

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA
GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO



**ANÁLISE DE IMAGENS DE SATÉLITE PARA CLASSIFICAÇÃO DE ÁREAS
CULTIVADAS**

GEISON LEAL FEITOSA

GOIÂNIA
2021

GEISON LEAL FEITOSA

ANÁLISE DE IMAGENS DE SATÉLITE PARA CLASSIFICAÇÃO DE ÁREAS
CULTIVADAS

Monografia de conclusão de curso apresentada ao curso de Ciência da Computação, da Escola Politécnica da Pontifícia Universidade Católica de Goiás, como requisito parcial à conclusão do curso.

Orientador(a): Prof. Me. Max Gontijo de Oliveira
Coorientado(a)r: Prof. Me. Francisco C. Xavier

GOIÂNIA
2021

GEISON LEAL FEITOSA

ANÁLISE DE IMAGENS DE SATÉLITE PARA CLASSIFICAÇÃO DE ÁREAS
CULTIVADAS

Este Trabalho de Conclusão de Curso julgado adequado para obtenção do título de Bacharel em Ciência da Computação, e aprovado em sua forma final pela Escola Politécnica da Pontifícia Universidade Católica de Goiás, em ____/____/____.

Prof^a. Me. Ludmilla Reis Pinheiro dos Santos
Coordenador(a) de Trabalho de Conclusão de Curso

Banca examinadora:

Orientador: Prof. Me. Max Gontijo

Prof^a. M^a. Lucília Ribeiro

Prof^a. Dr^a. Carmen Cecília Centeno

GOIÂNIA

2021

Dedico este trabalho à minha família que sempre me apoiou com meus estudos, conduzindo minha vida nos caminhos da sabedoria e do conhecimento.

AGRADECIMENTOS

À Deus, que segundo Santo Agostinho é a Luz verdadeira que ilumina e guia todos nós (AGOSTINHO, 1973). Acredito que foi Ele quem guiou meus passos para chegar onde cheguei e alcançar meus objetivos.

À minha família, que mesmo nas suas limitações financeiras me deu exemplar educação e incentivo nos meus estudos.

Ao professor e orientador deste trabalho Max Gontijo de Oliveira, que me orientou quanto ao desenvolvimento deste trabalho. Que além de ser um excelente profissional é um exemplo de ser humano.

Ao professor e coorientador deste trabalho Francisco Calaça Xavier, que também me orientou quanto ao desenvolvimento deste trabalho. A ele meus agradecimentos se estendem a minha carreira profissional, sou grato por ter recebido dele a primeira oportunidade de atuar no mercado de trabalho da computação.

Às professoras Lucília Ribeiro e Carmen Cecília Centeno, por aceitarem generosamente compor a banca examinadora. Estas duas professoras são um exemplo e inspiração na minha vida acadêmica, com ensinamentos que me fizeram crescer como aluno, profissional e ser humano. Tive o prazer de tê-las como professoras no meu primeiro período, durante todo o curso e agora neste momento tão importante de finalização do curso.

À Escola Politécnica da PUC Goiás, pela oportunidade de realização deste trabalho. E a todos os professores integrantes desta escola, pois através da transmissão de seus conhecimentos, auxiliaram neste trabalho.

Aos meus colegas e amigos que de alguma forma me auxiliaram a solucionar os problemas impostos pela jornada acadêmica.

Finalmente, agradeço a todos, que direta ou indiretamente, contribuíram para a realização deste trabalho.

RESUMO

Com uma população cada vez maior o monitoramento de áreas agrícolas se torna cada vez mais necessário, pois proporciona um fortalecimento na segurança alimentar, uma compreensão da produtividade e um apoio às políticas agrícolas. Diante disto, este trabalho tem como objetivo classificar áreas cultivadas através de imagens de satélite. Para tal, séries temporais foram construídas com valores do *normalized difference vegetation index* (NDVI) a partir de imagens de satélite do Sentinel 2. O *Dynamic Time Warping* (DTW) foi utilizado como ferramenta de comparação entre as séries temporais, por ser uma solução eficiente para lidar com os desafios na análise de séries temporais de terras agrícolas. Os resultados obtidos foram satisfatórios e demonstraram que a classificação de áreas cultivadas, através de imagens de satélite, é possível. E que o DTW é uma ferramenta eficaz nesse processo. A abordagem adotada neste trabalho pode beneficiar também outras aplicações, como o monitoramento de desmatamentos, o mapeamento de desastres ou o mapeamento de culturas agrícolas.

Palavras-chave: Monitoramento de terras agrícolas. Classificação de áreas cultivadas. Análise de imagens de satélite. Programação dinâmica. *Dynamic Time Warping*.

ABSTRACT

With an ever-increasing population, monitoring of agricultural areas becomes more and more necessary as it provides strength in food security, an understanding of productivity and support for agricultural policies. Therefore, this work aims to classify cultivated areas through satellite images. For this purpose, time series were constructed with normalized difference vegetation index (NDVI) values from Sentinel 2 satellite images. Dynamic Time Warping (DTW) was used as a tool to compare the time series, as it is an efficient solution to deal with the challenges in analyzing agricultural land time series. The results obtained were satisfactory and demonstrated that the classification of cultivated areas, through satellite images, is possible. And that DTW is an effective tool in this process. The approach adopted in this work can also benefit other applications, such as deforestation monitoring, disaster mapping or agricultural crop mapping.

Keywords: Agricultural land monitoring. Classification of cultivated areas. Analysis of satellite images. Dynamic programming. Dynamic Time Warping.

LISTA DE FIGURAS

Figura 1 - Multispectral Imager (MSI) Satélite Sentinel-2A e Sentinel-2B	18
Figura 2 – Órbita satélite Sentinel-2A e Sentinel-2B	19
Figura 3 – Bandas do Sentinel-2.....	19
Figura 4 - Tiles	21
Figura 5 - NDVI	24
Figura 6 – Matriz tridimensional de imagens de satélite.....	25
Figura 7 – Série temporal de imagem de satélite.....	25
Figura 8 – Distância Euclidiana.....	26
Figura 9 – DTW.....	27
Figura 10 – Pseudo-código DTW	29
Figura 11 - Tile escolhido: 22KDF	31
Figura 12 - Portal Copernicus Open Access Hub da ESA.....	32
Figura 13 – Uso do QGIS na análise dos pontos no tile de estudo.....	33
Figura 14 – Dados de uma imagem, obtidos pelo software QGIS.....	34
Figura 15 – Pivô.....	38
Figura 16 – Sequeiro.....	39
Figura 17 – Mata.....	39
Figura 18 – Comparação de imagens de uma mesma área com concentração de água. Lado esquerdo imagem do mapa Bing e lado direito imagem em NDVI.....	40

LISTA DE GRÁFICOS

Gráfico 1 – Série temporal em NDVI do ponto 1 (Pivô).....	41
Gráfico 2 – Série temporal em NDVI do ponto 11 (Mata).....	42
Gráfico 3 – Série temporal em NDVI do ponto 18 (Lago/Rio)	42
Gráfico 4 – Assertividade do DTW conforme dados “sujos” foram sendo inseridos nas séries de teste	48

LISTA DE TABELAS

Tabela 1 – Pontos para o modelo.	37
Tabela 2 – Pontos para teste.	43
Tabela 3 – Resultado do teste com as 26 séries de teste.	46
Tabela 4 – Resultado dos testes com 5, 10, 25 e 30 pixels de chuva a mais em cada série de teste.	47
Tabela 5 – Resultado do teste com uma única amostra de referência de cada classe.	49

LISTA DE SIGLAS

DTW - *Dynamic Time Warping*

ESA - *European Space Agency*

GIS - *Geographic Information System*

GMES - *Global Monitoring for Environment and Security*

IAF - Índice de área foliar

INPE - Instituto Nacional de Pesquisas Espaciais

IVs - Índices de Vegetação

NDVI - *Normalized Difference Vegetation Index*

NIR - *Near-infrared*

PD - Programação dinâmica

PDI - Processamento Digital de Imagens

SIG - Sistema de Informação Geográfica

SUMÁRIO

1. INTRODUÇÃO	13
1.1. Organização dos capítulos	15
2. REFERENCIAL TEÓRICO	16
2.1 Processamento digital de imagens (PDI)	16
2.2 Missão Sentinel	17
2.2.1 Sentinel-2	18
2.3 Índice de vegetação (IVs)	21
2.4 Normalized Difference Vegetation Index (NDVI)	22
2.5 Séries Temporais	24
2.6 Dynamic Time Warping (DTW).....	26
2.7 Programação Dinâmica (PD).....	27
2.8 Implementação do DTW	28
2.9 Trabalhos relacionados	30
3. DADOS E MÉTODOS	31
3.1 Área de estudo	31
3.2 Obtenção das imagens.....	32
3.3 Metodologia.....	32
3.3.1.QGIS	33
3.3.2.Cálculo do NDVI	34
3.3.2.1. Python.....	35
3.3.2.2. Programa para construção das imagens em NDVI	36
3.3.3.Classes do Problema	36
3.3.3.1. Pivô	38
3.3.3.2. Sequeiro.....	38
3.3.3.3. Mata	39
3.3.3.4. Lago/Rio.....	40
3.3.3.5. Estrada.....	40
3.3.3.6. Rodovia.....	40
3.3.4.Construção das séries temporais do modelo.	41
3.3.5.Programa para construção das séries temporais	43
3.3.6.Amostras de teste.....	43
3.3.7.Construção das séries temporais de teste.	44
3.3.8.Programa para a comparação entre as séries temporais.....	44
4. ANÁLISE E DISCUSSÃO	46

5. CONCLUSÃO.....	51
REFERÊNCIAS.....	53
ANEXOS.....	57
ANEXO A - Pontos 4, 5 e 3.	57
ANEXO B - Pontos 18, 12, 16, 6 e 11	58
ANEXO C - Pontos 25 e 26.....	59
ANEXO D - Pontos 24, 1, 9, 2, 10, 20, 7, 8, 19, 22, 23 e 21	60
ANEXO E - Pontos 17, 15, 14 e 13	61

1. INTRODUÇÃO

A população mundial deverá aumentar de 7,8 bilhões para 8,6 bilhões até 2030, 10,5 bilhões até 2050 e 21,6 bilhões até 2100 (UNITED NATIONS, 2019). Este crescimento populacional impacta os sistemas de abastecimento de alimentos em todo o mundo, tornando urgente o desenvolvimento de programas de gestão sustentável de recursos naturais (WALDNER et al., 2015).

O monitoramento eficiente de áreas agrícolas pode ser uma ferramenta de grande auxílio no desenvolvimento de programas de gestão sustentável de recursos naturais. A análise de imagens de satélites pode fornecer informações espaciais e temporais oportunas e relevantes neste monitoramento (CSILLIK et al., 2019).

A crescente resolução espacial e temporal de imagens de satélite disponíveis globalmente, como as fornecidas pelo Sentinel-2, possibilitam a geração de dados cada vez mais precisos sobre a agricultura.

Diante deste contexto, este trabalho tem como objetivo principal contribuir com soluções a respeito do monitoramento de áreas agrícolas, através da análise de imagens de satélite para a classificação de áreas cultivadas.

Uma vez que a classificação de áreas cultivadas seja possível, outras soluções no âmbito do monitoramento de áreas agrícolas serão beneficiadas, como:

- a identificação das culturas plantadas,
- a mensuração da quantidade plantada em determinada área, município, estado, país e até mesmo no planeta,
- a predição da quantidade que determinada cultura será colhida em determinado tempo, entre outros.

Ajudando assim no desenvolvimento de programas de gestão sustentável, promovendo uma melhor produção e distribuição dos recursos provenientes da atividade agrícola. Esta gestão poderá ajudar os governos a garantirem a segurança alimentar, ou seja o acesso à alimentação, dos seus cidadãos. Além de uma melhor compreensão da produtividade de seu território e um melhor apoio aos produtores agrícolas.

Para alcançar o objetivo principal deste trabalho, alguns objetivos específicos são requeridos, como a criação de um dataset a partir de imagens de satélite, estudo sobre como analisar a cobertura vegetal da superfície terrestre e classificar áreas como cultivadas ou não através de imagens de satélite e o desenvolvimento de um

modelo capaz de classificar uma região em área de cultivo ou não.

No desenvolvimento deste trabalho serão utilizadas imagens da missão Sentinel, gerenciada pela Agência Espacial Europeia (ESA). A missão Sentinel é composta por diversos satélites, cada um com objetivos específicos. No caso deste trabalho, as imagens utilizadas foram fornecidas pelos satélites Sentinel 2-A e Sentinel 2-B, por se tratar de satélites destinados ao monitoramento do estado de vegetação, ao manejo florestal e à agricultura.

Para analisar a cobertura vegetal da superfície terrestre através de imagens de satélite é necessário a utilização de um índice de vegetação, como o *normalized difference vegetation index* (NDVI). Estas imagens, preferencialmente, devem ser obtidas de um determinado cenário espacial e temporal.

Este trabalho utiliza o NDVI para a geração de séries temporais modelo e de teste. Segundo Debiasi et. al. (2007) o NDVI é o índice mais empregado e aceito para analisar a cobertura vegetal utilizando o sensoriamento remoto orbital. Ele é um índice que apresenta uma correlação entre a luz infravermelha e o espectro de luz vermelha que incidem e que refletem ao atingir a superfície do planeta.

Os diferentes objetos na superfície terrestre refletem, absorvem e transmitem radiação eletromagnética em proporções variadas. Graças a essas variações é possível distinguir estes objetos nas imagens de sensores remotos (FLORENZANO, 2002).

Maus et al. (2016) afirmam que há uma continuidade temporal para cada classe de uso do solo. Uma floresta por exemplo não muda para pastagem ou lavoura da noite para o dia. Com base nessa afirmação, este trabalho supõe que seja possível associar cada série temporal a um tipo específico de cobertura da terra. Então comparando séries temporais com outras séries temporais previamente classificadas pressupõe-se que seja possível identificar com qual delas as séries mais se aproximam.

Porém o mapeamento de terras agrícolas baseado em análise de séries temporais obtidas através de imagens de satélites enfrenta uma série de limitações, como por exemplo a perda de dados pela influência de nuvens ou até mesmo mudanças anuais dos ciclos fenológicos causados pelo clima ou por variações nas práticas agrícolas (PETITJEAN et al., 2012).

A fim de lidar com estes desafios e obter melhores resultados na classificação de terras cultivadas, este trabalho utiliza o *Dynamic Time Warping* (DTW) como

ferramenta de comparação entre as séries. Pois o DTW é capaz de comparar séries temporais de tamanho variável, além de ser robusto para mudanças e distorções em toda a dimensão do tempo (CUTURI et al, 2017).

1.1. Organização dos capítulos

No primeiro capítulo foi visto que o monitoramento eficiente de áreas agrícolas se faz cada vez mais necessário. E que a crescente resolução espacial e temporal de imagens de satélite disponíveis globalmente pode ajudar nesse monitoramento. Com isto, este trabalho propõe a análise de imagens de satélite para classificação de áreas cultivadas, utilizando o DTW na comparação de séries temporais construídas com valores de NDVI.

O Capítulo 2 proporciona uma fundamentação teórica para que o objetivo deste trabalho seja alcançado. Neste capítulo é abordado os conceitos do processamento digital de imagens (PDI), dos índices de vegetação (IVs), do NDVI, de séries temporais, do DTW e da programação dinâmica (PD). Além de trazer uma visão sobre a missão Sentinel e os produtos Sentinel 2. Trabalhos relacionados a este tema também foram expostos neste capítulo.

