 1).

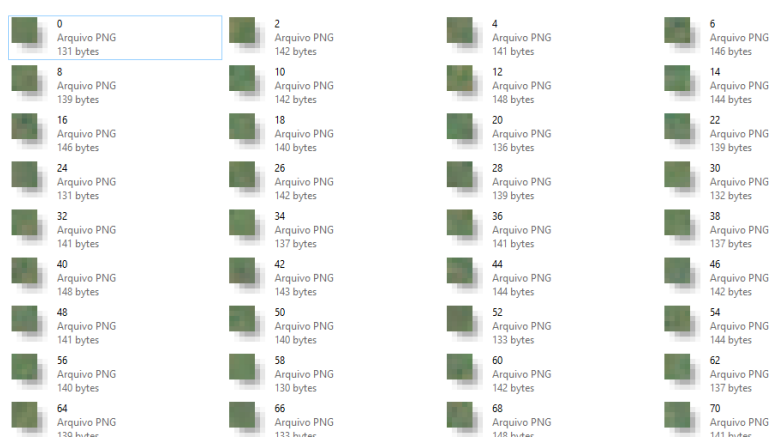


Figura 4 – Padronização de tamanho das amostras. Autor 2022.

Classes	Cana-de-açúcar	Ervas Daninhas	Floresta	Não definida	Total
Subamostras	3694	3318	3393	6780	17185

Tabela 1 – Conjunto de dados Brutos. Autor 2022.

3.4.5 Treinamento e teste

Em seguida, foram testados quatro cenários com diferentes tipos de parametrização para analisar o melhor resultado de acurácia do treinamento e teste da CNN (Tabela 2). Com relação aos tipos de parametrização dos cenários foram utilizados:

- quantidade de épocas: O cenário 1 foi o único que utilizou 50 épocas e os demais cenários, 30 épocas;
- parametrização padrão: O segundo foi o primeiro cenário original, ou seja, considerado padrão para ser comparado com as diferentes análises aplicadas nos outros cenários;
- quantidade de classes: O cenário 3 foi o único que utilizou três classes e os demais cenários, quatro classes;
- proporção das subamostras: O quarto cenário foi único que utilizou a proporção de 75% das subamostras para treinamento e 25% para teste, e os demais, 50% por 50%;
- quantidade de camadas de convolução: O quarto cenário foi único que utilizou quatro camadas de convolução, e os demais, uma; e
- tamanho da entrada: O quarto cenário foi único que utilizou tamanho de entrada 50x50, e os demais, 5x5.

Cada um dos cenários podem ser representados por uma arquitetura demonstrando a sequência de processamento realizado para treinamento e teste da CNN. Segue abaixo a arquitetura do quarto cenário (Figura 5)




Figura 5 – Arquitetura da CNN no cenário 4, Autor 2022

Parâmetro da CNN	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Classes	4	4	3	4
Conjunto de Dados	50% treino 50% teste	50% treino 50% teste	50% treino 50% teste	75% treino 25% teste
Camada de Entrada	1 neurônio imagem RGB 3 canais	1 neurônio imagem RGB 3 canais	1 neurônio imagem RGB 3 canais 5x5 color	1 neurônio imagem RGB 3 canais 50x50 color
Camada Convoluti- onal	5x5 color 32 neurônios Filtros conv. 3x3 Ativação ReLU	5x5 color 32 neurônios filtros conv. 3x3Ativação ReLU	32 neurônios filtros conv. 3x3 Ativação ReLU	32 neurônios filtros conv. 3x3 Ativação ReLU
Camada Pooling	-	-	-	2x2 64 neurônios filtros conv. 3x3 Ativação ReLU
Camada Convoluti- onal	-	-	-	2x2 128 neurônios filtros conv. 3x3 Ativação ReLU
Camada Pooling	-	-	-	2x2 64 neurônios filtros conv. 3x3Ativa- ção ReLU
Camada Convoluti- onal	-	-	-	2x2 40 neurônios
Camada Pooling	-	-	-	40 neurônios Ativação ReLU
Camada Flattening	40	40	40	40
Camada (MLP) Fully-Connected	40 neurônios Ativação ReLU	40 neurônios Ativação ReLU	40 neurônios Ativação ReLU	40 neurônios Ativação ReLU
Camada de Saída	4 neurônios Ativação Sigmoid	4 neurônios Ativação Sigmoid	3 neurônios Ativação Sigmoid	4 neurônios Ativação Sigmoid
Função de Perda	Categorical Cross Entropy	Categorical Cross Entropy	Categorical Cross Entropy	Categorical Cross Entropy
Otimizador	Adam	Adam	Adam	Adam
Medida de Avaliação	Accuracy	Accuracy	Accuracy	Accuracy
Épocas de Treinamento	50	30	30	30
Tamanho da Entrada	5	5	5	50

Tabela 2 – Parametrizações utilizadas nos cenários de aplicação da CNN. Autor, 2022

3.4.6 *Classify* (Classificação)

Foi feita a classificação, a partir do algoritmo *classify*, para o cenário que apresentou a melhor acurácia. O objetivo do uso deste algoritmo foi representar as subamostras de cada classe, identificadas e separadas, através da imagem resultante do treinamento feito pela CNN, sendo possível distinguir cada classe através de uma forma geométrica, similar a um mapa, com diferentes cores.

3.4.7 *Georeferencer* (Georreferenciador)

A forma geométrica oriunda da classificação não é georreferenciada, e portando, foi necessário desenvolver o algoritmo *georeferencer* (georreferenciador). Para georreferenciar a forma geométrica utilizou-se os parâmetros de coordenadas geográficas da imagem da área de estudo, a qual serviu como camada de entrada. Com a aplicação da biblioteca Rasterio, a forma geométrica passou por uma inversão das suas bandas e em seguida a imagem da área de estudo transferiu seus metadados à forma geométrica, criando assim um mapa matricial (Geotiff) georreferenciado, representando as classes identificadas.

3.4.8 Orthomosaico (RPA)

Para comprovar os resultados apresentados no mapa através da localização das classes avaliadas, foi feito o imageamento com a RPA de um talhão com alto grau de infestação por erva daninha, dentro da área de estudo. A seleção do talhão para imageamento teve a colaboração direta dos técnicos de campo da Usina Santa Clotilde. A resolução da câmera e altitude de voo do RPA possibilitou comprovar de fato uma alta infestação de plantas daninhas. O imageamento foi realizado a uma altitude de 100m, com sobreposição de fotos de 80x80, em um angulo de 90°, no horário de 11:00h, gerando um total de 213 fotos que recobriram uma área de 10 hectares.

