

**UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ**  
**CAMPUS DE CASCAVEL**  
**CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

**GOOGLE EARTH ENGINE PARA MAPEAMENTO DE CULTURAS AGRÍCOLAS NO**  
**PARANÁ**

**ALEX PALUDO**

**CASCAVEL – PARANÁ – BRASIL**

**FEVEREIRO – 2019**

**ALEX PALUDO**

**GOOGLE EARTH ENGINE PARA MAPEAMENTO DE CULTURAS AGRÍCOLAS NO  
PARANÁ**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola para obtenção do título de Mestre em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, com a temática Geoprocessamento, Estatística Espacial e Agricultura de Precisão.

Orientador: Dr. Jerry Adriani Johann

**CASCADEL – PARANÁ – BRASIL**

**FEVEREIRO – 2019**

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

Paludo, Alex  
Google Earth Engine para Mapeamento de Culturas  
Agrícolas no Paraná / Alex Paludo; orientador(a), Jerry  
Adriani Johann, 2019.  
75 f.


Dissertação (mestrado), Universidade Estadual do Oeste  
do Paraná, Campus de Cascavel, Centro de Ciências Exatas e  
Tecnológicas, Programa de Pós-Graduação em Engenharia  
Agrícola, 2019.

1. Modelo Digital de Elevação. 2. Segmentação. 3.  
Continuous Naive Bayes. 4. Sensoriamento Remoto. I.  
Johann, Jerry Adriani. II. Título.

## **ALEX PALUDO**

Google Earth Engine para mapeamento de culturas agrícolas no Paraná

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



Orientador(a) - Jerry Adriani Johann

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



Denise Maria Grzegorzewski

Universidade Federal da Fronteira Sul (UFFS)



Erivelto Mercante

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

Cascavel, 11 de fevereiro de 2019.

## **BIOGRAFIA RESUMIDA**

Brasileiro, nasceu em Guaraniaçu – PR, no ano de 1993. Graduado em Engenharia Agrícola pela Universidade Estadual do Oeste do Paraná – UNIOESTE/Cascavel (2016). Participou durante 5 anos de projetos de iniciação científica nas áreas de geoprocessamento e sensoriamento remoto. Foi aluno do Programa de Pós-Graduação em Engenharia Agrícola, Nível Mestrado (2017-2019), na área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão.

Dedico à minha família  
aos meus pais, João Domingos e Delesia,  
e ao meu orientador, Dr. Jerry Adriani Johann.

## AGRADECIMENTOS

Primeiramente a Deus, pela vida;

À Universidade Estadual do Oeste do Paraná – UNIOESTE e ao Programa de Pós-Graduação em Engenharia Agrícola – PGEAGRI, pela oportunidade oferecida em fazer o mestrado;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo apoio financeiro;

Ao meu orientador, Jerry Adriani Johann, pelo apoio, a dedicação e o companheirismo;

Aos colegas e amigos do Laboratório de Estatística Aplicada – LEA. Em especial, a Willyan Ronaldo Becker, Jonathan Richetti, Laíza Cavalcante e Weverto Verica;

A minha família, meus pais, João Domingos Paludo e Delesia gaieski Paludo, que sempre me incentivaram a estudar e me deram muita força;

A revisora de português, inglês e normas, Dhandara Capitani, pela dedicação em ler todo esse texto (a primeira!), sugerindo melhorias que refletiram na qualidade do resultado final da dissertação;

E a todos que de alguma forma contribuíram na realização deste trabalho.

Obrigado!