O Capítulo 3 apresenta a área de estudo, os meios utilizados para a obtenção das imagens e a metodologia adotada para o desenvolvimento deste trabalho. Dentro desta metodologia está o cálculo do NDVI, a construção das séries temporais e a classificação das séries modelo e de teste.

O Capítulo 4 apresenta os resultados obtidos a partir deste trabalho, considerando o que foi proposto e o que foi alcançado, e apresenta sugestões para trabalhos futuros.

Por fim, no Capítulo 5 são apresentadas reflexões e conclusões sobre a realização do trabalho.

2. REFERENCIAL TEÓRICO

Este capítulo traz uma fundamentação teórica para que o objetivo deste trabalho seja alcançado. Neste capítulo será abordado os conceitos do processamento digital de imagens (PDI), dos índices de vegetação (IVs), do *difference vegetation index* (NDVI), de séries temporais, do *Dynamic Time Warping* (DTW) e da programação dinâmica (PD). Além de trazer uma visão sobre a missão Sentinel e os produtos Sentinel 2. Trabalhos relacionados a este tema também serão expostos neste capítulo.

2.1 Processamento digital de imagens (PDI)

O PDI envolve um conjunto de tarefas interconectadas. Iniciando com a captura de uma imagem, que normalmente corresponde à iluminação refletida na superfície dos objetos.

Os objetos são percebidos em função da soma das cores espectrais emitidas por eles. Por exemplo, ao combinar os espectros verde, vermelho e azul tem-se o padrão RGB (*Red, Green e Blue*) que forma as cores perceptíveis pelo olho humano.

Após a captura, uma imagem precisa ser representada de forma apropriada para o tratamento computacional. Na maioria das vezes é necessário um pré-processamento que envolve a filtragem de ruídos e a correção de distorções geométricas.

Como os computadores não são capazes de processar imagens contínuas, mas apenas *arrays* de números digitais, é necessário representar imagens como matrizes bidimensionais. Onde cada ponto na matriz bidimensional que representa a imagem digital é denominado *pixel*.

Uma imagem monocromática, que possui apenas uma cor, é uma função bidimensional contínua $f(x, y)$, na qual x e y são coordenadas espaciais e o valor de f em qualquer ponto (x, y) é proporcional à intensidade luminosa (brilho ou nível de cinza) no ponto considerado.

Já em imagens coloridas $f(x, y)$ pode ser visto como um vetor com os valores correspondentes a intensidade de vermelho, verde e azul daquele pixel.

Diante disto podemos perceber que ao combinarmos os valores de $f(x, y)$ de

duas ou mais imagens de diferentes espectros podemos gerar valores $f(x, y)$ de outra imagem em outro espectro. Em muitos casos essa combinação é necessária e pode gerar índices capazes de fornecer informações a respeito dos objetos presentes nas imagens.

Outro ponto relevante no PDI é a amostragem, em outras palavras a “resolução” da imagem. A amostragem refere-se à quantidade de pixels utilizados para representar matricialmente a imagem. Quanto maior a quantidade de pixel, maior a riqueza em detalhes da imagem, conseqüentemente maior será o volume de dados a serem armazenados e processados.

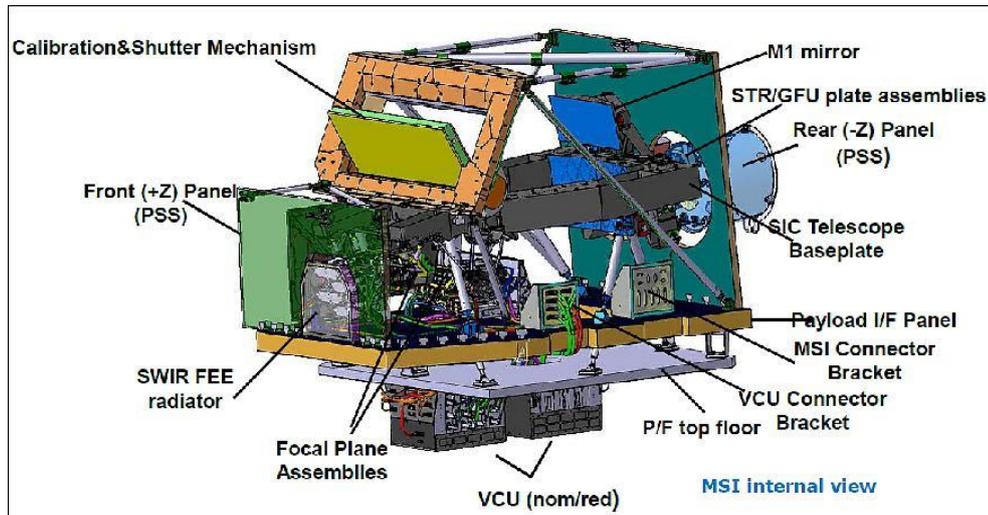
2.2 Missão Sentinel

A missão *Global Monitoring for Environment and Security* (GMES) surgiu para dar continuidade a algumas missões antigas gerenciadas pela Agência Espacial Europeia (ESA) no monitoramento dos recursos naturais terrestres, do uso e ocupação das terras, dos ambientes marinhos, do clima e desastres naturais. Em 2012 ela passou a se chamar Sentinel e em 2014 a série de satélites Sentinel começou a ser lançada no espaço (EMBRAPA, 2020).

Para abranger temas de diferentes áreas, a missão é composta por pares de satélites especializados e adequados a cada um. O par de satélites Sentinel-1 leva a bordo sensores de radar e são aplicados ao monitoramento terrestre e oceânico. Os satélites Sentinel-2 são dotados com sensor óptico de alta resolução espacial e foram direcionados ao monitoramento da vegetação, solos e áreas costeiras. A terceira série carrega sensores ópticos e radares adequados ao monitoramento marinho. Já as séries 4 e 5 são aplicadas ao monitoramento da qualidade do ar (EMBRAPA, 2020).

O primeiro satélite da série foi o Sentinel-1A, lançado em 2014, que assim como o Sentinel-1B é equipado com o sensor de radar *Synthetic Aperture Radar* (SAR). Em 2015, foi lançado o Sentinel-2A, o primeiro satélite óptico da série a ser operado pela ESA, e em 2017 o Sentinel-2B. Ambos levam a bordo um sensor multiespectral *MultiSpectral Instrument* (MSI) conforme mostrado na Figura 1. Em 2016 foi lançado o Sentinel-3A e em 2018 o Sentinel-3B (EMBRAPA, 2020).

Figura 1 - Multispectral Imager (MSI) Satélite Sentinel-2A e Sentinel-2B



Fonte: EMBRAPA, 2020.

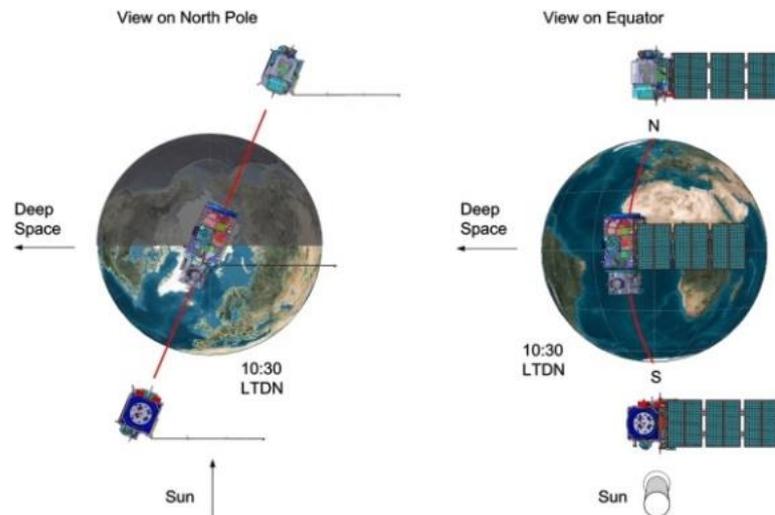
Além desses citados anteriormente, há também os satélites das missões Sentinel-4, Sentinel-5 e Sentinel-5 Precursor. Em 21 de novembro de 2020, o primeiro satélite da missão Sentinel-6, cujo objetivo é monitorar o aumento da altura da superfície do mar causado pelas mudanças climáticas, foi lançado em um foguete SpaceX Falcon 9 da Base Aérea de Vandenberg, na Califórnia, EUA (THE EUROPEAN SPACE AGENCY, 2021b).

As imagens da missão Modis possuem uma alta resolução temporal e as imagens da missão Landsat possuem uma alta resolução espacial. Já as imagens da missão Sentinel possuem uma alta resolução tanto temporal quanto espacial (PETITJEAN et al., 2012). Por este motivo este trabalho optou em utilizar as imagens da missão Sentinel em suas análises.

2.2.1 Sentinel-2

Os satélites Sentinel-2A e Sentinel-2B voam na mesma órbita, mas a 180° um do outro, executando uma alta frequência de revisita de 5 dias no Equador, conforme ilustrado na Figura 2, produzindo assim uma nova imagem a cada 5 dias (THE EUROPEAN SPACE AGENCY, 2021a).

Figura 2 – Órbita satélite Sentinel-2A e Sentinel-2B



Fonte: THE EUROPEAN SPACE AGENCY, 2021a.

A carga óptica de instrumentos que eles carregam amostra 13 bandas espectrais conforme a Figura 3, com resolução espacial de 10m para as bandas do visível (THE EUROPEAN SPACE AGENCY, 2021a).

Figura 3 – Bandas do Sentinel-2

Band	Resolution	Central Wavelength	Description
B1	60 m	443 nm	Ultra blue (Coastal and Aerosol)
B2	10 m	490 nm	Blue
B3	10 m	560 nm	Green
B4	10 m	665 nm	Red
B5	20 m	705 nm	Visible and Near Infrared (VNIR)
B6	20 m	740 nm	Visible and Near Infrared (VNIR)
B7	20 m	783 nm	Visible and Near Infrared (VNIR)
B8	10 m	842 nm	Visible and Near Infrared (VNIR)
B8a	20 m	865 nm	Visible and Near Infrared (VNIR)
B9	60 m	940 nm	Short Wave Infrared (SWIR)
B10	60 m	1375 nm	Short Wave Infrared (SWIR)
B11	20 m	1610 nm	Short Wave Infrared (SWIR)
B12	20 m	2190 nm	Short Wave Infrared (SWIR)

Fonte: GISGEOGRAPHY, 2021.

Com base nos dados apresentados, conclui-se que as imagens dos satélites Sentinel-2A e Sentinel-2B possuem uma resolução espectral de 13 bandas e uma resolução temporal de 5 dias. Conclui-se também que para as bandas 4 e 8, que serão objetos de estudo deste trabalho, a resolução temporal é de 10 metros.

Resolução espacial refere-se ao nível de detalhamento que podemos observar objetos na superfície terrestre. Em outras palavras, é o “nível de detalhamento” ou, a capacidade dos sensores presentes no satélite de enxergar os objetos em relação ao seu tamanho.

Resolução espectral pode ser compreendida como a quantidade de bandas que os sensores presentes no satélite conseguem disponibilizar. Quando a energia solar atinge a superfície terrestre, parte desta energia é absorvida e parte é refletida. Esta energia é emitida pela superfície terrestre através de ondas.

Resolução temporal corresponde ao tempo que o satélite leva para recobrir a mesma área novamente. E assim gerar uma nova imagem daquela área.

Conforme afirmação da própria ESA, os satélites Sentinel-2A e Sentinel-2B contribuem para observações multiespectrais em curso e beneficiam os serviços e aplicações da Copernicus, como gestão da terra, agricultura e silvicultura, controle de desastres, operações de socorro humanitário, mapeamento de riscos e preocupações com a segurança (THE EUROPEAN SPACE AGENCY, 2021a).

A Copernicus é um programa de observação da Terra que pertence a ESA. E o seu objetivo é fornecer informações de cobertura fundiária aos usuários que trabalham no campo de aplicações ambientais (THE EUROPEAN SPACE AGENCY, 2021c).

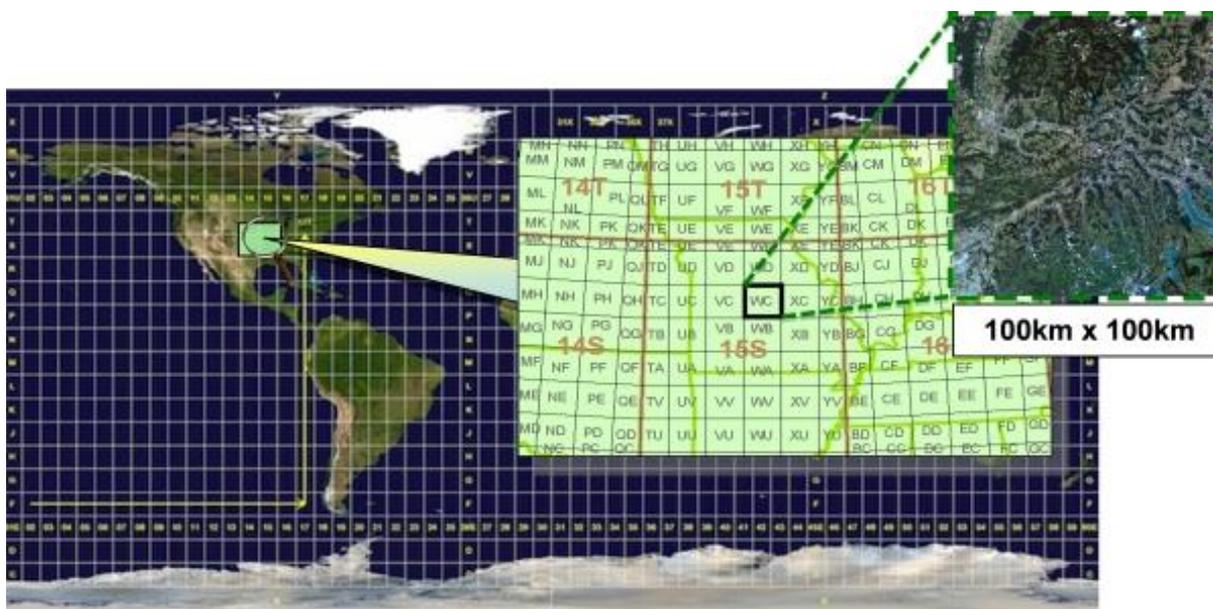
Os satélites Sentinel-2A e Sentinel-2B foram projetados para fornecer informações geográficas sobre a cobertura da terra e variáveis relacionadas, como o estado de vegetação ou o ciclo da água, e suporta aplicações em outros domínios, incluindo planejamento espacial, manejo florestal, manejo da água, agricultura e segurança alimentar (THE EUROPEAN SPACE AGENCY, 2021c).

A alta resolução temporal, espectral e espacial das imagens fornecidas pelo Sentinel 2, estão tornando-o o satélite adequado para fornecer imagens para análise de séries temporais. Obtendo vantagens sobre as abordagens de imagem única, permitindo a incorporação das características fenológicas da vegetação ao longo de um ou de vários anos (CSILLIK et al., 2019).

A ESA possui uma política de dados gratuitos, graças a essa política qualquer

pessoa pode acessar e baixar as imagens fornecidas pelo Sentinel 2. Cada banda espectral é armazenada como uma imagem, no formato *Joint Photographic Experts Group* (JPEG) 2000, separada para facilitar o acesso. As imagens são organizadas em um plano cartesiano da Sentinel-2, baseado no Sistema de Referência de Grade Militar, que divide a Terra em quadrados de aproximadamente 100 km de cada lado conhecidos como “grânulos” ou “tiles”, conforme a Figura 4 (GOOGLE PUBLIC CLOUD DATA, 2021).