No software WebODM foram realizados os seguintes processamentos digitais das fotos obtidas pela RPA:

- carregamento das fotos para uma pasta do servidor;
- envio das fotos para o nó de renderização;
- criação de nuvem de pontos;
- criação de nuvem de pontos densa;
- criação do Modelo Digital de Superfície (MDS); e

- geração do Orthomosaico.

3.4.9 Análise dos resultados (Métodos estatísticos)

O software LibreOffice foi utilizado para as seguintes análises estatísticas:

- coeficiente Kappa (equações 1 e 2); e
- cálculo de porcentagem dos valores de área (ha) para as classes cana-de-açúcar, erva daninha e floresta.

$$\hat{K} = \frac{\hat{p}_o - \hat{p}_e}{1 - \hat{p}_e}$$

(Equação 1)

Onde:

$$\hat{p}_o = \sum_{l=1}^N \frac{n_{ll}}{n}$$

$$\hat{p}_e = \sum_{l=1}^N \frac{n_{l*} * n_{*l}}{n^2}$$

(Equação 2)

Onde:

Po é a taxa de aceitação relativa

Pe é a taxa hipotética de aceitação

Quando a concordância é total entre os conjuntos de dados k = 10

O algoritmo de treinamento da CNN realizou duas análises estatísticas que geraram as seguintes informações:

- matriz confusão; e
- acurácia.

4 RESULTADOS E DISCUSSÃO

4.1 ANÁLISE DOS CENÁRIOS DE APLICAÇÃO DA CNN

No primeiro cenário, a CNN obteve uma acurácia de 98,3% (Figura 6). A matriz confusão indicou que para a classe cana-de-açúcar todas as 1847 subamostras foram classificadas corretamente e não houve confusão com as classes Ervas daninhas, Floresta e N. Para o treinamento da classe Erva daninha observou-se uma confusão de 251 subamostras com a classe cana-de-açúcar, 1408 subamostras foram classificadas corretamente e não houve confusão com as classes Floresta e N. No que se refere a classe floresta foram classificadas corretamente 1696 subamostras e houve confusão com a classe N para apenas uma subamostra, e não teve confusão com a cana-de-açúcar e com a Erva daninha. A Classe N teve todas as suas subamostras classificadas corretamente (Tabela 3).

Accuracy
0.9830960854092526

Figura 6 – Acurácia do treinamento do cenário 1, Autor 2022

Classes	Cana	Erva Daninha	Floresta	N
Cana	1847	0	0	0
Erva	251	1408	0	0
Floresta	0	0	1696	1
N	0	0	0	3390

Tabela 3 – Matriz Confusão cenário 1, Autor 2022

O ótimo resultado de acurácia obtido nesse cenário corrobora com os resultados obtidos por Quan, et al. (2019), Shah, et al. (2021), mesmo estes tendo utilizado um outro tipo de sensor e de CNN.

Este elevado valor de acurácia possibilita que o algoritmo seja utilizado no manejo de controle de ervas daninhas, diminuindo a frequência e quantidade de aplicação de herbicidas e, por consequência, a degradação do meio ambiente. (YU, et al., 2019). Além disso, esse tipo de controle evita perdas significativas de produtividade e qualidade agrícola. (JIN, et al., 2022)

O gráfico para analisar a precisão do treinamento da CNN apresentou variação dos valores de acurácia para a validação e treinamento da CNN. Observou-se um aumento dos valores de acurácia a partir da décima época, mantendo-se estável com valores entre 97% e 100%, e uma queda para 95% na época 40, voltando a se estabilizar a partir da época 43 (Gráfico 1).




Gráfico 1. Acurácia da CNN no cenário 1. Autor, 2022

O outro gráfico feito para analisar a validação da perda mostrou que a partir da época 10 os valores se mantiveram próximo de 0, sendo os melhores para o aprendizado da CNN, assim como, observou-se dois aumentos nos valores de perdas nas épocas 37 e 42 e voltou a se estabilizar a partir da época 43 (Gráfico 2).

Cabe ressaltar que a tendência da curva dos valores de acurácia é bastante similar a tendência da curva dos valores de perda, apresentados no gráfico 2, se diferenciando apenas pelo os valores do eixo y. Onde os valores do eixo y, representando a acurácia, tendem a se estabilizar próximos a 1 e os que representam a perda tendem a se estabilizar próximo a 0.




Gráfico 2. Perda do treinamento e da validação da CNN no cenário 1. Autor, 2022

No segundo cenário, a CNN obteve uma acurácia de 94,5% (Figura 9). A matriz confusão indicou que para a classe cana 1669 subamostras foram classificadas corretamente e houve confusão com a classe Ervas daninhas para 178 subamostras, não havendo confusão com as classes Floresta e N. Para o treinamento da classe Erva daninha observou-se uma confusão de 244 subamostras com a classe cana-de-açúcar, 1404 subamostras foram classificadas corretamente e não houve confusão com as classes Floresta e N. No que se refere a classe floresta foram classificadas corretamente 1660 subamostras e houve confusão com a classe N para 36 subamostras, e não teve confusão com as classes cana-de-açúcar e Erva daninha. A Classe N teve todas as suas subamostras classificadas corretamente (Tabela 4).

Accuracy
0.9454143389199255

Figura 9 – Acurácia do treinamento do cenário 2, Autor 2022

Classes	Cana	Erva	Floresta	N
Cana	1669	178	0	0
Erva	244	1404	0	0
Floresta	0	0	1660	36
N	0	0	0	3390

Tabela 4 – Matriz Confusão cenário 2. Autor 2022

O gráfico para analisar a precisão do treinamento da CNN apresentou grande variação nos valores de acurácia para a validação e treinamento da CNN. Observou-se um aumento dos valores de acurácia a partir da décima época, porém apresentou baixa estabilidade com picos de diminuição nas épocas 15 (92%) e 20 (93%), voltando a crescer até a época 30 (Gráfico 3).




Gráfico 3. Acurácia da CNN no cenário 2. Autor, 2022

O outro gráfico, para análise da validação dos valores de perda, mostrou que houve grande instabilidade entre as épocas 5 e 25, ocorrendo três picos de aumentos nas épocas 8, 12 e 22, voltando à estabilização, a partir da época 24 (Gráfico 4).