# GOOGLE EARTH ENGINE PARA MAPEAMENTO DE CULTURAS AGRÍCOLAS NO PARANÁ

## RESUMO

A produção agropecuária brasileira influencia diretamente na economia do país, sendo que a produção nacional de grãos abrange boa parte desse setor. Desta forma, a informação de área semeada com as principais culturas agrícolas tem grande valor no planejamento de ações logísticas, em políticas públicas ou privadas do mercado de commodities. Uma forma de obter dados mais confiáveis desse setor da economia é com o auxílio do sensoriamento remoto, obtendo dados de maneira mais rápida e eficiente. Entretanto, para se trabalhar com sensoriamento remoto, se torna necessário uma alta capacidade computacional para o processamento dos dados. Para contornar este problema, tem sido utilizado o processamento de dados em nuvem na plataforma Google Earth Engine (GEE), que está disponível de forma gratuita aos usuários e que permite a realização de diversas atividades ligadas ao sensoriamento remoto orbital. Assim, o objetivo deste trabalho foi mapear as principais culturas agrícolas de verão e de inverno no estado do Paraná, para os anos-safra 2016/2017 e 2017/2018, utilizando a plataforma GEE. Para tanto, foram utilizadas imagens dos sensores OLI e MSI, imagens do modelo digital de elevação (SRTM), processo de segmentação no mosaico falsa cor das imagens dos sensores e o algoritmo Continuous Naive Bayes como métodos de classificação. O processo de mapeamento foi parametrizado separadamente para cada uma das 39 microrregiões do estado. Por fim, quantificaram-se as áreas das culturas (soja, milho 1ª e 2ª safras e culturas de inverno) por município e compararam-se estas com dados oficiais e dados de campo. A acurácia dos mapeamentos de verão resultou em Exatidão Global (EG) variando entre 87,6% (Milho, ano-safra 2017/2018) a 96,7% (Soja, ano-safra 2016/2017), com índice kappa (K) entre 72% (Milho, ano-safra 2017/2018) e 91% (Soja, ano-safra 2016/2017). A correlação linear ( $r$ ) entre a área mapeada e a oficial por município foi de 0,92 e o índice de concordância  $dr = 0,81$  para a cultura da soja; para o milho 1ª safra obtiveram-se  $r = 0,59$  e  $dr = 0,53$ . Para os mapeamentos de milho 2ª safra e culturas de inverno, a EG variou entre 95% (culturas de inverno, ano-safra 2018) e 96,7% (Milho 2ª safra, ano-safra 2017), com K entre 90% (culturas de inverno, ano-safra 2018) e 92% (Milho 2ª safra, ano-safra 2017). Entre a área mapeada e a oficial por município obtiveram-se  $r = 0,95$  e  $dr = 0,83$  para a cultura do milho 2ª safra, e  $r = 0,78$  e  $dr = 0,76$  para as culturas de inverno. Na comparação entre a área mapeada e os dados de campo obtiveram-se  $r = 0,96$  e  $dr = 0,86$  para a cultura do milho 1ª safra; e  $r = 0,96$  e  $dr = 0,92$  para a soja, no ano-safra 2017/2018. Para o milho 2ª safra obtiveram-se  $r = 0,79$  e  $dr = 0,71$ ; e  $r = 0,80$  com  $dr = 0,72$  para as culturas de inverno no ano safra 2017. No ano-safra 2018, para milho 2ª safra obtiveram-se  $r = 0,88$  e  $dr = 0,86$ ; e  $r = 0,71$  com  $dr = 0,78$  para as culturas de inverno. O mapeamento de áreas com culturas agrícolas realizado com a plataforma GEE pode ser realizado forma rápida, precisa e eficiente. Pelos mapeamentos é possível ter-se a distribuição espacial das culturas por talhão das lavouras, bem como a quantificação de áreas por área de abrangência de uma empresa, município, microrregião, mesorregião e para todo estado.

**PALAVRAS-CHAVE:** Modelo Digital de Elevação; Segmentação; Continuous Naive Bayes; Sensoriamento Remoto; Landsat-8; Sentinel-2.