Figura 4 - Tiles



Fonte: THE EUROPEAN SPACE AGENCY, 2021. 4

2.3 Índice de vegetação (IVs)

Para analisar as mudanças ocorridas no uso e cobertura da terra é necessária uma análise multitemporal através de índices de vegetação (IVs) (BAYMA, 2015).

Os IVs são alterações espectrais de duas ou mais bandas, aplicados para aumentar a contribuição da propriedade da vegetação e possibilitar comparações confiáveis da atividade fotossintética terrestre (HUETE et al., 2002). São usados frequentemente para monitorar e caracterizar a cobertura vegetal da Terra, relacionando-se com parâmetros biofísicos da vegetação (JIANG et al., 2008), como:

- **fitomassa**: massa total dos seres vegetais que subsistem em equilíbrio numa dada superfície de solo,
- **índice de área foliar (IAF)**: a razão entre a área foliar do dossel (estrutura

formada pelas copas das árvores) e a unidade de superfície projetada no solo (m^2/m^2),

- **porcentagem da cobertura verde:** a mensuração de áreas com cobertura vegetal,
- e **teor de clorofila:** estimativa do potencial de absorção e transferência de energia da vegetação, através da clorofila (pigmentação que dão a tonalidade verde às folhas).

2.4 Normalized Difference Vegetation Index (NDVI)

Dentre os IVs utilizados para o monitoramento da vegetação destacam-se o Normalized Difference Vegetation Index (NDVI), também conhecido como Índice de Vegetação por Diferença Normalizada (IVDN) (HUETE et al., 2002). No geral, o NDVI é mais sensível à presença de pigmentos que participam dos processos fotossintéticos, em particular ao conteúdo de clorofila e pode ser aplicado em diferentes tipos de vegetação (GITELSON et al., 1996; HUETE et al., 1997).

O NDVI permite comparações significativas de mudanças sazonais e inter- anuais de crescimento da vegetação (HUETE et al., 2002). Permitindo assim a análise do comportamento da vegetação, em um determinado cenário (PONZONI; SHIMABUKURO 2009).

O NDVI é um índice que apresenta uma correlação entre a luz infravermelha e o espectro de luz vermelha que incidem e que refletem ao atingirem a superfície do planeta. Essa relação é dada pela seguinte formulação:

$$(1)$$

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Onde *NIR* é a quantidade de luz infravermelha próxima e *Red* a quantidade de luz vermelha.

Segundo Elvidge (1995), Chen (1995) e Jiang et al. (2008), o NDVI tem sido globalmente utilizado em estudos como um discriminador de vegetação, pois pode ser correlacionado facilmente a vários parâmetros de vegetação, como fitomassa, área foliar, porcentagem de cobertura verde, entre outros.

O NDVI é o mais empregado e um dos mais aceitos índices para analisar a cobertura vegetal utilizando o sensoriamento remoto orbital (DEBIASI et. al., 2007). Isto porque, além de um diagnóstico detalhado da fitomassa, ele corrige os efeitos das sombras provenientes das elevações topográficas (COSTA et al, 2007).

Os valores do NDVI oscilam de -1 a +1. Onde valores mais próximos de 1 refere-se a maior densidade da cobertura vegetal, ou seja, apresenta-se em seu estágio denso, úmido e bem desenvolvido (MELO, 2011).

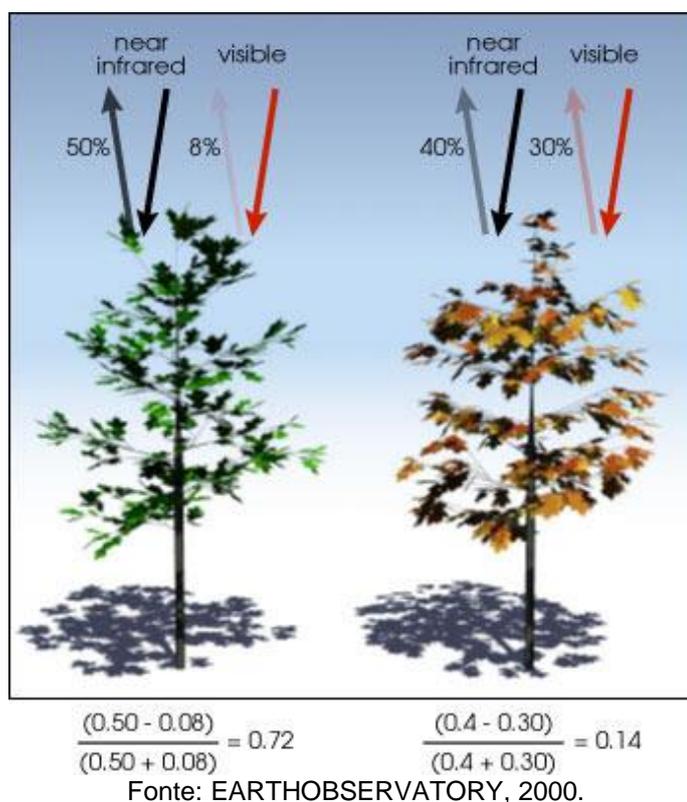
A vegetação, a água e o solo refletem, absorvem e transmitem radiação eletromagnética em proporções que variam de acordo com as suas características bio-físico-químicas. Devido a essas variações é possível distinguir os objetos da superfície terrestre nas imagens de sensores remotos (FLORENZANO, 2002).

Diferentemente dos demais objetos da superfície terrestre, a vegetação (verde e sadia) absorve radiação solar incidente fortemente nas regiões espectrais vermelhas e reflete o NIR. Sendo assim ela tem alta absorção de luz visível e alta refletância do NIR, resultando em valores positivos de NDVI, conforme ilustrado na Figura 5. Já o solo nu, nuvem, neve e concreto tem valores de NDVI próximos de zero, enquanto água tem valores negativos de NDVI (PETTORELLI, 2013).

Esses resultados são explicados quando observamos que na fórmula do NDVI, quanto mais NIR refletido e menos refletância de vermelho maior será o numerador.

Quando a refletância de ambos é próxima, o valor do numerador tende a valores mais próximos de zero, gerando também um resultado próximo de zero. E quando a refletância do NIR é superior à do vermelho o numerador terá um valor negativo, gerando também um valor negativo para o NDVI.

Figura 5 - NDVI



2.5 Séries Temporais

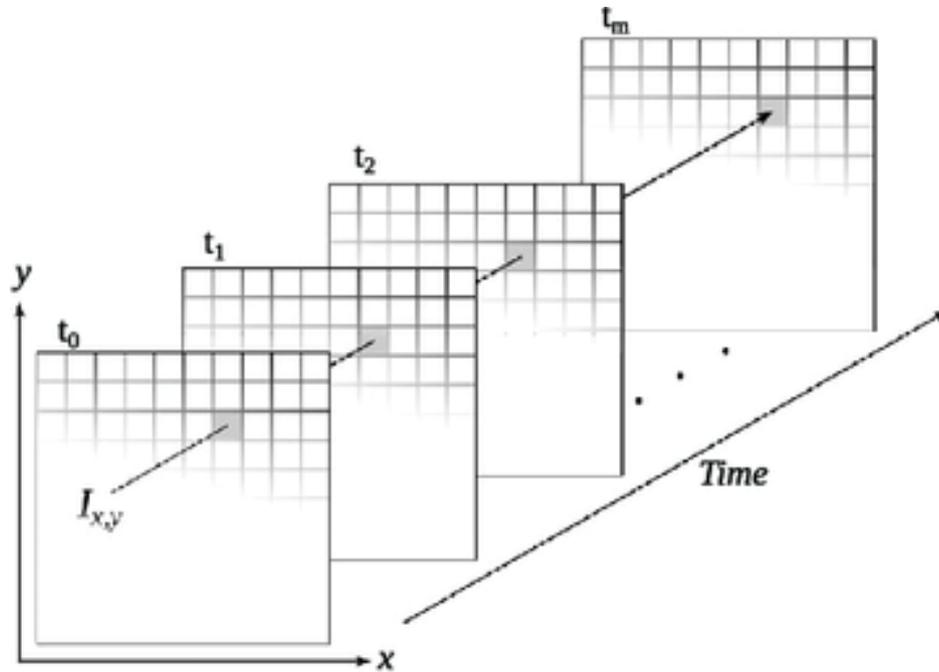
Instituições governamentais federais e estaduais, institutos de pesquisa e organizações não-governamentais tem promovido diversas iniciativas de mapeamento da cobertura vegetal, através da utilização de dados provenientes de sensores remotos orbitais. Mas a maioria dessas iniciativas são baseadas em análises de imagens de satélite de uma única data. Isso impossibilita uma análise mais apurada da dinâmica das mudanças ocorridas na cobertura e no uso da terra (BAYMA, 2015).

Para detectar mudanças na cobertura vegetal da superfície terrestre é necessário a análise de imagens de sensores remotos através de um índice de vegetação, como o NDVI, obtidas de um determinado cenário espacial e temporal.

Como mencionado na seção 2.1.1 os satélites Sentinel-2 possuem uma frequência de revisita de 5 dias. Esse sensoriamento com intervalos regulares nos permite mapear os dados fornecidos em matrizes tridimensionais no espaço-tempo, conforme é exemplificado na Figura 6, onde cada posição da matriz corresponde a um pixel. E cada pixel (x, y) , nos tempos t_0, \dots, t_m , forma uma série temporal de

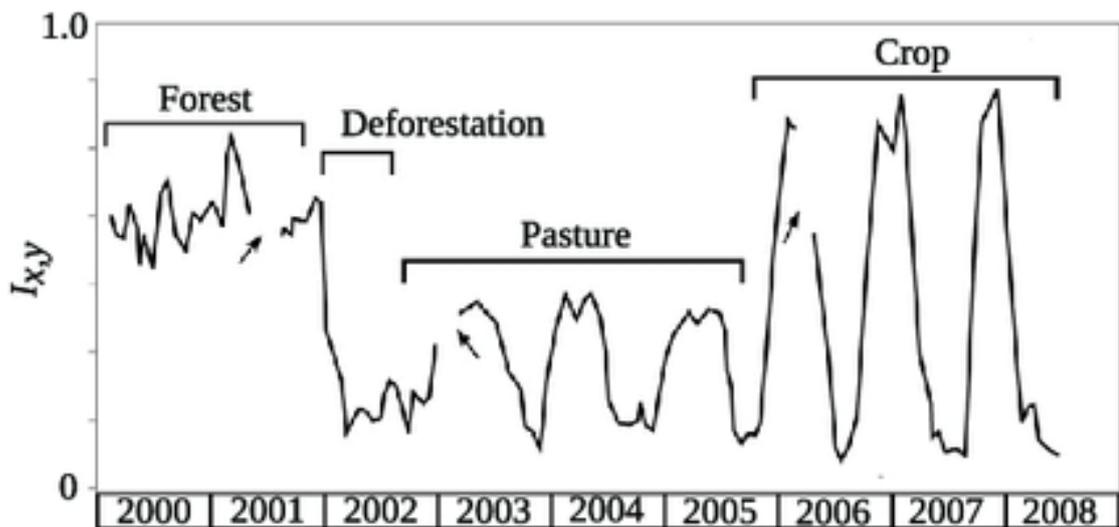
imagens de satélite, onde podemos extrair informações sobre o uso e a cobertura da terra, conforme vemos na Figura 7.

Figura 6 – Matriz tridimensional de imagens de satélite.



Fonte: MAUS et al., 2016.

Figura 7 – Série temporal de imagem de satélite.



Fonte: MAUS et al., 2016.

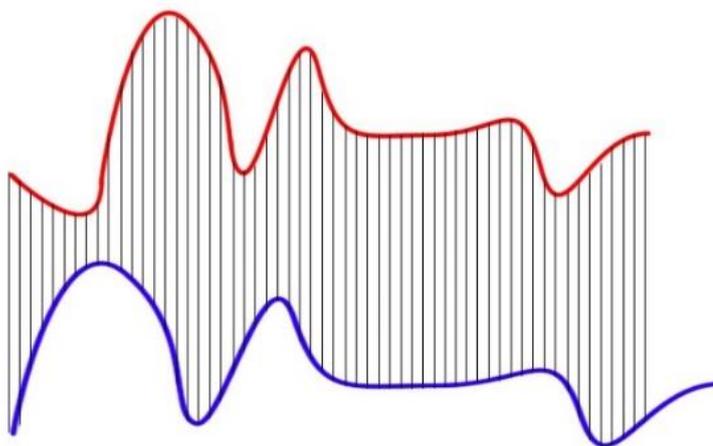
Há uma continuidade temporal para cada classe de uso do solo, resultante da ação humana (MAUS et al., 2016). Uma área de floresta por exemplo não muda para pastagem ou lavoura da noite para o dia. Para que essas mudanças ocorram é necessário um intervalo de tempo maior.

Com base nisso, podemos supor que é possível associar intervalos fechados de cada série temporal a um tipo específico de cobertura da terra. Logo se compararmos séries temporais com outras séries temporais previamente classificadas podemos identificar com qual delas as séries mais se aproximam.

Porém o mapeamento de terras agrícolas baseado em análise de séries temporais obtidas através de imagens de satélites é desafiador. Pois enfrenta uma série de limitações como a falta de amostras usadas para treinar um algoritmo supervisionado, dados perdidos pela influência de nuvens, mudanças anuais dos ciclos fenológicos causados pelo clima ou por variações nas práticas agrícolas (PETITJEAN et al., 2012).

Esses desafios fazem com que a comparação um para um, entre séries temporais sejam ineficientes. Conforme mostra a Figura 8, apesar das séries terem o mesmo padrão, o mapeamento não está sincronizado.

Figura 8 – Distância Euclidiana.



Fonte: ZHANG, 2020.

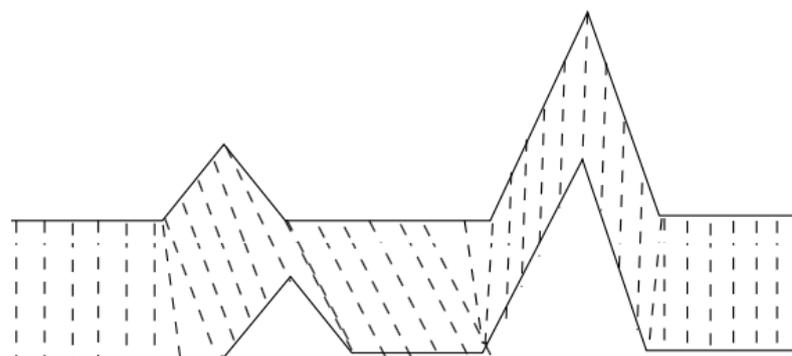
2.6 Dynamic Time Warping (DTW)

O DTW foi originalmente proposto para o reconhecimento de fala, porém estudos realizados por Petitjean et al. (2012) e Csillik (2019) provaram que ele pode ser uma solução eficiente para lidar com os desafios na análise de séries temporais de terras agrícolas.

O DTW é capaz de comparar séries temporais de tamanho variável e é robusto para mudanças e distorções em toda a dimensão do tempo (CUTURI et al,

2017). Conforme exemplificado na Figura 9, o DTW não faz uma comparação ponto a ponto, cada ponto de ambas as séries pode ser combinado com um ou mais pontos da outra série.

Figura 9 – DTW.



Fonte: DYNAMIC TIME WARPING, 2016.

O DTW também não é muito sensível ao número de amostras de referência, desde que seu padrão temporal seja característico de cada classe modelo. Esta é uma grande vantagem para mapear culturas em extensões com falta de amostras de referência (CSILLIK et al., 2019).