Gráfico 4. Perda do treinamento e da validação da CNN no cenário 2. Autor, 2022

No terceiro cenário, a CNN obteve uma acurácia de 93,8% (Figura 12). A matriz confusão indicou que 1773 subamostras da classe cana-de-açúcar foram identificadas corretamente, ocorrência de confusão com a classe Ervas daninhas para 74 subamostras, e não ocorrência de confusão com a classe N. Para o treinamento da classe Erva daninha observou-se uma confusão em 348 subamostras com a classe cana-de-açúcar, 1311 subamostras foram classificadas corretamente e não houve confusão com a classe N. A Classe N teve todas as suas subamostras classificadas corretamente (Tabela 5).

Accuracy

0.9388051044083526

Figura 12 – Acurácia do treinamento do cenário 3, Autor 2022

Classes	Cana	Erva	N
Cana	1773	74	0
Erva	348	1311	0
N	0	0	3390

Tabela 5 – Matriz Confusão cenário 3. Autor 2022

O gráfico para analisar a precisão do treinamento da CNN apresentou grande variação nos valores de acurácia para a validação e treinamento da CNN. Observou-se um aumento dos valores de acurácia a partir da sexta época, porém apresentou instabilidade com picos de diminuição nas épocas 18 (91%) e 23 (90%), voltando a aumentar os valores a partir da época 24 até a época 30 (Gráfico 5).




Gráfico 5. Acurácia da CNN no cenário 3. Autor, 2022

O outro gráfico, para análise da validação da perda, mostrou que houve grande instabilidade entre as épocas 5 e 23, sendo observados dois aumentos nos valores de perdas nas épocas 19 e 22, e voltando os valores de perda a se estabilizarem a partir da época 24 (Gráfico 6).




Gráfico 6. Perda do treinamento e da validação da CNN no cenário 3. Autor, 2022

No quarto cenário, a CNN obteve uma acurácia de 95,4% (Figura 15). A matriz confusão indicou que 875 subamostras da classe cana-de-açúcar foram identificadas corretamente, houve confusão com a classe Ervas daninhas para 48 subamostras, não havendo confusão para as classes Florestas e N. Para o treinamento da classe Erva daninha observou-se uma confusão em 144 subamostras com a classe cana-de-açúcar, 685 subamostras foram classificadas corretamente e não houve confusão com as classes Floresta e N. No que se refere a classe floresta foram classificadas corretamente 841 subamostras, havendo confusão com a classe N em 36 subamostras, e não houve confusão com as classes cana-de-açúcar e Erva daninha. A Classe N teve todas as suas subamostras classificadas corretamente (Tabela 6).

Accuracy
0.9536670547147846

Figura 15 – Acurácia do treinamento do cenário 4, Autor 2022

Classes	Cana	Erva	Floresta	N
Cana	875	48	0	0
Erva	144	685	0	0
Floresta	0	0	841	36
N	0	0	0	1695

Tabela 6 – Matriz Confusão cenário 4. Autor, 2022

O gráfico para analisar a precisão do treinamento da CNN apresentou grande variação nos valores de acurácia para a validação e treinamento da CNN. Observou-se um aumento dos valores de acurácia a partir da quinta época, porém apresentou instabilidade nos valores até a época 30, com picos de diminuição nas épocas 12 (93%), 18 (93,5%), 22 (91%) e 25 (93%) (Gráfico 7).




Gráfico 7. Acurácia da CNN no cenário 4. Autor, 2022

O outro gráfico feito para analisar a validação da perda mostrou que houve grande instabilidade entre as épocas 5 e 25, sendo observados vários aumentos nos valores de perdas, tendo como os mais representativos aqueles situados nas épocas 5, 12, 16, 20, 23, 25, e voltaram a se estabilizar a partir da época 26 (Gráfico 8).




Gráfico 8. Perda do treinamento e da validação da CNN no cenário 4. Autor, 2022

4.2 COMPARAÇÃO ENTRE ACURÁCIA DA CNN E COEFICIENTE KAPPA

Comparando os dados da acurácia e o coeficiente Kappa, o maior valor de discrepância (3,5%) entre eles foi observado no cenário 3, onde a acurácia apresentou um valor de 93,8% e o índice Kappa de 90,3%. Os melhores valores tanto para Acurácia como para o coeficiente Kappa ocorreram no cenário 1, tendo uma valor de discrepâncias de 1,4% (Tabela 7).

Na tabela 7 foi possível observar que em todos os cenários analisados, os valores de acurácia do algoritmo da CNN foram superiores aos do coeficiente Kappa. No entanto, segundo Landis e Koch (1977) que classificaram os diferentes níveis de concordância (ou reprodutibilidade) para o coeficiente Kappa, os valores entre 81% e 100% são considerados como tendo uma concordância perfeita.

Cenários	Acurácia da CNN	Coeficiente Kappa	Discrepância
1	98,3%	96,9%	1,4%
2	94,5%	92,4%	2,1%
3	93,8%	90,3%	3,5%
4	95,3%	93,1%	2,2%

Tabela 7 – Acurácia da CNN e coeficiente Kappa da matriz de confusão, Autor, 2022

Portanto, os valores de coeficiente Kappa obtidos utilizando a CNN atingiram níveis compatíveis, e até superiores, com resultados obtidos por algoritmos de RNA (Redes neurais artificiais), desenvolvidos por Yano (2018) e Sartori, et al. (2009).

4.3 REPRESENTAÇÃO VISUAL E GEORREFERENCIAMENTO

Utilizou-se o algoritmo *classify*, para gerar a representação visual em formato geométrico das classes identificadas durante a aplicação do algoritmo da CNN para treinamento e teste das subamostras. A forma geométrica resultante teve a classe N retirada para uma melhor visualização dos limites das classes cana-de-açúcar (verde claro), Erva Daninha (Vermelha) e Floresta (Verde escuro). Em seguida, utilizou-se o algoritmo *georeferencer* para georreferenciar a forma geométrica transformando-a em mapa (Figura 18).