# MAPPING AGRICULTURAL CULTURES IN THE STATE OF PARANÁ WITH THE ONLINE PLATFORM GOOGLE EARTH ENGINE

## ABSTRACT

Brazilian agricultural production directly influences the country's economy, with national grain production covering a large part of this sector. In this way, the information of area sown with the main agricultural crops has great value in the planning of logistic actions, in public or private policies of the commodities market. One method to obtain more reliable data from this sector of the economy is with the aid of remote sensing, obtaining data more quickly and efficiently. However, in order to work with remote sensing, a high computational capacity is required for data processing. To overcome this problem, the use of cloud data processing in the Google Earth Engine (GEE) platform was employed, which is available to users free of charge, has been used to perform various activities related to orbital remote sensing. Thus, the objective of this work was to map the main summer and winter crops in the state of Paraná, for the 2016/2017 and 2017/2018 harvest years, using the GEE platform. For this purpose, images of the OLI and MSI sensors, images of the digital elevation model (SRTM), false color mosaic segmentation of the sensor images and the Naive Bayes Continuous algorithm as classification methods were used. The mapping process was parameterized separately for each of the 39 microregions of the state. Finally, the crop areas (soybean, 1<sup>st</sup> and 2<sup>nd</sup> maize and winter crops) were quantified by municipality and compared with official data and field data. The accuracy of the summer mapping resulted in Global Accuracy ranging from 87.6% (Maize, 2017/2018) to 96.7% (Soybean, 2016/2017), with a kappa index (K) between 72% (Maize, 2017/2018 crop year) and 91% (Soybean, 2016/2017). The linear correlation (r) between the mapped area and the official area per municipality was 0.92 and the agreement index  $dr = 0.81$  for the soybean crop and for the 1<sup>st</sup> crop corn yielded  $r = 0.59$  and  $dr = 0.53$ . For the mapping of 2<sup>nd</sup> crop maize and winter crops, the Global Accuracy varied between 95% (winter crops, 2018 crop year) and 96.7% (Maize 2<sup>nd</sup> crop, 2017 crop year), with index kappa (K) between 90% (winter crops, 2018 crop year) and 92% (Maize 2<sup>nd</sup> crop, 2017 crop year). Between the mapped area and the official area per municipality,  $r = 0.95$  and  $dr = 0.83$  for maize 2<sup>nd</sup>crop and  $r = 0.78$  and  $dr = 0.76$  for winter crops were obtained. The linear (r) correlation between the mapped area and the field data was 0.96 and the agreement index  $dr = 0.86$  for the 1<sup>st</sup> crop corn and for the soybean yield  $r = 0.96$  and  $p = 0.92$  for the crop year 2017/2018,  $r = 0.79$  and  $dr = 0.71$  for maize 2<sup>nd</sup> crop  $r = 0.80$  and  $dr = 0.72$  for winter crops in the crop year 2017,  $r = 0.88$  and  $dr = 0.86$  for maize crop 2<sup>nd</sup> crop  $r = 0.71$  and  $dr = 0.78$  for winter crops in the crop year 2018. The mapping of areas with agricultural crops carried out with the GEE platform can be carried out quickly, accurately and efficiently. Through the mappings it is possible to have the spatial distribution of crops per crop plot, as well as the quantification of areas by area of coverage of a company, municipality, microregion, mesoregion and for every state.