Por se tratar de um problema de otimização combinatória, a solução algorítmica deve considerar uma abordagem apropriada. Neste caso, a abordagem usada é a programação dinâmica.

2.7 Programação Dinâmica (PD)

Programação dinâmica (PD) é um procedimento computacional que permite a construção de uma solução a partir de soluções menores. A construção da solução é realizada através da decomposição de um problema complexo e de grandes dimensões, em subproblemas menores, interrelacionados e interdependentes, organizados em múltiplos estágios.

Normalmente a PD é usada em problemas de otimização, que envolve encontrar a “melhor” solução entre todas as soluções possíveis, por se tratar de uma técnica que guarda os resultados de subproblemas evitando o recálculo.

Segundo o princípio de otimização de Bellman (1957), o melhor caminho para se ir do ponto (i, j) até o ponto (n, m) passando por (x, y) é dado pela concatenação dos melhores caminhos de (i, j) até (x, y) e de (x, y) até (n, m) . Logo, conseqüentemente temos que o custo mínimo total para chegar até (n, m) passando por $(n-1, m-1)$ é igual a distância mínima total para se chegar a $(n-1, m-1)$ mais a distância até (n, m) .

No DTW a solução final, que é o custo mínimo entre duas séries s e t , ou seja, a distância entre elas, é obtido com base na distância das últimas posições de cada série somado ao custo mínimo considerando que as séries tenham tamanhos $n-1$ e m , n e $m-1$ ou $n-1$ e $m-1$.

2.8 Implementação do DTW

Em geral, o DTW é um método que calcula uma combinação ideal entre duas sequências, com certas restrições e regras:

- Cada índice da primeira sequência deve ser combinado com um ou mais índices da outra sequência e vice-versa.
- O primeiro índice da primeira sequência deve ser combinado com o primeiro índice da outra sequência (mas não precisa ser sua única correspondência).
- O último índice da primeira sequência deve ser combinado com o último índice da outra sequência (mas não precisa ser sua única correspondência).
- O mapeamento dos índices da primeira sequência para os índices da outra sequência deve ser crescente e vice-versa.

A combinação ótima é denotada pela combinação que satisfaz todas essas restrições e regras e que tem o custo mínimo, onde o custo é calculado como a soma das diferenças absolutas, para cada par de índices combinados, entre seus valores.

Na PD é necessário estabelecer uma recorrência para a construção de uma solução a partir de soluções menores. Sejam s e t duas sequências de tamanhos respectivamente n e m , e seja $d(s_i, t_j)$ a distância absoluta entre as amostras s_i e t_j , no problema DTW, consideremos ainda que a função $DTW(s, t, n, m)$ calcula e retorna o custo mínimo ótimo para duas sequências s e t de tamanhos respectivamente n e m . Uma vez que a solução deve considerar que as duas

amostras finais das duas sequências devem estar combinadas, como consequência, temos que $d(s_n, t_n)$ é um custo que compõe o custo final. Logo, para se obter o custo total, precisa-se apenas saber qual é o custo ótimo acumulado até aquele momento.

Esse custo ótimo envolve saber como as amostras s_{n-1} e t_{m-1} combinam. Existem apenas três possibilidades.

- a amostra s_{n-1} e a amostra t_m se combinam. Nesse caso, a amostra t_{m-1} é irrelevante pois ela se combina com outra amostra de s passada.
- a amostra s_n e a amostra t_{m-1} se combinam. Nesse caso, a amostra s_{n-1} é irrelevante pois ela se combina com outra amostra de t passada.
- a amostra s_{n-1} e a amostra t_{m-1} se combinam.

Por fim, a recorrência de DTW pode ser descrita como:

$$DTW(s, t, n, m) = d(s, t, n, m) + \min(DTW(s, t, n-1, m), \\ DTW(s, t, n, m-1), \\ DTW(s, t, n-1, m-1))$$

A Figura 10 apresenta um algoritmo de programação dinâmica que faz uso dessa recorrência.

Figura 10 – Pseudo-código DTW

```
int DTWDistance(s: array [1..n], t: array [1..m]) {
    DTW := array [0..n, 0..m]

    for i := 1 to n
        for j := 1 to m
            DTW[i, j] := infinity
    DTW[0, 0] := 0

    for i := 1 to n
        for j := 1 to m
            cost := d(s[i], t[j])
            DTW[i, j] := cost + minimum(DTW[i-1, j],
                                        DTW[i, j-1],
                                        DTW[i-1, j-1])

    return DTW[n, m]
}
```

Fonte: ZHANG, 2020.

Como podemos ver na Figura 10, inicialmente é criada uma matriz de tamanho $n+1 \times m+1$ e insere-se infinito em todas as suas posições. Posteriormente é inserido 0 na posição $[0, 0]$, indicando que o custo mínimo da combinação de duas sequências de tamanho 0 evidentemente é 0.

Utilizando a recorrência discutida, os valores de custo mínimo para cada solução parcial são armazenados na matriz através das linhas de código abaixo.

$$DTW[i, j] := cost + \text{minimum}(DTW[i-1, j], \\ DTW[i, j-1], \\ DTW[i-1, j-1])$$

O que diz que o custo entre duas sequências com comprimento i e j é igual à distância entre suas últimas posições mais o custo mínimo acumulado das combinações das amostras anteriores.

Logo, ao final de todo esse processo, $DTW[n, m]$ armazenará o custo mínimo entre as sequências s e t .

2.9 Trabalhos relacionados

O Instituto Nacional de Pesquisas Espaciais (INPE), desde janeiro de 2019, vem desenvolvendo um projeto chamado Brasil Data Cube. Este projeto tem como objetivo gerar informações sobre o uso da terra de todo o território brasileiro utilizando aprendizado de máquina e análise de séries temporais de imagens de satélite (BRAZIL DATA CUBE, 2021).

Veloso (2017) afirma que as informações de monitoramento de safras são essenciais para a segurança alimentar e para melhorar nossa compreensão do papel da agricultura sobre mudanças climáticas. Em seu estudo é mostrado que séries temporais densas derivadas do NDVI, permitem capturar estágios fenológicos curtos e assim, descrever precisamente o desenvolvimento de várias culturas.

Csillik (2019) demonstrou em seu estudo que o DTW, sobretudo com restrição de tempo, se mostrou eficiente para o mapeamento de culturas. Superando as classificações usando, por exemplo, a distância euclidiana. Em seu estudo foram utilizadas imagens das regiões da Califórnia e do Texas, alcançando precisão de classificação satisfatória com o uso do DTW em series temporais derivadas do NDVI.

3. DADOS E MÉTODOS

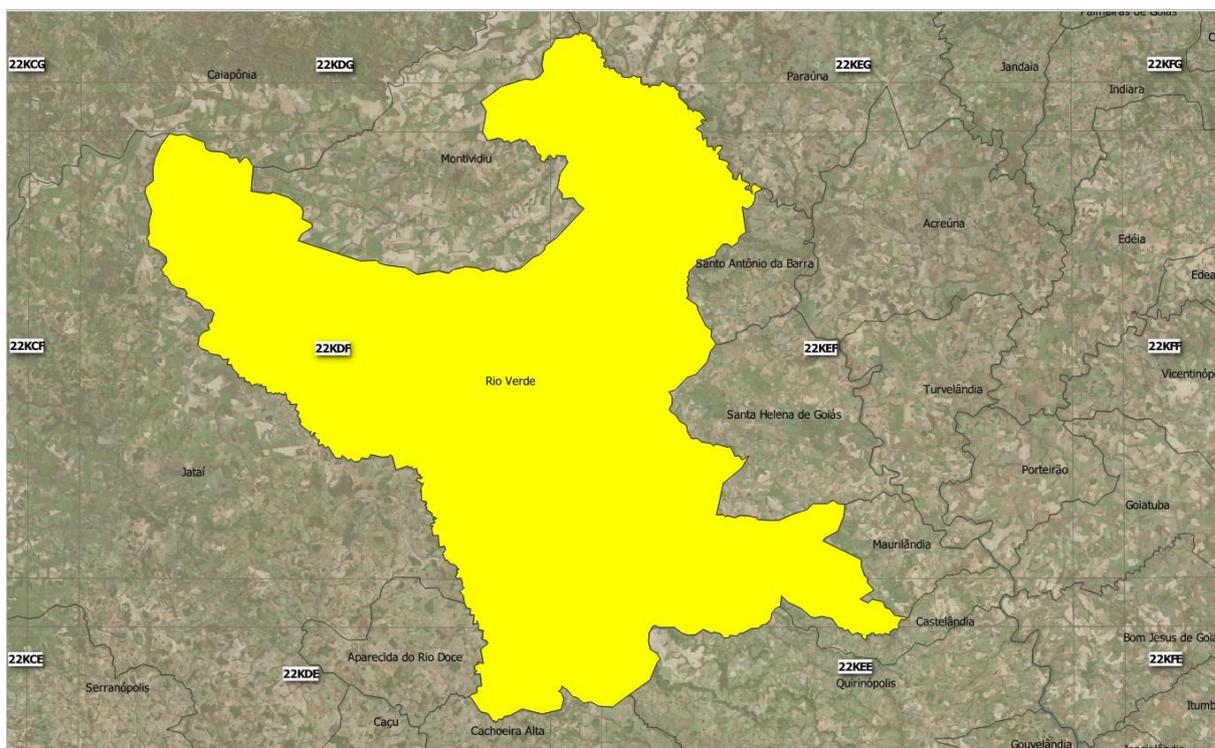
Este capítulo aborda a obtenção dos dados, sua modelagem e os métodos adotados para o desenvolvimento deste trabalho. Serão especificados, de forma detalhada, os recursos utilizados e os meios para alcançar os objetivos propostos.

3.1 Área de estudo

A área de estudo compreende a região de Rio Verde no estado de Goiás, uma das regiões com maior produção agrícola do país, cerca de R\$ 2,578 bilhões no ano de 2019 (FAEG, 2020). Sendo um dos maiores produtores de milho e soja segundo o Governo de Goiás (2020).

O tile do produto Sentinel-2 que cobre a região é identificado por 22KDF, apresentado na Figura 11.

Figura 11 - Tile escolhido: 22KDF



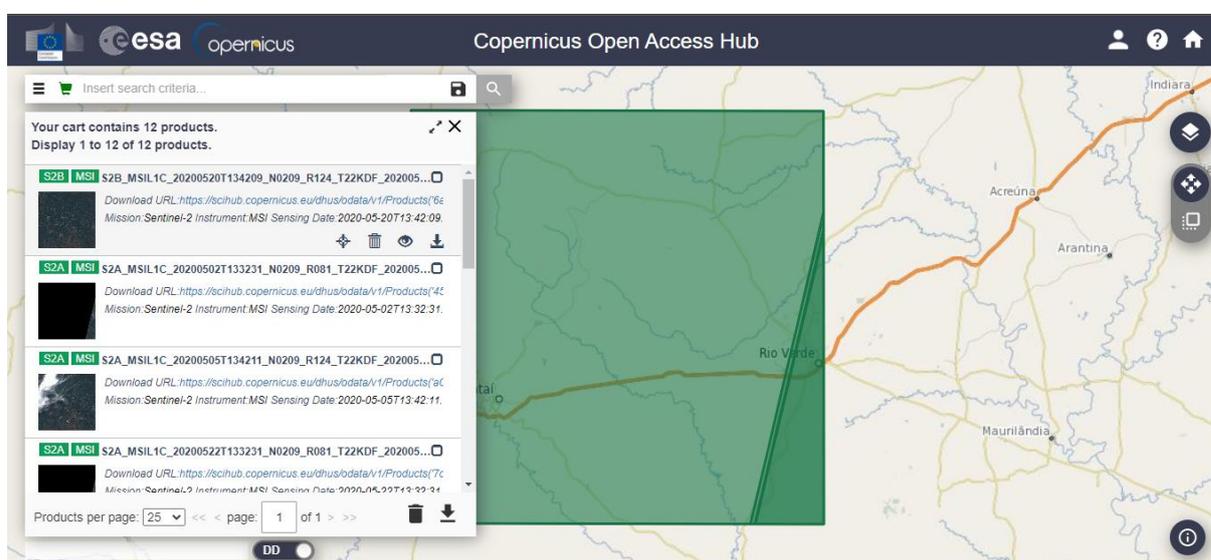
Fonte: Elaborado pelo autor.

3.2 Obtenção das imagens

Imagens ópticas da área de estudo foram obtidas gratuitamente a partir do satélite Sentinel-2 através do Portal *Copernicus Open Access Hub* da Agência Espacial Europeia (ESA), Figura 12. Apenas a banda do vermelho (banda 4) e a banda do infravermelho próximo (banda 8) foram utilizadas.

A cobertura de tempo das imagens foi de maio de 2020 a abril de 2021, que corresponde ao período de um ano. Totalizando assim, 252 imagens, 126 na banda 4 e 126 na banda 8.

Figura 12 - Portal Copernicus Open Access Hub da ESA



Fonte: Elaborado pelo autor.

3.3 Metodologia

O fluxo de trabalho consiste nas seguintes etapas:

1. Cálculo do *difference vegetation index* (NDVI) para cada imagem do conjunto de dados. Com isso das 252 imagens iniciais passou-se a ter 126 imagens em NDVI.
2. Seleção e classificação, com o auxílio do software QGIS, dos pontos modelo distribuídos espacialmente na área de estudo conforme mostra a Tabela 1 e os Anexos A, B, C, D e E.
3. Seleção e classificação, com o auxílio do software QGIS, de alguns pontos de teste dentro da área de estudo para as análises conforme mostra a Tabela 2.

4. Construção das séries com valores de NDVI de cada ponto, conforme mostra os Gráficos 1, 2 e 3, e aplicação do *Dynamic Time Warping* (DTW) para comparar o segundo conjunto de séries temporais com o primeiro.

3.3.1. QGIS

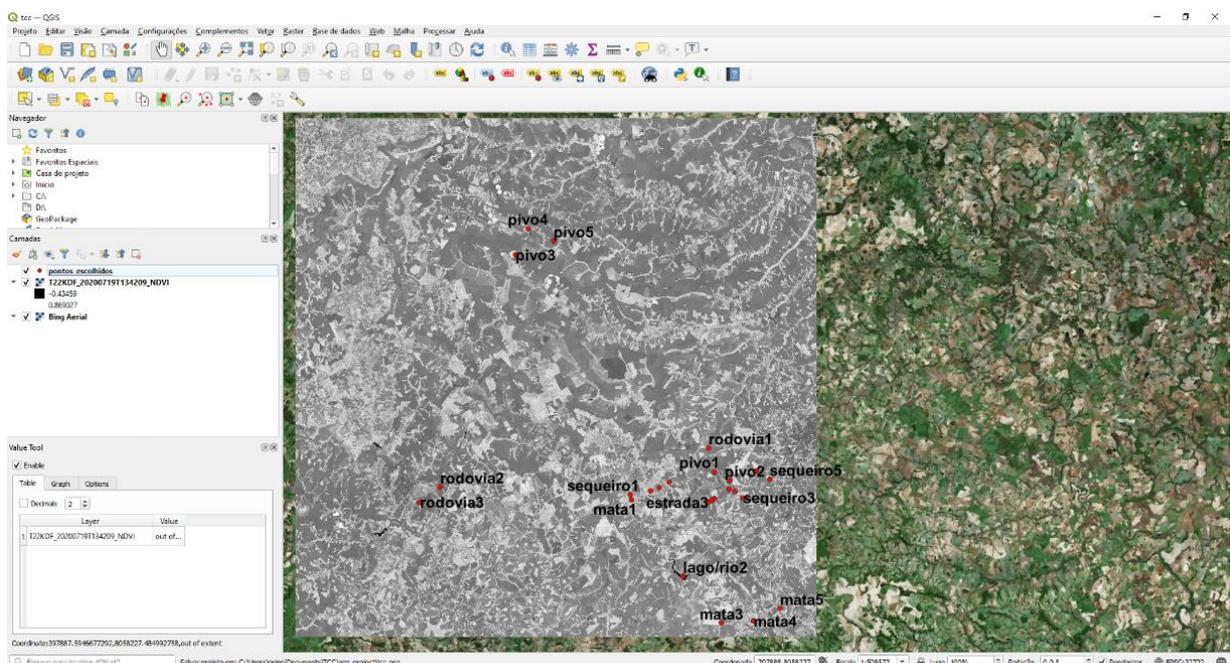
O QGIS é um *Geographic Information System* (GIS), que em português significa Sistema de Informação Geográfica (SIG). O QGIS é um projeto oficial da *Open Source Geospatial Foundation* (OSGeo), impulsionado por voluntários.