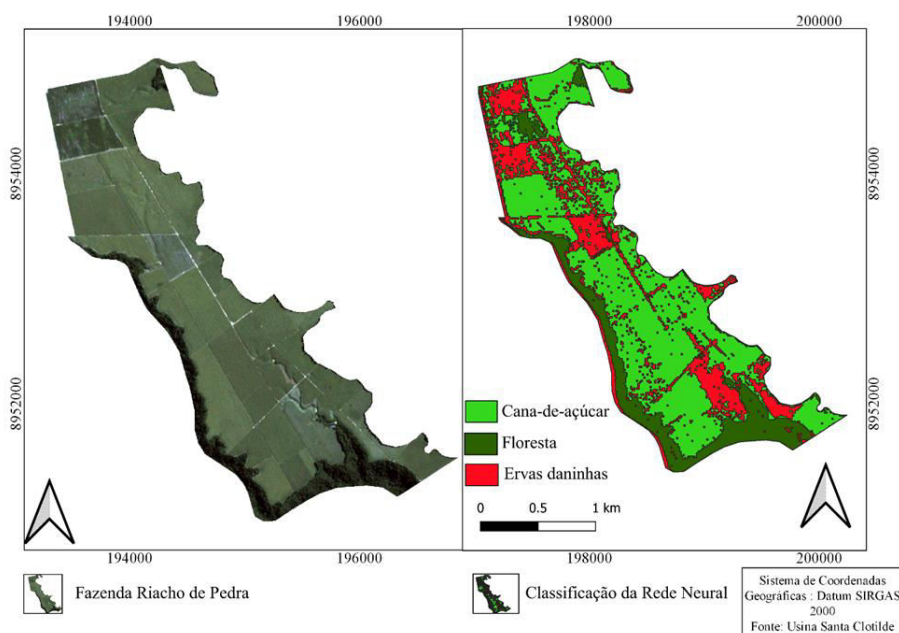


Figura 18 - Classificação representativa da Rede. Autor, 2022

4.4 COMPROVAÇÃO DE PRESENÇA DE ERVA DANINHA COM ORTHOMOSAICO

A partir do orthomosaico das fotos obtidas por RPA, comprovou-se a infestação por erva daninha no talhão de plantio de cana-de-açúcar (Figura 19). Durante o

trabalho de campo para imageamento por RPA foi possível classificar a espécie de erva daninha, *Momordica charantia* L, primordialmente presente no talhão imageado.

Na mesma figura 19, pode-se observar um dos talhões totalmente infestado por ervas daninhas. Trata-se de um talhão que será utilizado para renovação, ou seja, quando é feito o primeiro plantio do colmo da cana-de-açúcar, a colheita desse talhão atinge altas produtividades, porém com o decorrer do uso de rebrotas desse mesmo colmo durante as safras, a planta vai perdendo o seu vigor, ocasionando assim falhas no talhão e necessitando de uma renovação de plantio com colmos mais vigorosos.

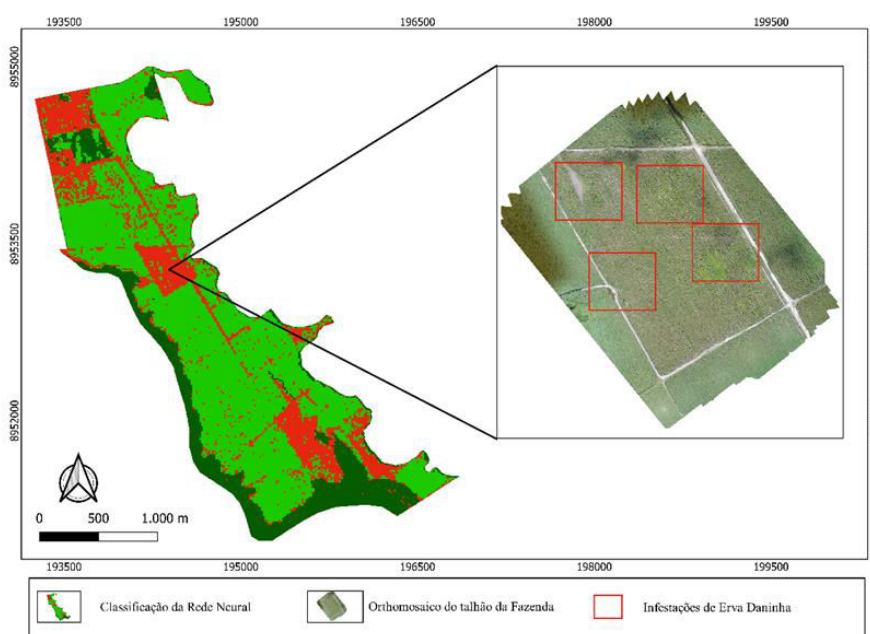


Figura 19 - Orthomosaico do talhão com infestação de erva daninha. Autor, 2022

4.5 CÁLCULO DE ÁREA DAS CLASSES

A partir do mapa foi possível realizar a quantificação de áreas (ha) para cada classe de uso do solo dentro da Fazenda Riacho de Pedra, chegando-se aos seguintes valores: 272,5 ha para Cana, 97,8 ha para Erva Daninha e Floresta 80,6 ha. Detectou-se uma infestação por erva daninha equivalente a 21,7% da área total analisada, a qual deveria estar coberta por cana de açúcar (Tabela 8 e Gráfico 9).

Classificação	Área (ha)	(%)
Cana	272,5	60,4
Erva Daninha	97,8	21,7
Floresta	80,6	17,9
Total	450,9	

Tabela 8. Dados de área e porcentagem. Autor, 2022.

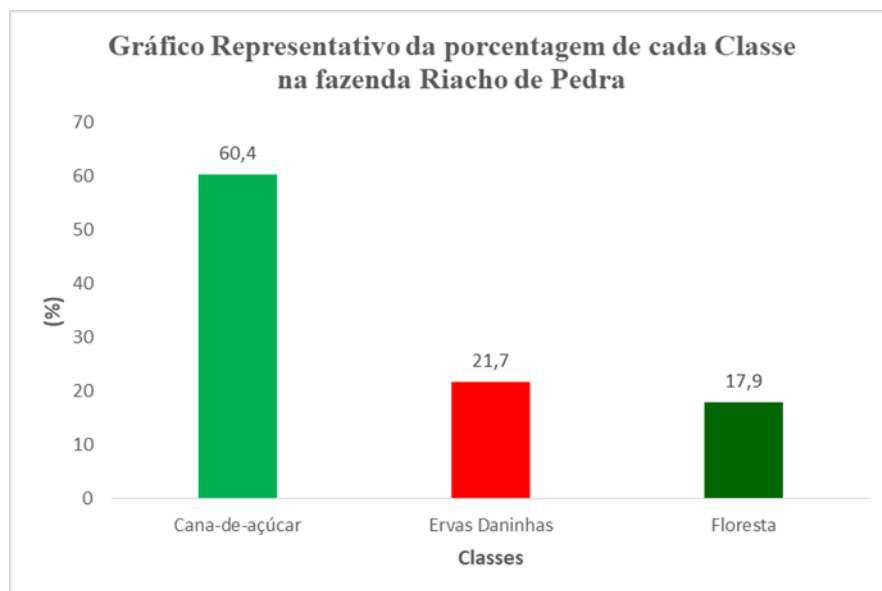


Gráfico 9 - Gráfico Representativo da porcentagem de cada Classe na fazenda Riacho de Pedra.