**KEYWORDS:** Digital Elevation Model; Segmentation; Continuous Naive Bayes; Remote Sensing; Landsat-8; Sentinel-2.

## SUMÁRIO

<b>RESUMO</b> .....	<b>v</b>
<b>ABSTRACT</b> .....	<b>vi</b>
<b>1 INTRODUÇÃO</b> .....	<b>1</b>
<b>2 OBJETIVOS</b> .....	<b>3</b>
2.1 Objetivo geral.....	3
2.2 Objetivos específicos .....	3
<b>3 REVISÃO BIBLIOGRÁFICA</b> .....	<b>4</b>
3.1 Principais commodities agrícolas .....	4
3.1.1 Cultura do milho.....	4
3.1.1.1 Épocas de semeadura do milho primeira e segunda safra no Paraná.....	5
3.1.2 Cultura da soja.....	6
3.1.2.1 Épocas de semeadura e colheita da soja no Paraná.....	6
3.1.3 Culturas de inverno .....	7
3.1.3.1 Épocas de semeadura e colheita das culturas de inverno no Paraná.....	8
3.2 Caracterização climatológica do estado do Paraná.....	9
3.3 Satélites para mapeamento agrícola .....	11
3.3.1 Sentinel 2.....	11
3.3.2 Landsat-8.....	12
3.4 Modelo digital de elevação.....	13
3.5 Segmentação.....	15
3.6 Plataforma Google Earth Engine (GEE) .....	15
3.6.1 Operações matemáticas .....	17
3.6.2 Processamento de dados.....	18
3.6.3 Uso do Google Earth Engine em pesquisas de mapeamento de culturas .....	19
3.7 Mineração de dados.....	20
3.7.1 Classificador naive bayes.....	22
<b>4 MATERIAL E MÉTODOS</b> .....	<b>23</b>
4.1 Área de estudo.....	23
4.2 Plataforma de processamento utilizada.....	25
4.3 Etapas de processamento.....	27
4.3.1 Imagens multiespectrais.....	27
4.3.1 Criação do mosaico .....	28
4.3.2 SRTM digital elevation data .....	28
4.3.3 Simple non-iterative clustering (SNIC).....	29
4.3.4 Amostragem dos alvos.....	29
4.3.5 Classificação.....	29
<b>5 RESULTADOS E DICUSSÃO</b> .....	<b>31</b>
5.1 Mapeamento de verão .....	31
5.2 Mapeamento de milho segunda safra e culturas de inverno.....	38
<b>6 CONCLUSÕES</b> .....	<b>47</b>
<b>7 CONSIDERAÇÕES FINAIS</b> .....	<b>49</b>
<b>8 REFERÊNCIAS</b> .....	<b>50</b>

## LISTA DE TABELAS

Tabela 1 Produção Agrícola brasileira em Toneladas Comparando o estado do Paraná ao Brasil no ano de 2016.....	4
Tabela 2 Porcentagem mensal de semeadura e colheita do milho 1ª safra para o estado em 2016/2017.....	5
Tabela 3 Porcentagem mensal de semeadura e colheita do milho 2ª safra para o estado em 2016/2017.....	6
Tabela 4 Porcentagem mensal de semeadura e colheita de soja para o estado em 2016/2017 .....	7
Tabela 5 Porcentagem mensal de semeadura e colheita das culturas de inverno para o estado em 2016/2017.....	8
Tabela 6 Comprimentos de onda e resolução espacial das bandas espectrais dos satélites Sentinel-2 .....	12
Tabela 7 Comprimentos de onda e resolução espacial das bandas espectrais dos satélites Landsat-7 e Landsat-8.....	13
Tabela 8 Calendário agrícola do Paraná para Soja, Milho 1ª e 2ª safras e culturas de inverno .....	25
Tabela 9 Datas mínimas, máximas e média da porcentagem de nuvem utilizadas em cada cultura na realização do mapeamento .....	28
Tabela 10 Área mapeada (ha) e oficial de soja por mesorregião para os anos-safra 2016/2017 e 2017/2018 e comparação entre áreas mapeadas dos anos-safra.....	32
Tabela 11 Área mapeada (ha) e oficial de milho primeira safra por mesorregião para os anos-safra 2016/2017 e 2017/2018 e comparação entre áreas mapeadas dos anos-safra .....	35
Tabela 12 Valores de exatidão global (EG), índice kappa (K) e erros de omissão e inclusão para os mapeamentos de soja e milho primeira safra .....	37
Tabela 13 Área mapeada (ha) e oficial de milho segunda safra por mesorregião para os anos-safra 2017 e 2018 e comparação entre áreas mapeadas dos anos-safra.....	38
Tabela 14 Área mapeada (ha) e oficial de culturas de inverno por mesorregião para os anos-safra 2017 e 2018 e comparação entre áreas mapeadas dos anos-safra .....	42
Tabela 15 Valores de exatidão global (EG), índice kappa (K) e erros de omissão e inclusão para os mapeamentos de milho segunda safra e culturas de inverno.....	43