O QGIS possui diversas funcionalidades que permitem visualizar, gerir, editar, analisar e criar mapas. Neste trabalho ele foi utilizado como ferramenta de auxílio na identificação e classificação dos pontos modelo e dos pontos teste.

Conforme mostra a Figura 13, para a realização desta etapa do trabalho, foram analisadas três camadas através do QGIS. São elas:

- Camada Bing Aerial, que serviu como camada base,
- Camada em NDVI, que serviu para a análise da localização e extremidades do tile utilizado,
- Camada dos pontos escolhidos, para a análise da localização de cada ponto no tile.

Figura 13 – Uso do QGIS na análise dos pontos no tile de estudo.



Fonte: Elaborado pelo autor.

3.3.2. Cálculo do NDVI

Conforme foi dito na seção 2.2.1 cada tile, que corresponde a uma imagem, tem o tamanho aproximado de 100km por 100km, e cada pixel tem 10m por 10m. Logo cada imagem tem uma resolução de aproximadamente 10.000 pixels por 10.000 pixels. Dando o total aproximado de 100.000.000 de pixels em cada imagem.

Sendo mais preciso, a Figura 14 mostra a quantidade exata de pixels que cada imagem tem. Um total de 120.560.400 pixels.

Figura 14 – Dados de uma imagem, obtidos pelo software QGIS.

Nome	T22KDF_20200719T134209_NDVI
Caminho	C:\Users\geiso\Documents\TCC\imagens\07_2020\19\L1C_T22KDF_A017596_20200719T134212\T22KDF_20200719T134209_NDVI.tif
SRC	EPSG:32722 - WGS 84 / UTM zone 22S - Projetado
Extensão	399960.0000000000000000,7990240.0000000000000000 : 509760.0000000000000000,8100040.0000000000000000
Unidade	metros
Largura	10980
Altura	10980
tipo de dado	Float32 - Ponto flutuante de 32 bits
Descrição do driver GDAL	GTiff
Metadados do driver GDAL	GeoTIFF
Descrição do registro	C:/Users/geiso/Documents/TCC/imagens/07_2020/19/L1C_T22KDF_A017596_20200719T134212/T22KDF_20200719T134209_NDVI.tif
Compressão	
Banda 1	<ul style="list-style-type: none"> • STATISTICS_APPROXIMATE=YES • STATISTICS_MAXIMUM=0.8690265417099 • STATISTICS_MEAN=0.34395456032658 • STATISTICS_MINIMUM=-0.43458980321884 • STATISTICS_STDDEV=0.18085079119959 • STATISTICS_VALID_PERCENT=100
Mais informação	<ul style="list-style-type: none"> • AREA_OR_POINT=Area
Dimensões	X: 10980 Y: 10980 Bandas: 1
Origem	399960,8.10004e+06
Tamanho do Pixel	10,-10

Fonte: Elaborado pelo autor.

Já na seção 3.2 foi dito que para este trabalho foram utilizadas 252 imagens, 126 na banda 4 (vermelho) e 126 na banda 8 (infra vermelho próximo). Foi implementado um programa em *Python*, conforme detalhado na seção 3.3.2.2, para a construção de outras 126 imagens, mas com valores de NDVI.

3.3.2.1. Python

Python é uma linguagem de programação moderna, que foi lançada em 1991 pelo matemático e programador de computadores holandês, Guido Van Rossum. Ela possui um modelo de desenvolvimento comunitário e aberto, gerenciado pela organização *Python Software Foundation* (PYTHON SOFTWARE FOUNDATION, 2021).

Linguagem de modo geral são utilizadas para comunicação entre pessoas. Linguagens de programação também são utilizadas para a comunicação, mas entre pessoas e máquinas ou entre máquinas. As primeiras linguagens de programação começaram a surgir muito antes de 1940, naquela época eram códigos matemáticos (BERTOLINI, 2019).

Com o surgimento dos computadores a partir de 1940, linguagens de programação mais modernas foram surgindo (BERTOLINI, 2019). A maioria delas buscando simplificar a programação, facilitando a implementação de programas mais complexos.

Programas de computador são desenvolvidos, utilizando linguagem de programação, a partir de um algoritmo. Algoritmo é um procedimento, um passo a passo para obtenção da solução de um determinado problema. Em outras palavras, algoritmo é uma sequência detalhada de ações a serem tomadas para a realização de alguma tarefa (MEDINA, 2006).

O Python é uma das linguagens de programação mais fáceis de aprender e uma das que mais cresce no mundo em termos de utilização. Nos últimos anos o Python passou a ser uma das linguagens de computação mais importante em ciência de dados e aprendizado de máquina. Sendo amplamente utilizada no ambiente acadêmico e no mercado (MCKINNEY, 2018).

Para o desenvolvimento de programas em Python é necessária uma plataforma de desenvolvimento integrado, que são softwares que combinam ferramentas comuns de programação facilitando o desenvolvimento de aplicações. Este trabalho utiliza o *Jupyter Notebook*, que é uma ferramenta gratuita pertencente ao conjunto de ferramentas Python, conhecido como Anaconda.

3.3.2.2. Programa para construção das imagens em NDVI

Para a construção das imagens em NDVI foi implementado um programa em Python seguindo os seguintes passos:

1. Busca das imagens nas bandas 4 e 8, vermelho e infra vermelho próximo respectivamente, referentes ao primeiro dia do espaço de tempo adotado por este trabalho. Este passo só foi possível porque como visto na seção 3.2 as imagens foram obtidas previamente.
2. Criação de um novo arquivo para construção da nova imagem em NDVI. Ao final deste passo, o programa possui três arquivos; duas imagens referente a banda 4 e 8 e outra imagem em NDVI, porém ainda “vazia”.
3. Mapeamento das imagens em matrizes bidimensionais, onde cada posição armazena o valor referente a um pixel da imagem mapeada.
4. Varredura das matrizes executando a formulação apresentada na seção 2.2, onde a posição $[i, j]$ da matriz referente a banda 4 combinada com a posição $[i, j]$ da matriz referente a banda 8 gerou o valor em NDVI para a posição $[i, j]$ da matriz referente a imagem em NDVI.
5. Retorno ao passo 1 repetindo o processo para a imagem referente ao próximo dia. Este processo foi executado para todas as imagens obtidas.

Este processo permitiu a obtenção de outras 126 imagens, mas em NDVI, para o período de um ano. Possibilitando também a construção de séries temporais com valores em NDVI para cada pixel dentro do período adotado.

3.3.3. Classes do Problema

Nesta fase do trabalho foram selecionados 26 pontos dentro do tile de estudo e cada um foi classificado como pivô, sequeiro, mata, lago/rio, estrada ou rodovia conforme mostra a Tabela 1 e os Anexos A, B, C, D e E. Estes pontos serviram como modelo das classes de “lavoura” e “não lavoura”. As classes de “lavoura” são pivô e sequeiro, já as classes de “não lavoura” são mata, lago/rio, estrada e rodovia.

Com base nas séries temporais destes pontos, outros pontos podem ser classificados a partir da comparação deles com estes.

Tabela 1 – Pontos para o modelo.

Ponto	Latitude	Longitude	Classe	Lavoura
1	-17.861.189	-51.110.273	Pivô	Sim
2	-17.878.122	-51.080.130	Pivô	Sim
3	-17.445.403	-51.505.553	Pivô	Sim
4	-17.394.791	-51.480.549	Pivô	Sim
5	-17.418.924	-51.429.913	Pivô	Sim
6	-17.905.063	-51.278.157	Sequeiro	Sim
7	-17.899.573	-51.069.151	Sequeiro	Sim
8	-17.910.992	-51.052.994	Sequeiro	Sim
9	-17.859.928	-51.026.260	Sequeiro	Sim
10	-17.876.034	-51.000.219	Sequeiro	Sim
11	-17.915.188	-51.276.121	Mata	Não
12	-17.891.626	-51.219.731	Mata	Não
13	-18.151.576	-51.096.587	Mata	Não
14	-18.147.891	-51.032.670	Mata	Não
15	-18.123.612	-50.979.561	Mata	Não
16	-17.897.434	-51.237.050	Lago/Rio	Não
17	-18.061.806	-51.173.091	Lago/Rio	Não
18	-17.880.991	-51.200.439	Lago/Rio	Não
19	-17.913.151	-51.110.955	Estrada	Não
20	-17.895.007	-51.081.052	Estrada	Não
21	-17.920.186	-51.122.726	Estrada	Não
22	-17.916.041	-51.115.840	Estrada	Não
23	-17.916.231	-51.115.992	Estrada	Não
24	-17.816.216	-51.121.759	Rodovia	Não
25	-17.889.928	-51.656.717	Rodovia	Não
26	-17.918.355	-51.696.700	Rodovia	Não

Fonte: Elaborado pelo autor.

As classes pivô e sequeiro são classes de lavoura e as demais não. Caso a série temporal a ser comparada se aproxime de uma das classes de lavoura ela provavelmente também pertence a uma área de lavoura. Se por outro lado ela não pertencer a uma área de lavoura ela se aproximará mais de uma das classes “não lavoura”.

Esta classificação foi feita através das imagens de satélite e das imagens em NDVI, com o auxílio do software QGIS.

3.3.3.1. Pivô

O pivô central de irrigação é um sistema de agricultura irrigada. Conforme mostra a Figura 15, uma área circular projetada no solo é irrigada através de uma tubulação, que forma um raio e gira em toda a área circular (PIVÔ CENTRAL DE IRRIGAÇÃO, 2021).

Figura 15 – Pivô.



Fonte: GOOGLE MAPS, 2021.

Esse sistema foi desenvolvido em 1948 por um agricultor chamado Frank Zybach, de Nebraska (MADER, 2010). E hoje é o principal sistema de agricultura irrigada do Brasil (EMBRAPA, 2021).

3.3.3.2. Sequeiro

Derivada da palavra "seco", a expressão sequeiro refere-se a uma plantação em solo firme, onde a pluviosidade é menor. Esse sistema de agricultura é utilizado no cerrado e no sertão nordestino do Brasil (AGRICULTURA DE SEQUEIRO, 2020).

Conforme pode ser visto na Figura 16, diferentemente do pivô que tem uma forma circular, o sequeiro na maior parte tem uma forma poligonal.

Figura 16 – Sequeiro.



Fonte: GOOGLE MAPS, 2021.

3.3.3.3. Mata

Mata é uma vegetação florestal, área com uma concentração maior de árvores (EMBRAPA, 2021).

Em imagens de satélite é perceptível a intensidade da cor verde, conforme mostra a Figura 17. Em áreas de mata, as mudanças na densidade da vegetação são mais lentas. Tornando suas séries temporais mais contínuas com valores mais altos de NDVI.

Figura 17 – Mata.



Fonte: GOOGLE MAPS, 2021.

3.3.3.4. Lago/Rio

Neste trabalho foram classificadas como lago/rio as áreas com concentração de água. Ao olhar uma imagem de satélite podemos facilmente confundi-la com uma região de vegetação, mas em uma imagem em NDVI é nítido a tonalidade mais escura. Isso ocorre porque conforme foi dito na seção 2.2, a água tem valores negativos de NDVI. Essa comparação pode ser vista na Figura 18.

Figura 18 – Comparação de imagens de uma mesma área com concentração de água. Lado esquerdo imagem do mapa Bing e lado direito imagem em NDVI.



Fonte: Elaborado pelo autor.

3.3.3.5. Estrada

"Via rural não pavimentada" essa é a definição de estrada, conforme o Código de Trânsito do Brasil, ao contrário de uma rodovia, que seria pavimentada. Mas a estrada não é um simples caminho, ela é concebida para a circulação de veículos de transporte (ESTRADA, 2020).

Assim como a definição acima, neste trabalho, foi considerado como estrada toda via não pavimentada, também popularmente conhecida como estrada de chão. Na seção 2.2 foi informado que para solo nu, como é o caso das estradas, os valores de NDVI são próximos de zero.

3.3.3.6. Rodovia

Conforme mencionando na seção anterior, o Código de Trânsito do Brasil

considera como rodovia as vias rurais pavimentadas. Neste trabalho também foram classificadas como rodovia tais vias.

Mas vale lembrar que a seção 2.2 diz que o concreto tem valores de NDVI próximo de zero. Isso vai aproximar uma rodovia de uma rua urbana ou de áreas com concreto. Mas irá distanciar de áreas com vegetação, tornando um falso positivo mais difícil de ocorrer em comparações com uma lavoura.

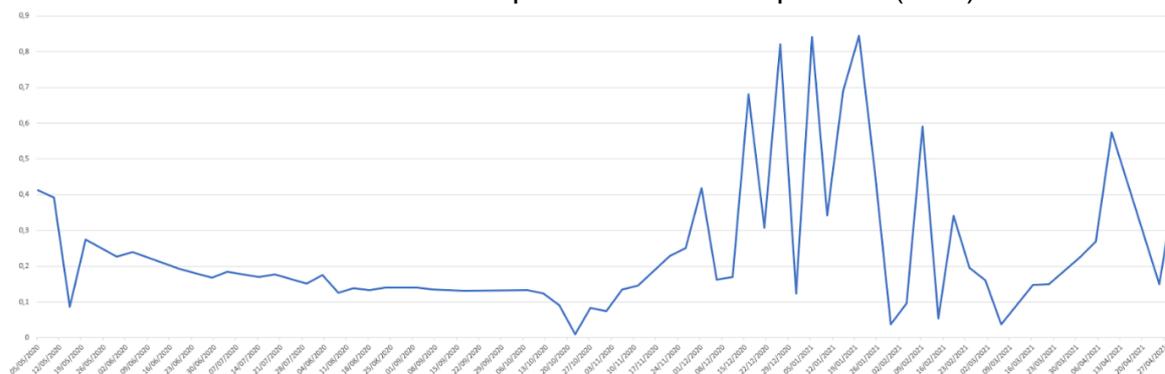
3.3.4. Construção das séries temporais do modelo.

Na seção 3.3.1 foi dito que para cada pixel de cada imagem foi calculado o valor do NDVI e na seção 3.3.2 diz que 26 pontos foram selecionados e classificados. De posse destes dados, foi construído a série temporal em NDVI de cada um dos 26 pontos, através do programa descrito na seção seguinte.

Exemplos dessas séries temporais podem ser vistos nos Gráficos 1, 2 e 3. Estas séries serviram como modelo para comparação dos pontos de teste, através do DTW.