Autor, 2022

5 CONCLUSÃO

O algoritmo da CNN apresentou uma alta acurácia quando aplicado à imagens de média resolução (Satélite PlanetScope), ao identificar e analisar infestação de ervas daninhas em áreas de plantio de cana-de-açúcar.

Ao comparar diferentes cenários de aplicação do algoritmo de CNN, observou-se que o primeiro cenário teve maior destaque com um valor de acurácia de 98,3%. Ou seja, o algoritmo conseguiu atingir um alto nível de aprendizado e acertos na identificação de ervas daninhas a partir de uma imagem PlanetScope.

Com relação as comparações dos resultados obtidos para os parâmetros acurácia e coeficiente Kappa, dos algoritmos analisados, observou-se que os valores de acurácia da CNN apresentou melhores resultados que os valores do coeficiente Kappa. Sem, no entanto, descartar os resultados obtidos pelo coeficiente Kappa os quais atingiram uma concordância perfeita para todos os cenários.

Na análise quantitativa de área infestada por Erva daninha, conclui-se que há grande probabilidade de impacto negativo na produtividade de cana-de-açúcar da Fazenda Riacho de Pedra, já que em um área plantada de 450,9 ha, 21,7% desta área está infestada.

O imageamento por RPA, assim como a indicação da Fazenda Riacho da Pedra pelos técnicos da Usina, foi altamente assertivo na comprovação da infestação por erva daninha, previamente detectada pelo algoritmo da CNN. A diferenciação e reconhecimento da espécie (*Momordica charantia* L.) se deu localmente durante visita em campo ao mesmo tempo em que foi realizado o imageamento com o RPA.

5.1 TRABALHOS FUTUROS

Para trabalhos futuros, recomenda-se a adequação do algoritmo de CNN para aplicação em imagens oriundas de RPA visando a diferenciação entre as espécies de ervas daninhas localizadas em áreas de pequenos, médios e grandes produtores de cana-de-açúcar.

Da mesma forma, recomenda-se a aplicação deste mesmo algoritmo de CNN para detecção e localização de infestações por Erva daninha dentro de áreas de plantio com outras culturas como milho, soja, algodão, palma, coco, pastagem, entre outros de alta relevância para o estado de Alagoas.

REFERÊNCIAS

- ALAM, M. S.; ALAM, M.; TUFAIL, M.; et al. TobSet: A New Tobacco Crop and Weeds Image Dataset and Its Utilization for Vision-Based Spraying by Agricultural Robots. **Applied Sciences**, v. 12, n. 3, p. 1308, 2022. Disponível em: <<https://www.mdpi.com/2076-3417/12/3/1308>>. Acesso em: 4 abr. 2022.
- ANDRADE, M. C. Usinas e destilarias das Alagoas: uma contribuição ao estudo da produção do espaço. 2. Ed. Maceió: **EDUFAL**, 2010. 2v. 140p.
- ANUL HAQ, M. CNN Based Automated Weed Detection System Using UAV Imagery. **Computer Systems Science and Engineering**, v. 42, n. 2, p. 837–849, 2022.
- BAPTISTA, G. **Fundamentos de Sensoriamento Remoto**. [s.l.]: figshare, 2021. Disponível em: <https://figshare.com/articles/book/Fundamentos_de_Sensoriamento_Remoto/15087123>. Acesso em: 10 abr. 2022.
- BORDONAL, R. O.; CARVALHO, J. L. N.; LAL, R.; et al. Sustainability of sugarcane production in Brazil. A review. **Agronomy for Sustainable Development**, v. 38, n. 2, p. 13, 2018. Disponível em: <<http://link.springer.com/10.1007/s13593-018-0490-x>>. Acesso em: 7 abr. 2022.
- BURKS, T.F.; SHEARER, S.A.; HEATH, J.R.; DONOHUE, K.D. Evaluation of Neural-network Classifiers for Weed Species Discrimination. **BiosystemsEngineering**, [S.L.], v. 91, n. 3, p. 293-304, jul. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.biosystemseng.2004.12.012>.
- Calheiros, S. Q., Silva, P. R.; Neto, J. V. Identificação de conflitos espaciais do uso e ocupação do solo no litoral sul meridional de Alagoas - Brasil. **Revista da Casa da Geografia de Sobral (RCGS)**, V. 15(n. 2), p. 12 – 31,2013.
- CAMARGO, T.; SCHIRRMANN, M.; LANDWEHR, N.; DAMMER, K.-H.; PFLANZ, M. Optimized Deep Learning Model as a Basis for Fast UAV Mapping of Weed Species in Winter Wheat Crops. **Remote Sensing**, [S.L.], v. 13, n. 9, p. 1704, 28 abr. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13091704>.
- CONAB. **Acompanhamento da Safra Brasileira – Cana-de-açúcar**. v. 6 - Safra 2020/21, n. 4 - Quarto levantamento, Brasília, p. 1-58, agosto de 2020.
- COX, G.; HARRIS, H.; COX, D. Application of Precision Agriculture to Sugar Cane. In: ROBERT, P.C.; RUST, R.H.; LARSON, W.E. (Orgs.). **ASA, CSSA, and SSSA Books**. Madison, WI, USA: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, 2015, p. 753–765. Disponível em: <<http://doi.wiley.com/10.2134/1999.precisionagproc4.c72>>. Acesso em: 2 abr. 2022.
- CZYMMEK, V.; HARDERS, L. O.; KNOLL, F. J.; et al. Vision-Based Deep Learning Approach for Real-Time Detection of Weeds in Organic Farming. In: **2019 IEEE International Instrumentation and Measurement Technology Conference**

(I2MTC). Auckland, New Zealand: IEEE, 2019, p. 1–5. Disponível em: <<https://ieeexplore.ieee.org/document/8826921/>>. Acesso em: 4 abr. 2022.

DA SILVA, P. F. P. **Desenvolvimento de um plugin em ambiente SIG open source (QGIS) para obter parâmetros e métricas de copas de árvores, através de imagens adquiridas por VANTs**. 2017.

DEL-CAMPO-SANCHEZ, A.; BALLESTEROS, R.; HERNANDEZ-LOPEZ, D.; et al. Quantifying the effect of *Jacobiasca lybica* pest on vineyards with UAVs by combining geometric and computer vision techniques. **PLOS ONE**, v. 14, n. 4, p. e0215521, 2019.

DIANA PUTRI, A. R.; LITASARI; SUSANTO, A. Comparison between colour models in automatic identification of cane sugar. In: **2013 IEEE International Conference on Computational Intelligence and Cybernetics (CYBERNETICSCOM)**. Yogyakarta, Indonesia: IEEE, 2013, p. 146–150. Disponível em: <<http://ieeexplore.ieee.org/document/6865799/>>. Acesso em: 7 abr. 2022.

DOERGE, T.A. Management zone concepts. **Site-specific management guidelines**. 1999. p.4. Disponível na Internet. http://www.farmresearch.com/SSMG/ssmg-02/SSMG_02.pdf em 04 Dez. 1999.

DRIEMEIER, C.; LING, L. Y.; SANCHES, G. M.; et al. A computational environment to support research in sugarcane agriculture. **Computers and Electronics in Agriculture**, v. 130, p. 13–19, 2016. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0168169916308560>>. Acesso em: 7 abr. 2022

ESPINOZA, M.; LE, C. Z.; RAHEJA, A.; et al. Weed identification and removal using machine learning techniques and unmanned ground vehicles. In: THOMASSON, J. A.; TORRES-RUA, A. F. (Orgs.). **Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping V**. Online Only, United States: SPIE, 2020, p. 20. Disponível em: <<https://www.spiedigitallibrary.org/conference-proceedings-of-spie/11414/2557625/Weed-identification-and-removal-using-machine-learning-techniques-and-unmanned/10.1117/12.2557625.full>>. Acesso em: 4 abr. 2022.

FERREIRA, R.V.; CONTATO, E.D.; KUVA, M.A.; et al. Organização das comunidades infestantes de plantas daninhas na cultura da cana-de-açúcar em agrupamentos-padrão. **Planta Daninha**, v. 29, n. 2, p. 363–371, 2011.

GARCIA, B. O.; MOLINARI, H. B. C. PACHECO, T. F.; KOBAYASHI, A. K.; BARBOSA, G. V. S.; PAIVA, L. V.; GUIDUCCI, R. C. N. Análise do potencial econômico de variedade de cana geneticamente modificada para produção de açúcar. In: **EMBRAPA AGROENERGIA-ARTIGO EM ANAIS DE CONGRESSO (ALICE)**, 6., 2020, Brasília. Anais [...] . Df: Embrapa, 2020. v. 6, p. 1-8.

GOMES, D. dos S. Inteligência Artificial: conceitos e aplicações. **Olhar Científico**. v1, n. 2, p. 234-246, 2010.

GONÇALVES, M. C. V. O. AGRONEGÓCIO E A MECANIZAÇÃO DO TRABALHO NO CAMPO: ENTRE LUCRO, PRECARIZAÇÃO E EXCLUSÃO. **VIII jornada internacional políticas públicas**, São Luiz, p. 1-12, 22 ago. 2017. Disponível em: <http://www.joinpp.ufma.br/jornadas/joinpp2017/pdfs/eixo10/oagronegocioeamecanizacaodotrabalhonocampoentrelucroprecarizacaoeexclusao.pdf>. Acesso em: 04 Abril. 2020.

GUALAZZI, G. A. S., FONTES, M. DE B., MAGALHÃES, J. H., DE PAULA, J. V., MOLINA, M. O. E. & DOS SANTOS, G. R. RPAs Armadas: **O Desafio Brasileiro. XV Congresso Acadêmico sobre Defesa Nacional**. Distrito Federal: Ministério da Defesa, 2018.

HAYKIN, S. Redes neurais: princípios e prática. **Bookman Editora**, 2001.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Portal de Mapas do IBGE**. Disponível em: <https://portaldemapas.ibge.gov.br/portal.php#mapa222130>. Acesso em: 20 Abril. 2020.

ISLAM, F.; WANG, J.; FAROOQ, M. A.; et al. Potential impact of the herbicide 2,4-dichlorophenoxyacetic acid on human and ecosystems. **Environment International**, v. 111, p. 332–351, 2018. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0160412017315313>>. Acesso em: 7 abr. 2022.

JAMIL, M., AHMED, R.; SAJJAD, H. Land suitability assessment for sugarcane cultivation in Bijnor district, India using geographic information system and fuzzy analytical hierarchy process. **GeoJournal** 83, 595–611. 2018.

JIANG, H.; ZHANG, C.; QIAO, Y.; et al. CNN feature based graph convolutional network for weed and crop recognition in smart farming. **Computers and Electronics in Agriculture**, v. 174, p. 105450, 2020.

JIN, X.; SUN, Y.; CHE, J.; et al. A novel deep learning- based method for detection of weeds in vegetables. *Pest Management Science*, p. ps.6804, 2022. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1002/ps.6804>>. Acesso em: 4 abr. 2022.

JUNIOR, L. C. M.; COVOLAN, J. A. U. Aplicação de redes neurais profundas para detecção e classificação de plantas daninhas e seu estado da arte. **REGRAD**, P v. 11, n. 1, p. 13, 2018.

LANDIS, J. R.; KOCH, G. G. An application of hierarchical Kappa-type statistics in the assessment of majority agreement among multiple observers. **Biometrics**, p. 363-374, 1977.

LE, V. N. T.; AHDEROM, S.; ALAMEH, K.. Performances of the LBP Based Algorithm over CNN Models for Detecting Crops and Weeds with Similar Morphologies. **Sensors**, v. 20, n. 8, p. 2193, 2020. Disponível em: <<https://www.mdpi.com/1424-8220/20/8/2193>>. Acesso em: 4 abr. 2022.

LIANG, W.-C.; YANG, Y.-J.; CHAO, C.-M. Low-Cost Weed Identification System Using Drones. In: **2019 Seventh International Symposium on Computing and Networking Workshops (CANDARW)**. Nagasaki, Japan: IEEE, 2019, p. 260–263. Disponível em: <<https://ieeexplore.ieee.org/document/8951624/>>. Acesso em: 4 abr. 2022.

LIMA, D. C. **Métodos para estimativa de imagens nir a partir de imagens de câmeras rgb**. 2020. 126 f. Tese (Doutorado) - Curso de Ciência da Computação, Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos,, Universidade Federal de São Carlos, São Carlos, 2020. Cap. 5.