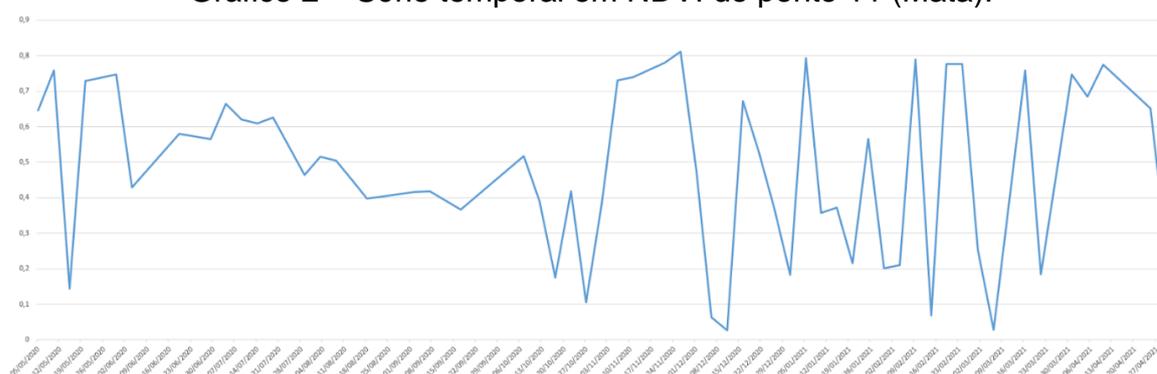
O Gráfico 1 pertence a uma série temporal em NDVI de um Pivô. Nele podemos ver que em um determinado espaço de tempo os valores permanecem próximos de 0 indicando a ausência ou pouca presença de vegetação. Posteriormente esses valores mudam, ficando mais próximos de 1, indicando que a densidade vegetal daquela área aumentou, provavelmente houve uma plantação nesse período.

Gráfico 1 – Série temporal em NDVI do ponto 1 (Pivô).



O Gráfico 2 pertence a uma série temporal em NDVI de uma Mata. Geralmente áreas de mata não sofrem grandes alterações repentinas na sua densidade vegetal. Isso explica o fato de os valores da série permanecerem mais próximos de 1.

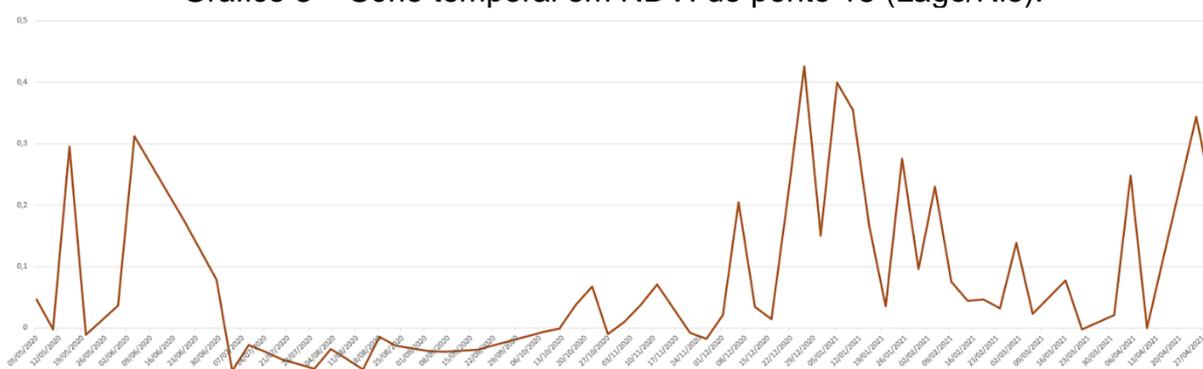
Gráfico 2 – Série temporal em NDVI do ponto 11 (Mata).



Fonte: Elaborado pelo autor.

O Gráfico 3 pertence a classe Lago/Rio, uma área com uma concentração de água. Nela podemos perceber que os valores permanecem na maior parte próximos de 0, em alguns instantes com valores negativos.

Gráfico 3 – Série temporal em NDVI do ponto 18 (Lago/Rio).



Fonte: Elaborado pelo autor.

Em todos os gráficos é possível notar mudanças repentinas nos valores. Nos gráficos de Pivô e de Mata os valores repentinamente passam a ter valores mais próximo de 0 e depois retornam a média de valor presente naquele espaço de tempo. Já no gráfico de Lago/Rio a mudança é inversa, os valores sobem para valores mais próximos de 0,5. Esse comportamento é reflexo da perda de dados referente a presença de nuvens nas imagens usadas para construção das séries

temporais.

3.3.5. Programa para construção das séries temporais

Para a construção das séries temporais com valores em NDVI foi implementado um programa em *Python* seguindo os seguintes passos:

1. Busca da imagem em NDVI referente ao primeiro dia do espaço de tempo adotado por este trabalho. Este passo só foi possível porque como visto na seção 3.3.2 as imagens foram geradas previamente.
2. Mapeamento da imagem em uma matriz bidimensional, onde cada posição armazena o valor em NDVI referente a um pixel da imagem mapeada.
3. Implementação de um vetor onde será armazenado os valores de NDVI do ponto, referente a cada imagem que corresponde a uma data. Formando assim a série temporal de cada ponto.
4. Busca do pixel, na imagem, correspondente a latitude e longitude de cada ponto selecionado e conseqüentemente a obtenção do valor em NDVI.
5. Armazenamento do valor obtido no vetor referente a série temporal.
6. Retorno ao passo 1 repetindo o processo para a imagem referente ao próximo dia. Este processo foi executado para todas as imagens em NDVI.

3.3.6. Amostras de teste

Assim como os pontos que serviram como modelo, outros 26 pontos de teste distintos foram selecionados dentro do tile de estudo e classificados também como pivô, sequeiro, mata, lago/rio, estrada e rodovia conforme mostra a Tabela 2.

Tabela 2 – Pontos para teste.

Ponto	Latitude	Longitude	Classe	Lavoura
1	-17.572.252	-51.121.196	Pivô	Sim
2	-17.449.494	-51.489.737	Pivô	Sim
3	-17.397.791	-51.634.310	Pivô	Sim
4	-17.390.869	-51.637.486	Pivô	Sim
5	-17.252.176	-51.595.554	Pivô	Sim
6	-17.233.698	-51.591.225	Sequeiro	Sim

Ponto	Latitude	Longitude	Classe	Lavoura
7	-17.264.725	-51.432.589	Sequeiro	Sim
8	-17.413.052	-51.535.127	Sequeiro	Sim
9	-17.413.052	-51.535.127	Sequeiro	Sim
10	-17.413.052	-51.535.127	Sequeiro	Sim
11	-17.748.716	-51.375.105	Mata	Não
12	-17.751.743	-51.370.036	Mata	Não
13	-17.783.642	-51.375.153	Mata	Não
14	-17.566.228	-51.134.099	Mata	Não
15	-17.562.104	-51.150.738	Mata	Não
16	-18.062.224	-51.172.688	Lago/Rio	Não
17	-18.002.775	-51.212.971	Lago/Rio	Não
18	-17.881.021	-51.200.758	Lago/Rio	Não
19	-17.844.442	-51.340.657	Estrada	Não
20	-17.844.794	-51.340.496	Estrada	Não
21	-18.014.516	-51.557.091	Estrada	Não
22	-17.876.409	-51.018.154	Estrada	Não
23	-17.883.789	-51.018.759	Estrada	Não
24	-17.824.326	-50.992.000	Rodovia	Não
25	-17.821.955	-51.004.348	Rodovia	Não
26	-17.815.045	-51.100.171	Rodovia	Não

Fonte: Elaborado pelo autor.

3.3.7. Construção das séries temporais de teste.

Utilizando o mesmo processo da seção 3.3.4, séries temporais foram construídas para cada ponto de teste.

Através do programa descrito na seção a seguir, cada série temporal de teste foi comparada com cada série temporal modelo e analisado a assertividade do DTW em dizer de qual série temporal modelo cada série temporal de teste se aproxima mais e conseqüentemente dizer se é ou não uma área cultivada.

3.3.8. Programa para a comparação entre as séries temporais.

Para a comparação entre as séries temporais foi implementado um programa em Python seguindo os seguintes passos:

1. Implementação de um vetor onde cada posição armazena outro vetor

referente a cada série temporal modelo com valores em NDVI. Este passo só foi possível porque como visto na seção 3.3.3 as séries temporais em formato de vetores foram geradas previamente.

2. Implementação de um vetor seguindo os mesmos critérios do passo anterior, mas para o armazenamento dos valores das séries temporais teste. Este passo também só foi possível porque as séries temporais em formato de vetores foram geradas previamente, conforme visto na seção 3.3.6.
3. Varredura do vetor com os valores das séries temporais teste comparando os valores de cada posição, que também são vetores, com cada posição do vetor com os valores das séries temporais modelo. Para essa comparação foi implementado a recorrência descrita pelo DTW na seção 2.6, utilizando a PD como solução algorítmica exposto na seção 2.5. Neste passo foi identificado de qual série temporal modelo cada série temporal teste se aproximou mais.
4. Geração do resultado. O resultado possui a seguinte estrutura:

classificação, classe pertencente, classe comparação. Onde:

- *classificação*, mostra uma resposta positiva (Sim), caso a série em comparação se aproxime mais de uma classe “lavoura” ou uma resposta negativa (Não), caso a série em comparação se aproxime mais de uma classe “não lavoura”.
- *classe pertencente*, mostra a classe na qual a série temporal teste pertence.
- *classe comparação*, mostra a classe na qual a série temporal teste se aproximou mais.

4. ANÁLISE E DISCUSSÃO

O objetivo deste projeto é identificar se um determinado ponto no mapa, dentro do tile de estudo, é ou não uma área cultivada, ou seja, uma área de lavoura.

Primeiramente foi realizado a comparação, através do *Dynamic Time Warping* (DTW), das 26 séries temporais de teste com as 26 séries temporais modelo. E conforme mostra a Tabela 3, para esse teste obteve-se 100% de acerto.

Tabela 3 – Resultado do teste com as 26 séries de teste.

Ponto	Ponto é Lavoura?	O Ponto é:	O DTW diz que é Lavoura?	O DTW diz que é:
1	SIM	Pivô	SIM	Sequeiro
2	SIM	Pivô	SIM	Pivô
3	SIM	Pivô	SIM	Pivô
4	SIM	Pivô	SIM	Sequeiro
5	SIM	Pivô	SIM	Pivô
6	SIM	Sequeiro	SIM	Sequeiro
7	SIM	Sequeiro	SIM	Sequeiro
8	SIM	Sequeiro	SIM	Sequeiro
9	SIM	Sequeiro	SIM	Sequeiro
10	SIM	Sequeiro	SIM	Sequeiro
11	NÃO	Mata	NÃO	Mata
12	NÃO	Mata	NÃO	Mata
13	NÃO	Mata	NÃO	Mata
14	NÃO	Mata	NÃO	Mata
15	NÃO	Mata	NÃO	Mata
16	NÃO	Lago/Rio	NÃO	Lago/Rio
17	NÃO	Lago/Rio	NÃO	Rodovia
18	NÃO	Lago/Rio	NÃO	Lago/Rio
19	NÃO	Estrada	NÃO	Rodovia
20	NÃO	Estrada	NÃO	Estrada
21	NÃO	Estrada	NÃO	Estrada
22	NÃO	Estrada	NÃO	Rodovia
23	NÃO	Estrada	NÃO	Estrada
24	NÃO	Rodovia	NÃO	Estrada
25	NÃO	Rodovia	NÃO	Rodovia
26	NÃO	Rodovia	NÃO	Rodovia
Acerto (%)			100	77

Fonte: Elaborado pelo autor.

A fim de analisar o quanto anomalias nos dados, como a presença de nuvens, podem diminuir a assertividade, foi inserido aleatoriamente nas séries de teste

valores médios que representam a presença de nuvens.

Foram realizados testes inserindo 5, 10, 25 e 30 pixels com nuvens, conforme mostra a Tabela 4. Percebe-se que, à medida que a quantidade desses pixels com nuvens foram aumentando, a assertividade foi diminuindo.

Tabela 4 – Resultado dos testes com 5, 10, 25 e 30 pixels de chuva a mais em cada série de teste.

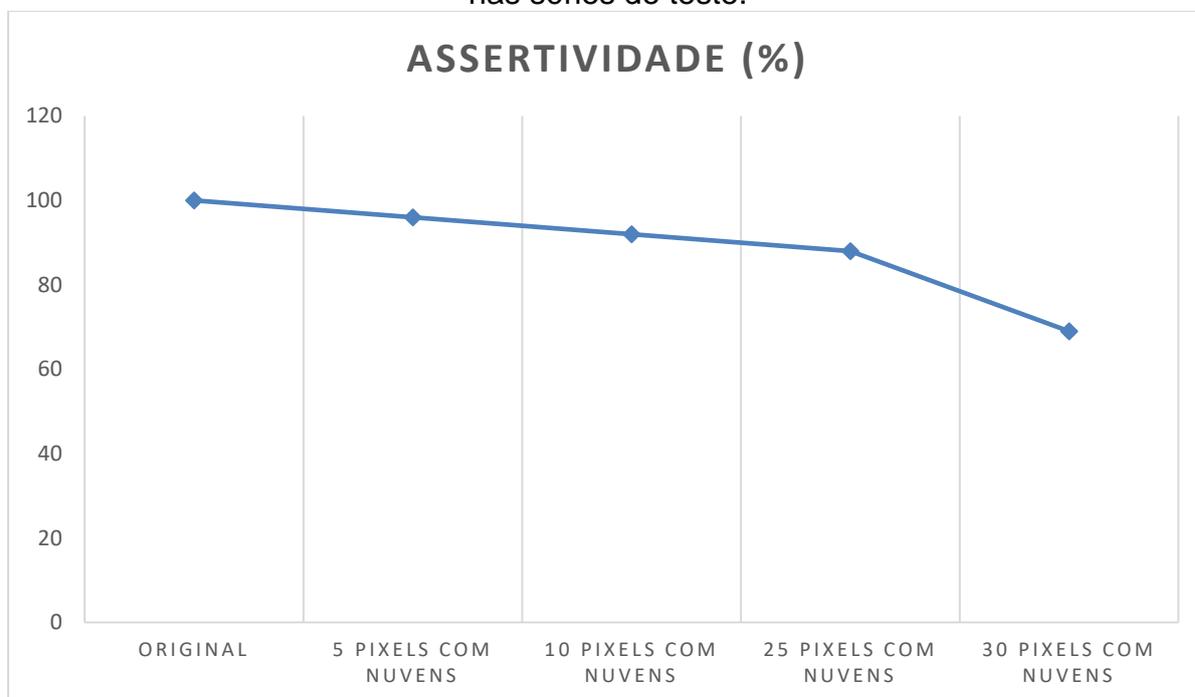
Ponto	Ponto é Lavoura?	O Ponto é:	5 pixels com nuvem		10 pixels com nuvem		25 pixels com nuvem		30 pixels com nuvem	
			O DTW diz que é Lavoura?	O DTW diz que é:	O DTW diz que é Lavoura?	O DTW diz que é:	O DTW diz que é Lavoura?	O DTW diz que é:	O DTW diz que é Lavoura?	O DTW diz que é:
1	SIM	Pivô	SIM	Sequeiro	SIM	Sequeiro	SIM	Pivô	NÃO	Rodovia
2	SIM	Pivô	SIM	Pivô	SIM	Pivô	SIM	Sequeiro	SIM	Sequeiro
3	SIM	Pivô	SIM	Pivô	SIM	Pivô	SIM	Pivô	SIM	Pivô
4	SIM	Pivô	SIM	Sequeiro	SIM	Pivô	SIM	Pivô	SIM	Pivô
5	SIM	Pivô	SIM	Pivô	SIM	Pivô	SIM	Pivô	SIM	Pivô
6	SIM	Sequeiro	SIM	Sequeiro	SIM	Sequeiro	SIM	Pivô	SIM	Pivô
7	SIM	Sequeiro	SIM	Sequeiro	SIM	Pivô	SIM	Sequeiro	NÃO	Rodovia
8	SIM	Sequeiro	SIM	Sequeiro	SIM	Sequeiro	NÃO	Estrada	NÃO	Rodovia
9	SIM	Sequeiro	SIM	Sequeiro	SIM	Sequeiro	SIM	Sequeiro	NÃO	Estrada
10	SIM	Sequeiro	SIM	Sequeiro	SIM	Sequeiro	NÃO	Lago/Rio	NÃO	Estrada
11	NÃO	Mata	NÃO	Mata	NÃO	Mata	NÃO	Mata	SIM	Pivô
12	NÃO	Mata	SIM	Sequeiro	SIM	Sequeiro	NÃO	Mata	SIM	Sequeiro
13	NÃO	Mata	NÃO	Mata	NÃO	Mata	SIM	Pivô	SIM	Sequeiro
14	NÃO	Mata	NÃO	Mata	SIM	Sequeiro	NÃO	Mata	NÃO	Mata
15	NÃO	Mata	NÃO	Mata	NÃO	Mata	NÃO	Mata	NÃO	Mata
16	NÃO	Lago/Rio	NÃO	Lago/Rio	NÃO	Lago/Rio	NÃO	Lago/Rio	NÃO	Lago/Rio
17	NÃO	Lago/Rio	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Rodovia
18	NÃO	Lago/Rio	NÃO	Lago/Rio	NÃO	Lago/Rio	NÃO	Lago/Rio	NÃO	Lago/Rio
19	NÃO	Estrada	NÃO	Rodovia	NÃO	Rodovia	NÃO	Estrada	NÃO	Rodovia
20	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada
21	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Rodovia
22	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada
23	NÃO	Estrada	NÃO	Rodovia	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada
24	NÃO	Rodovia	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada
25	NÃO	Rodovia	NÃO	Rodovia	NÃO	Estrada	NÃO	Estrada	NÃO	Estrada
26	NÃO	Rodovia	NÃO	Rodovia	NÃO	Rodovia	NÃO	Rodovia	NÃO	Rodovia
Acerto (%)			96	73	92	69	88	65	69	42

Fonte: Elaborado pelo autor.