LOFTON, J.; TUBANA, B. S.; KANKE, Y.; et al. Estimating Sugarcane Yield Potential Using an In-Season Determination of Normalized Difference Vegetative Index. **Sensors**, v. 12, n. 6, p. 7529–7547, 2012.

KHAN, S.; TUFAIL, M.; KHAN, M. T.; et al. Deep learning-based identification system of weeds and crops in strawberry and pea fields for a precision agriculture sprayer. **Precision Agriculture**, v. 22, n. 6, p. 1711–1727, 2021. Disponível em: <<https://link.springer.com/10.1007/s11119-021-09808-9>>. Acesso em: 4 abr. 2022.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. A review of the use of convolutional neural networks in agriculture. **The Journal of Agricultural Science**, v. 156, n. 3, p. 312–322, 2018.

MACEDO, R. C.; ALMEIDA, C. M.; SANTOS, J. R. AND RUDORFF, B. F. T. Modelagem dinâmica espacial das alterações de cobertura e uso da terra relacionadas à expansão canavieira. **Boletim de Ciências Geodésicas**. vol.19, n.2, pp.313-337. 2013.

MENESES, P. R.; ALMEIDA, T. de; et al. **Introdução ao processamento de imagens de sensoriamento remoto**. Universidade de Brasília, Brasília, 2012.

MOMIN, M. A.; GRIFT, T. E.; VALENTE, D. S.; et al. Sugarcane yield mapping based on vehicle tracking. **Precision Agriculture**, v. 20, n. 5, p. 896–910, 2019. Disponível em: <<http://link.springer.com/10.1007/s11119-018-9621-2>>. Acesso em: 7 abr. 2022.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, v. 1, n. 1, p. 32, 2003

MORA-FALLAS, A.; GOËAU, H.; JOLY, A.; BONNET, P.; MATA-MONTERO, E. Segmentación de instancias para detección automática de malezas y cultivos en campos de cultivo. **Revista Tecnología en Marcha**, [S. l.], v. 33, n. 5, p. Pág. 13–17, 2020. DOI: 10.18845/tm.v33i5.5069. Disponível em: https://revistas.tec.ac.cr/index.php/tec_marcha/article/view/5069. Acesso em: 4 abr. 2022.

MORO, M. F.; SOUZA, V. C.; OLIVEIRA-FILHO, A. T.; et al. Alienígenas na sala: o que fazer com espécies exóticas em trabalhos de taxonomia, florística e fitossociologia? **Acta Botanica Brasilica**, v. 26, n. 4, p. 991–999, 2012.

NORVIG, P.; RUSSELL, S. **Inteligência artificial**. Tradução: Regina Célia Simille de Macedo. Consultoria Editorial e Revisão técnica: Dr. Flávio Soares Corrêa da Silva, Dra. Leliane Nunes de Barros and Dra. Renata Wassermann, v. 3, p. 13-31, 2013.

OLIVEIRA, P. D. S. **Uso de aprendizagem de máquina e redes neurais convolucionais profundas para a classificação de áreas queimadas em imagens de alta resolução espacial**. 2019. 34 f. Dissertação (Mestrado) - Curso de Geografia, Departamento de Geografia da Universidade de Brasília, Universidade de Brasília, Brasília, 2019.

ORÉ, G.; ALCÂNTARA, M. S.; GÓES, J. A.; et al. Crop Growth Monitoring with Drone-Borne DInSAR. **Remote Sensing**, v. 12, n. 4, p. 615, 2020.

PALANISWAMI, C.; GOPALASUNDARAM, P.; BHASKARAN, A. Application of GPS and GIS in Sugarcane Agriculture. **Sugar Tech**, v. 13, n. 4, p. 360–365, 2011.

PHAM, P.; GOLDIN, S. E. Sugar Cane Grading from Photos Using Convolutional Neural Networks. In: **2019 4th International Conference on Information Technology (InCIT)**. Bangkok, Thailand: IEEE, 2019, p. 18–21. Disponível em: <<https://ieeexplore.ieee.org/document/8911950/>>. Acesso em: 7 abr. 2022.

PITELLI, R. A. Competição e controle das plantas daninhas em áreas agrícolas. p. 15, v4.12, **Série técnica IPEF**, 1987.

PITELLI, R. A. O termo planta-daninha. **Planta Daninha**, v. 33, n. 3, p. 622–623, 2015. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S010083582015000300622&lng=pt&tlng=pt>. Acesso em: 9 abr. 2022

PLANET LABS. Planet Imagery Product Specification. n. October, p. 56, 2019.

POSTAL, A. M.; KAMALI, F. P.; ASVELD, L.; et al. The impact of sugarcane expansion in Brazil: Local stakeholders' perceptions. **Journal of Rural Studies**, v. 73, p. 147–162, 2020.

PRUDKIN, G.; BREUNIG, M. F. **Drones e ciência - Teoria e aplicações metodológicas**. Santa Maria, RS: FACOS-UFMS, 2019. 126p.

QUAN, L.; FENG, H.; LV, Y.; et al. Maize seedling detection under different growth stages and complex field environments based on an improved Faster R-CNN. **Bio-systems Engineering**, v. 184, p. 1–23, 2019.

RAHMAN, E. M. **The potential for using remote sensing to quantify stress in and predict yield of sugarcane (*Saccharum spp. hybrid*)**. thesis (Doctor of Philosophy in Environmental Sciences) - Faculty of Science and Agriculture, Pietermaritzburg 2010.

RAHIMIKHOOB, A. Comparison of M5 Model Tree and Artificial Neural Network's Methodologies in Modelling Daily Reference Evapotranspiration from NOAA Satellite Images. **Water Resources Management**, v. 30, n. 9, p. 3063–3075, 2016.

RAO, N. R, Development of a crop- specific spectral library and discrimination of various agricultural crop varieties using hyperspectral imagery, **International Journal of Remote Sensing**, v. 29, n. 1, p. 131–144, 2008.

REETZ, H. F.Jr.; FIXEN, P. E. Strategic approach to site-specific systems. **Site-specific management guidelines**. 1999. Disponível na Internet. [http://www.farmresearch.com/SSMG/ssmg-28/SSMG 28.pdf](http://www.farmresearch.com/SSMG/ssmg-28/SSMG%2028.pdf) em 04 Dez. 1999

SUN, Y.; LUO, J.; XIA, L.; et al. Geo-parcel-based crop classification in very-high-resolution images via hierarchical perception. **International Journal of Remote Sensing**, v. 41, n. 4, p. 1603–1624, 2020.