Conforme mostra o Gráfico 4, inicialmente a assertividade foi de 100%. Com a inserção de 30 pixels com nuvens essa assertividade caiu para 69%, mostrando que,

principalmente em regiões do planeta onde a presença de nuvens é mais intensa será necessário um tratamento nos dados.

Gráfico 4 – Assertividade do DTW conforme dados “sujos” foram sendo inseridos nas séries de teste.



Fonte: Elaborado pelo autor.

É possível notar também que conforme mais pixels com nuvens foram inseridos, os pontos de mata tendem a serem confundidos com lavoura e lavouras com áreas de menor densidade de vegetação.

Já os pontos de estrada, rodovia e lago/rio continuaram sendo classificados como “não lavoura”. Ou seja, nos testes realizados, para essa classe de pontos, um falso positivo não aconteceu. E provavelmente essa tendência se manterá mesmo com inserção de mais pontos com nuvens.

Isso possivelmente ocorre pelo fato de que com mais pixels com nuvens os valores mais próximos de zero aumentam. Conforme a quantidade de pixels com nuvens aumenta os valores nas séries temporais de mata, que estão mais próximos de um, passam a ter em determinados momentos valores próximos a zero. Essa oscilação, provavelmente, é o motivo para que o DTW confunda uma série temporal de mata com uma lavoura.

Teoricamente não seria necessário mais de um ponto de cada classe modelo. Mas neste trabalho optou-se em selecionar mais de um ponto de cada classe

modelo pois diferentes tipos de cultura (soja, milho, arroz, entre outras) possuem diferentes tipos de comportamento.

Logo, uma quantidade menor de pontos por classe modelo, resulta em uma assertividade menor nas comparações. Essa diminuição da assertividade pode ser vista nos resultados da Tabela 5, onde o teste foi realizado com apenas um ponto modelo de cada classe e a assertividade caiu para 92%.

Tabela 5 – Resultado do teste com uma única amostra de referência de cada classe.

Ponto	Ponto é Lavoura?	O Ponto é:	O DTW diz que é Lavoura?	O DTW diz que é:
1	SIM	Pivô	SIM	Pivô
2	SIM	Pivô	SIM	Pivô
3	SIM	Pivô	NÃO	Mata
4	SIM	Pivô	SIM	Pivô
5	SIM	Pivô	SIM	Pivô
6	SIM	Sequeiro	SIM	Pivô
7	SIM	Sequeiro	SIM	Pivô
8	SIM	Sequeiro	SIM	Pivô
9	SIM	Sequeiro	SIM	Pivô
10	SIM	Sequeiro	SIM	Pivô
11	NÃO	Mata	NÃO	Mata
12	NÃO	Mata	SIM	Sequeiro
13	NÃO	Mata	NÃO	Mata
14	NÃO	Mata	NÃO	Mata
15	NÃO	Mata	NÃO	Mata
16	NÃO	Lago/Rio	NÃO	Estrada
17	NÃO	Lago/Rio	NÃO	Rodovia
18	NÃO	Lago/Rio	NÃO	Lago/Rio
19	NÃO	Estrada	NÃO	Rodovia
20	NÃO	Estrada	NÃO	Estrada
21	NÃO	Estrada	NÃO	Estrada
22	NÃO	Estrada	NÃO	Rodovia
23	NÃO	Estrada	NÃO	Rodovia
24	NÃO	Rodovia	NÃO	Estrada
25	NÃO	Rodovia	NÃO	Estrada
26	NÃO	Rodovia	NÃO	Rodovia
		Acerto (%)	92	50

Fonte: Elaborado pelo autor.

Este trabalho abre uma série de pesquisas no âmbito do monitoramento da superfície terrestre. Outros trabalhos podem ser desenvolvidos a fim de melhorar ainda mais os resultados em larga escala com o uso do DTW. Uma sugestão seria abordar o uso do DTW com restrição de tempo.

Além da classificação da superfície terrestre em áreas cultivadas ou não, que foi o objetivo proposto e alcançado por este trabalho, uma sugestão também seria a classificação das culturas (soja, milho, arroz, entre outras) existente nestas áreas.

Outro ponto a ser trabalhado, é o dimensionamento das áreas cultivadas. Assim será possível prevê a quantidade que determinada cultura está plantada e até mesmo prevê quanto de determinada cultura será colhida em determinado tempo.

Mas novas pesquisas não precisam, necessariamente, se limitar ao monitoramento de terras agrícolas. A abordagem adotada neste trabalho pode ser utilizada e evoluída em outros trabalhos como o monitoramento de desmatamentos e o mapeamento de desastres.

5. CONCLUSÃO

Este trabalho propôs classificar, através de imagens de satélite, áreas cultivadas, ou seja, áreas de lavoura. Visto que esse tipo de análise auxilia no processo de monitoramento da superfície terrestre. Contribuindo principalmente para a segurança alimentar, compreensão da produtividade e apoio às políticas agrícolas.

Através do *Dynamic Time Warping* (DTW) foi possível comparar séries temporais modelo em *difference vegetation index* (NDVI) com séries temporais teste também em NDVI. Estas séries foram geradas a partir de imagens obtidas do Sentinel 2, pertencentes ao tile identificado por 22KDF, correspondente a região do município de Rio Verde no estado de Goiás.

Ao obter os valores de NDVI através de cada par de imagens, vermelho e infra vermelho próximo, foi possível a construção de séries temporais de determinados pontos no tile de estudo para classificá-las como áreas cultivadas.

Porém o mapeamento de terras agrícolas baseado em análise de séries temporais obtidas através de imagens de satélites enfrenta uma série de limitações. Para lidar com esses desafios este trabalho utilizou o DTW como ferramenta de comparação entre as séries temporais de teste e as séries temporais modelo. O DTW foi escolhido por ser uma solução eficiente para lidar com os desafios na análise de séries temporais de terras agrícolas (PETITJEAN et al., 2012). Ele além de ser capaz de comparar séries temporais de tamanho variável é robusto para mudanças e distorções em toda a dimensão do tempo (CUTURI et al, 2017).

Os resultados demonstram que a classificação de áreas cultivadas através de imagens de satélite é possível. E que o DTW é uma ferramenta eficaz no processo de comparação entre séries temporais de terras agrícolas. Pois o DTW foi capaz de identificar séries temporais de lavoura, mesmo estas series contendo dados perdidos pela influência de nuvens e possuindo tamanhos distintos. Os resultados só começaram a apresentar piora quando dados “sujos” foram inseridos gradativamente ou quando a quantidade de séries modelo de cada classe foi reduzida a uma.

Diante dos resultados obtidos é possível afirmar que este trabalho alcançou seu objetivo principal, que é classificar áreas cultivadas através da análise de imagens de satélite, e os objetivos específicos. Demonstrando também que o modelo adotado foi capaz de distinguir até mesmo entre as diferentes classes, como por exemplo a distinção de séries temporais de sequeiros de séries temporais de pivôs.

Este trabalho demonstrou sua eficiência para o mapeamento de áreas cultivadas. No entanto, outras aplicações, como o monitoramento de desmatamentos, o mapeamento de desastres ou o mapeamento de culturas agrícolas podem se beneficiar com o uso dessa abordagem.

REFERÊNCIAS

AGOSTINHO. **Confissões**. São Paulo: Abril Cultural, 1973.

AGRICULTURA DE SEQUEIRO. In: WIKIPÉDIA, a enciclopédia livre. Flórida: Wikimedia Foundation, 2020. Disponível em: <https://pt.wikipedia.org/w/index.php?title=Agricultura_de_sequeiro&oldid=58324933>. Acesso em: 22 mai. 2020.

BAYMA, A. P. **ANÁLISE DO POTENCIAL DE SÉRIES TEMPORAIS DE ÍNDICES DE VEGETAÇÃO (NDVI E EVI) DO SENSOR MODIS PARA DETECÇÃO DE DESMATAMENTOS NO BIOMA CERRADO**. Brasília: Dissertação de Mestrado nº 079, 2015, 99p.

BELLMAN, Richard; KALABA, Robert. **Dynamic programming and statistical communication theory**. Proceedings of the National Academy of Sciences of the United States of America, v. 43, n. 8, p. 749, 1957.

BERTOLINI, C. et al. **LINGUAGEM DE PROGRAMAÇÃO I**. Santa Maria: UAB/NTE/UFSM, 2019.

BRAZIL DATA CUBE. **Brazil Data Cube**. 2021. Disponível em: <<http://brazildatacube.org/en/about-brazil-data-cube/>>. Acesso em: 16 nov. 2021

COSTA, F. H. S.; SOUZA FILHO, C. R.; RISSO, A. **Análise temporal de NDVI e mapas potencias naturais de erosão na região do Vale do Ribeira, São Paulo**. 2007. Disponível em: <<http://urlib.net/rep/dpi.inpe.br/sbsr@80/2006/11.16.02.22>>. Acesso em: 30 mai. 2021

CSILLIK, O. et al. **Object-Based Time-Constrained Dynamic Time Warping Classification of Crops Using Sentinel-2**. Remote Sensing, v. 11, n. 10, p. 1257, 27 maio 2019.

CUTURI M.; BLONDEL M.. **Soft-DTW: a differentiable loss function for time-series**. In: Proceedings of the 34th International Conference on Machine Learning, Sydney, NSW, Australia, v. 70, p. 894–903, 2017.

DEBIASI, P.; ECKHARDT, R. R.; CASTOLLDI, G.; MADRUGA, R.; COUTINHO, A. **Fusão de imagens MODIS com NDVI do Landsat para a classificação de áreas de cultivo de soja**. 2007. Disponível em: <<http://urlib.net/rep/dpi.inpe.br/sbsr@80/2006/11.15.17.45>>. Acesso em: 30 mai. 2021.

DYNAMIC TIME WARPING. In: WIKIPÉDIA, a enciclopédia livre. Flórida: Wikimedia Foundation, 2016. Disponível em: <https://pt.wikipedia.org/w/index.php?title=Dynamic_time_warping&oldid=45956112>. Acesso em: 17 nov. 2021.

EARTH OBSERVATORY. **Normalized Difference Vegetation Index (NDVI)**. 2000. Disponível em:

<https://earthobservatory.nasa.gov/features/MeasuringVegetation/measuring_vegetation_2.php>. Acesso em: 30 mai. 2021

EMBRAPA. **SENTINEL - Missão Sentinel**. 2020. Disponível em: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/sentinel>>. Acesso em: 31 mar. 2021.

EMBRAPA. **Área irrigada por pivôs centrais no Brasil atinge 1,6 milhão de hectares**. 2021. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/59843654/area-irrigada-por-pivos-centrais-no-brasil-atinge-16-milhao-de-hectares>>. Acesso em: 24 nov. 2021.

EMBRAPA. **Mata Ciliar**. 2021. Disponível em: <<https://www.embrapa.br/cerrados/colecao-entomologica/bioma-cerrado/mata-ciliar>>. Acesso em: 25 nov. 2021.

ELVIDGE, C. D.; CHEN, Z. **Comparison of broadband and narrow-band red and near-infrared vegetation indices**. In: Remote Sensing of Environment, New York, USA, v. 54, p. 38-48, 1995.

ESTRADA. In: WIKIPÉDIA, a enciclopédia livre. Flórida: Wikimedia Foundation, 2020. Disponível em: <<https://pt.wikipedia.org/w/index.php?title=Estrada&oldid=58390124>>. Acesso em: 25 nov. 2021.

FAEG. **Estudo do Mapa mostra como municípios com alta produção agrícola impactam PIB**. 2020. Disponível em: <<https://sistemafaeg.com.br/faeg/noticias/ditr/-estudo-do-mapa-mostra-como-municipios-com-alta-producao-agricola-impactam-pib>>. Acesso em: 30 ago. 2021.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002.

GITELSON, A. et al. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289-298, 1996.

GOOGLE MAPS. Disponível em: <>. Acesso em: 25 nov. 2021.

GOOGLE PUBLIC CLOUD DATA. **Dados da Sentinel-2**. 2021. Disponível em: <<https://cloud.google.com/storage/docs/public-datasets/sentinel-2>>. Acesso em: 11 nov. 2021.

GOVERNO DE GOIAS. **Rio Verde é 2º maior produtor de milho do Brasil**. 2020. Disponível em: <<https://www.goias.gov.br/servico/90-agricultura/123168-rio-verde-%C3%A9-2%C2%BA-maior-produtor-de-milho-do-brasil.html>>. Acesso em: 30 ago. 2021.

HUETE A. et al. **Overview of the radiometric and biophysical performance of the MODIS vegetation indices**. 2002. Disponível em: <[https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)>. Acesso em: 17 dez. 2021.

JIANG, Z et al. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833-3845, 2008.

MADER, S.. **Center pivot irrigation revolutionizes agriculture**. In: The Fence Post Magazine. v. 6, p. 2012, 2010.

MAUS, V., CAMARA, G., CARTAXO, R., SANCHEZ, A., RAMOS, M., and QUEIROZ, G. (2016). **A time-weighted dynamic time warping method for land-use and land-cover mapping**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 9(8):3729 – 3739

MCKINNEY, W. **Python para análise de dados**: Tratamento de dados com Pandas, NumPy e IPython. São Paulo: Novatec Editora, 2018.

MEDINA, M.; FERTIG, C. **Algoritmos e programação**: teoria e prática. São Paulo: Novatec Editora, 2015.