SANTOS, M. L.; LIMA, O. J.; NASSAR, E. J.; et al. Estudo das condições de estocagem do bagaço de cana-de-açúcar por análise térmica. **Química Nova**, v. 34, n. 3, p. 507–511, 2011.

SANTOS, S. S. **O cultivo da cana-de-açúcar no estado de Alagoas: uma análise comparativa dos efeitos da mecanização no estado de São Paulo**. 2011. 94 f. Dissertação (Mestrado) - Curso de Desenvolvimento Sustentável, Centro de Desenvolvimento Sustentável, Universidade de Brasília, Brasília, 2011. Cap. 3.

SARKER, M. I.; KIM, H. Farm land weed detection with region-based deep convolutional neural networks. **arXiv preprint arXiv:1906.01885**, 2019.

SARTORI, L. R.; GALO, M. L. B. T.; IMAI, N. N. Mapeamento de plantas daninhas em cultura de café a partir de imagens multiespectrais de escalas grandes usando redes neurais artificiais. **Revista Brasileira de Cartografia**, n. 61, p. 11, 2009.

SECRETARIA DE ESTADO DO PLANEJAMENTO, GESTÃO E PATRIMÔNIO/AL. **Alagoas em Dados e Informações**. 2020. <http://dados.al.gov.br>. Acesso em: 09 de Abril de 2022.

SILVA, G. S.; SILVA, A. F. M.; GIRALDELI, A. L.; et al. Manejo de plantas daninhas no sistema de mudas pré-brotadas de cana-de-açúcar. **Revista Brasileira de Herbicidas**, v. 17, n. 1, p. 86, 2018.

SILVA, J. A. S. DA; MAIRINK, C. H. P. Inteligência artificial. **LIBERTAS: Revista de Ciências Sociais Aplicadas**, v. 9, n. 2, p. 64-85, 13 dez. 2019.

SHAH, T. M.; NASIKA, D. P. B.; OTTERPOHL, R. Plant and Weed Identifier Robot as an Agroecological Tool Using Artificial Neural Networks for Image Identification. **Agriculture**, v. 11, n. 3, p. 222, 2021.

SHENDRYK, Y.; SOFONIA, J.; GARRARD, R.; RIST, Y.; SKOCAJ, D.; THORBURN, P. Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using UAV LiDAR and multispectral imaging. **International Journal Of Applied Earth Observation And Geoinformation**, [S.L.], v. 92, p. 1-14, out. 2020. Elsevier BV. <https://doi.org/10.1016/j.jag.2020.102177>

SHIRATSUCHI, L.S.; MOLIN, J.P.; CHRISTOFFOLETI, P.J. Mapeamento da distribuição espacial da infestação de *Panicum maximum* durante a colheita da cultura de milho. **Planta Daninha**, v. 22, n. 2, p. 269–274, 2004.

SOFONIA, J.; SHENDRYK, Y.; PHINN, S.; et al. Monitoring sugarcane growth response to varying nitrogen application rates: A comparison of UAV SLAM LiDAR and photogrammetry. **International Journal of Applied Earth Observation and Geoinformation**, v. 82, p. 101878, 2019.

TANG, J.; WANG, D.; ZHANG, Z.; HE, L.; XIN, J.; XU, Y. Weed identification based on K-means feature learning combined with convolutional neural network. **Computers And Electronics In Agriculture**, [S.L.], v. 135, p. 63-70, abr. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2017.01.001>.

TANUT, B.; WARANUSAST, R.; RIYAMONGKOL, P. High Accuracy Pre-Harvest Sugarcane Yield Forecasting Model Utilizing Drone Image Analysis, Data Mining, and Reverse Design Method. **Agriculture**, v. 11, n. 7, p. 682, 2021.

THEOBALD, O. **Machine Learning for Absolute Beginners (2nd ed.)**. Scatterplot Press. 2017.

USEYA, J.; CHEN, S. Exploring the Potential of Mapping Cropping Patterns on Smallholder Scale Croplands Using Sentinel-1 SAR Data. **Chinese Geographical Science**, v. 29, n. 4, p. 626–639, 2019.

VASCONCELOS, P. E. A.; MELLO, C. M. Responsabilidade penal e novas tecnologias: desafio do direito no século xxi sobre o uso de drones ou vant's. **Revista Jus-contemporânea**, v. 1, n. 1, p. 65–79, 2019. Disponível em: <<http://lexcul-tccjf.trf2.jus.br/index.php/revistajuscontemporanea/article/view/224/>>. Acesso em: 10 abr. 2022.

XU, K.; ZHU, Y.; CAO, W.; et al. Multi-Modal Deep Learning for Weeds Detection in Wheat Field Based on RGB-D Images. **Frontiers in Plant Science**, v. 12, p. 732968, 2021. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpls.2021.732968/full>>. Acesso em: 4 abr. 2022.

WEIS, M.; GUTJAHR, C.; RUEDA AYALA, V.; et al. Precision farming for weed management: techniques. **Gesunde Pflanzen**, v. 60, n. 4, p. 171–181, 2008. Disponível em: <<http://link.springer.com/10.1007/s10343-008-0195-1>>. Acesso em: 7 abr. 2022.

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

YANO, I. H. Mapeamento de infestações de plantas daninhas em lavoura de cana-de-açúcar por aeronave remotamente pilotadas (RPA). 2018. **Tese de Doutorado** (Doutor em Engenharia Agrícola) - Universidade Estadual de Campinas, [S. I.], 2018.

YAWSON, D. O.; ADU, M. O.; OSEI, K. N. Spatial assessment of sugarcane (*Saccharum* spp. L.) production to feed the Komenda Sugar Factory, Ghana. **Heliyon**, v. 4, n. 11, p. e00903, 2018.

YU, J.; SHARPE, S. M; SCHUMANN, A.W; et al. Detection of broadleaf weeds growing in turfgrass with convolutional neural networks: Precision weed control in turfgrass landscape. **Pest Management Science**, v. 75, n. 8, p. 2211–2218, 2019. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1002/ps.5349>>. Acesso em: 4 abr. 2022.

ZHANG, Q. et al. Missing data reconstruction in remote sensing image with a unified spatial–temporal–spectral deep convolutional neural network. **IEEE Transactions on Geoscience and Remote Sensing (TGRS)**, China, v. 56, n. 8, p. 4274-4288, 14 mar. 2018.