MELO, E. T.; SALES, M. C. L.; OLIVEIRA, J. G. B. de. **APLICAÇÃO DO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI) PARA ANÁLISE DA DEGRADAÇÃO AMBIENTAL DA MICROBACIA HIDROGRÁFICA DO RIACHO DOS CAVALOS, CRATEÚS-CE**. 2011. Disponível em: <<https://revistas.ufpr.br/raega/article/view/24919/16717>>. Acesso em: 05 mai. 2021. PYTHON SOFTWARE FOUNDATION, 2021. Disponível em: <<https://www.python.org/psf/>>. Acesso em: 16 dez. 2021.

PETITJEAN, F., INGLADA, J., GANÇARSKI, P.. **Satellite image time series analysis under time warping**. IEEE Trans. Geosci. Remote Sens. 50, 3081–3095, 2012.

PETTORELLI, N.. **The normalized difference vegetation index**. Oxford University Press, 2013.

PIVÔ CENTRAL DE IRRIGAÇÃO. In: WIKIPÉDIA, a enciclopédia livre. Flórida: Wikimedia Foundation, 2021. Disponível em: <https://pt.wikipedia.org/w/index.php?title=Piv%C3%B4_central_de_irriga%C3%A7%C3%A3o&oldid=60597934>. Acesso em: 8 mar. 2021.

PONZONI, F. J.; SHIMABUKURO, Y, E; KUPLICH, T. M. **Sensoriamento remoto no estudo da vegetação 2. ed**. São Jose dos Campos: Oficina de Texto, 2012, 160p.

THE EUROPEAN SPACE AGENCY. **Sentinel-2**. 2021. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 31 mar. 2021.

THE EUROPEAN SPACE AGENCY. **The Sentinel missions**. 2021. Disponível em: <http://www.esa.int/Applications/Observing_the_Earth/Copernicus/Overview4>. Acesso em: 31 mar. 2021.

THE EUROPEAN SPACE AGENCY. **Land Monitoring**. 2021. Disponível em:

<<https://sentinel.esa.int/web/sentinel/missions/sentinel-2/thematic-areas-and-services/land-monitoring>>. Acesso em: 31 mar. 2021.

THE EUROPEAN SPACE AGENCY. **Product Types**. 2021. Disponível em: <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/product-types>>. Acesso em: 11 nov. 2021.

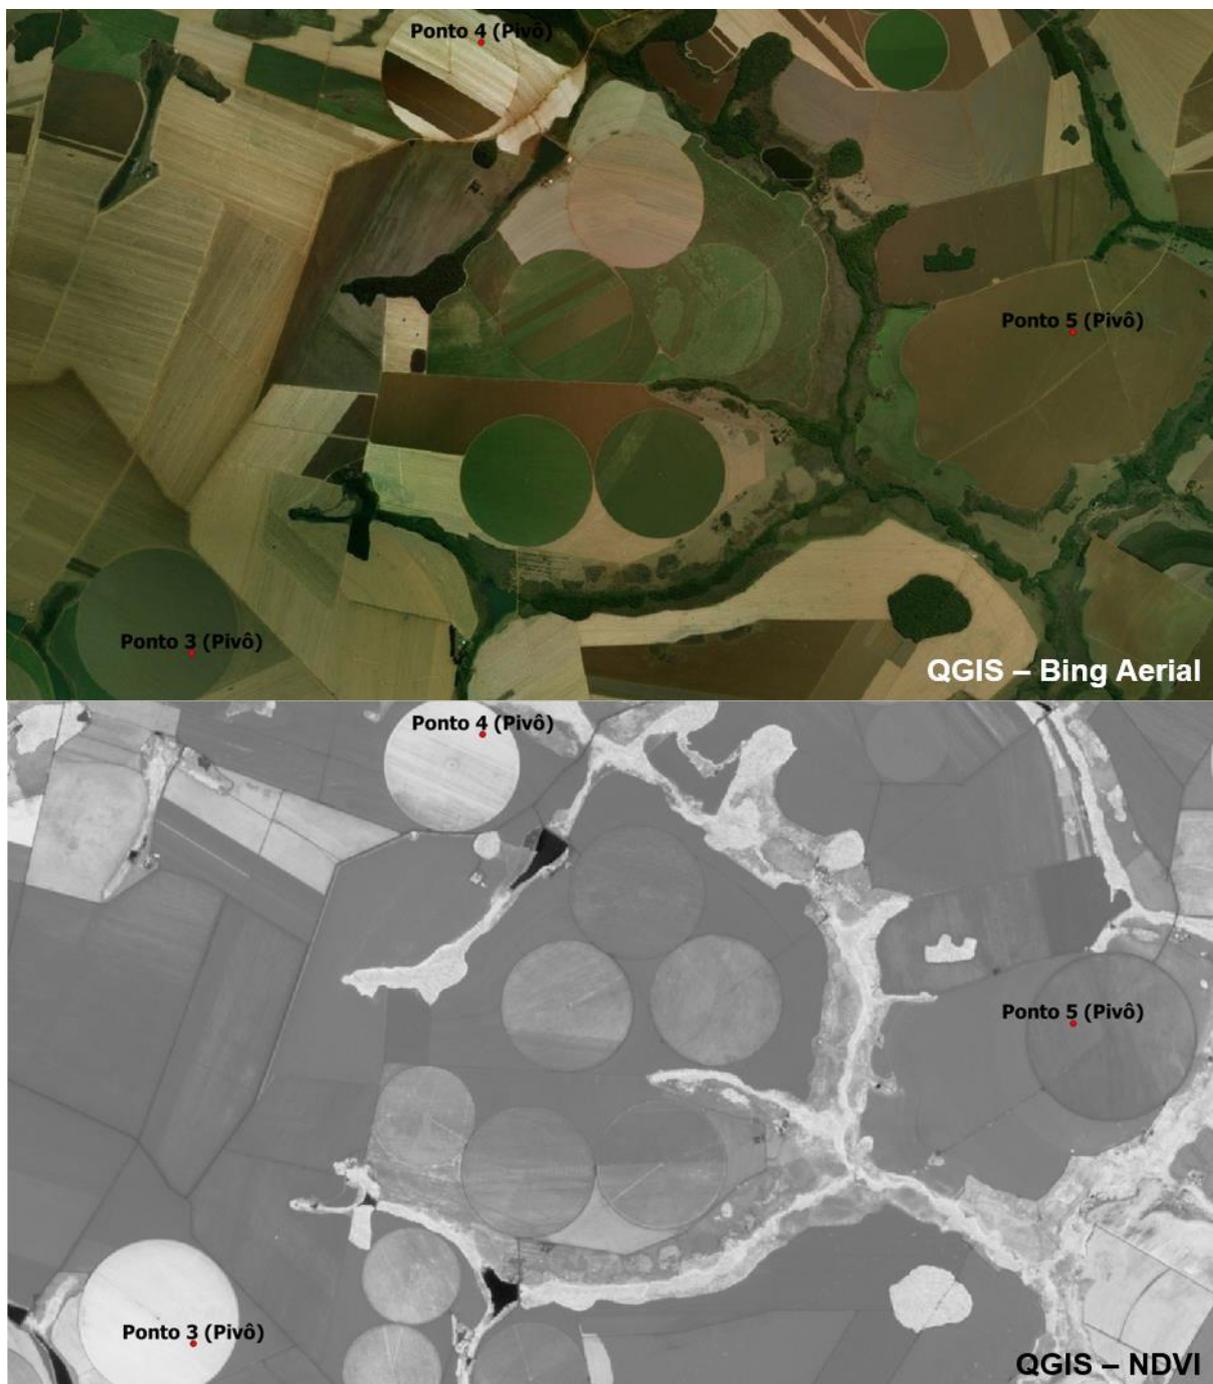
UNITED NATIONS. **World population prospects: the 2019 revision**. 2019. Disponível em: <<https://www.un.org/development/desa/pd/>>. Acesso em: 14 out. 2021.

VELOSO, A. et al. **Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications**. Remote Sensing of Environment, 2017.

ZHANG, J.. **Dynamic Time Warping: Explanation and Code Implementation**. 2020. Disponível em: <<https://towardsdatascience.com/dynamic-time-warping-3933f25fcdd>>. Acesso em: 15 nov. 2021.

ANEXOS

ANEXO A - Pontos 4, 5 e 3.



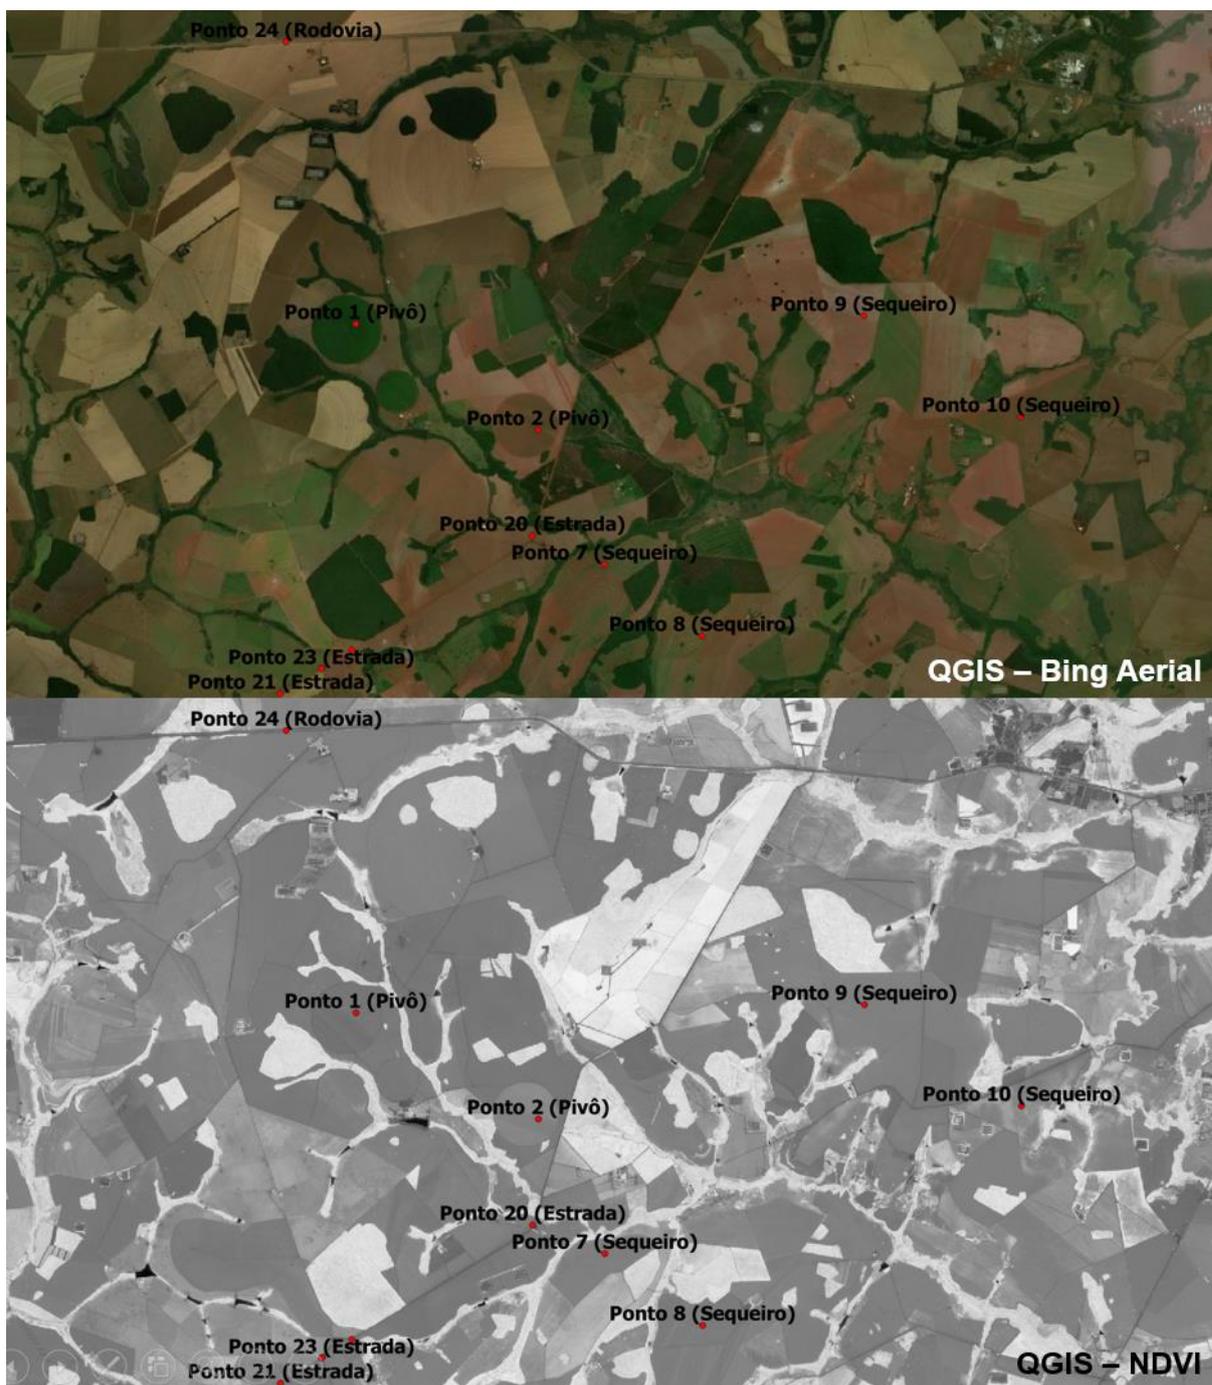
Fonte: Elaborado pelo autor.

ANEXO B - Pontos 18, 12, 16, 6 e 11

Fonte: Elaborado pelo autor.

ANEXO C - Pontos 25 e 26

Fonte: Elaborado pelo autor.

ANEXO D - Pontos 24, 1, 9, 2, 10, 20, 7, 8, 19, 22, 23 e 21

Fonte: Elaborado pelo autor.

ANEXO E - Pontos 17, 15, 14 e 13

Fonte: Elaborado pelo autor.



**PUC
GOIÁS**

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
GABINETE DO REITOR

Av. Universitária, 1089 • Setor Universitário
Caixa Postal 86 • CEP 74605-010
Goiânia • Goiás • Brasil
Fone: (62) 3946.1000
www.pucgoias.edu.br • reitoria@pucgoias.edu.br

RESOLUÇÃO n° 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O(A) estudante GEISON LEAL FEITOSA
do Curso de CIÊNCIA DA COMPUTAÇÃO, matrícula 2017100280254-0,
telefone: 62 981257627 e-mail GEISON.SECUNARX@HOTMAIL, na qualidade de titular dos
direitos autorais, em consonância com a Lei n° 9.610/98 (Lei dos Direitos do autor),
autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o
Trabalho de Conclusão de Curso intitulado
ANÁLISE DE IMAGENS DE SATÉLITE PARA CLASSIFICAÇÃO DE ÁREAS
CULTIVADAS, gratuitamente, sem ressarcimento dos direitos autorais, por 5
(cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial
de computadores, no formato especificado (Texto (PDF); Imagem (GIF ou JPEG); Som
(WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da
área; para fins de leitura e/ou impressão pela internet, a título de divulgação da
produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 14 de DEZEMBRO de 2021.

Assinatura do(s) autor(es): Geison Leal Feitosa

Nome completo do autor: GEISON LEAL FEITOSA

Assinatura do professor-orientador: Max Gontijo

Nome completo do professor-orientador: MAX GONTIJO DE OLIVEIRA