## LISTA DE FIGURAS

Figura 1 Temperatura média anual no estado do Paraná. ....	9
Figura 2 Precipitação anual média total no Estado do Paraná. ....	10
Figura 3 Zoneamento climático com classes climáticas do estado do Paraná. ....	10
Figura 4 Modelo Digital de Elevação para o estado do Paraná. ....	14
Figura 5 SNIC: Exemplo de aplicação de segmentação de uma imagem. ....	15
Figura 6 Interface inicial da Plataforma Google Earth Engine (GEE). ....	16
Figura 7 Interface de scripts criados (A) e edição/criação de scripts (B) no GEE. ....	17
Figura 8 Interface de visualização de camadas de processamento no GEE. ....	17
Figura 9 Aba de registro e importação de imagens e shapes no GEE. ....	18
Figura 10 Ilustração de uma árvore de decisão. ....	21
Figura 11 Mapa de localização do estado do Paraná e suas 39 microrregiões e dados de campo coletados nos dois anos em estudo. ....	23
Figura 12 Fluxograma da sequência de passos realizados para o mapeamento de cada cultura, por ano-safra. ....	24
Figura 13 Biblioteca do GEE com exemplos de scripts livres disponíveis para uso. ....	25
Figura 14 Interface de criação e edição dos scripts no GEE. ....	26
Figura 15 Ambiente de busca no banco de dados da plataforma GEE. ....	26
Figura 16 Janela inspector da plataforma GEE. ....	26
Figura 17 Interface de exibição espacial de camadas geradas pelo script do GEE. ....	27
Figura 18 Mapeamento de soja e milho primeira safra para os anos-safra 2016/2017 (a) e 2017/2018 (b). ....	33
Figura 19 Relação entre área mapeada e dados oficiais de soja no ano-safra 2016/2017 (a) e entre áreas mapeadas 2016/2017 e 2017/2018 (b). ....	34
Figura 20 Relação entre área mapeada e dados oficiais de milho primeira safra no ano-safra 2016/2017 (a) e entre áreas mapeadas 2016/2017 e 2017/2018 (b). ....	36
Figura 21 Relação entre dados de campo e área mapeada de milho primeira safra no ano-safra 2017/2018 (a) e entre dados de campo e áreas mapeadas de soja 2017/2018 (b). ....	38
Figura 22 Mapeamento de milho segunda safra e culturas de inverno para os anos-safra 2017 (a) e 2018 (b). ....	40
Figura 23 Relação entre área mapeada e dados oficiais de milho segunda safra no ano-safra 2017 (a) e entre áreas mapeadas 2017 e 2018 (b). ....	41
Figura 24 Relação entre área mapeada e dados oficiais de culturas de inverno no ano-safra 2017 (a) e entre áreas mapeadas 2017 e 2018 (b). ....	43
Figura 25 Relação entre dados de campo e área mapeada de culturas de inverno no ano-safra 2017 (a) e entre dados de campo áreas mapeadas de milho segunda safra 2017 (b). ....	44
Figura 26 Relação entre dados de campo e área mapeada de culturas de inverno no ano-safra 2018 (a) e entre dados de campo áreas mapeadas de milho segunda safra 2018 (b). ....	45

Figura 27 Fatores que levaram a erros de classificação no mapeamento das culturas,  
detectados na validação com dados de campo..... 46

## 1 INTRODUÇÃO

O Brasil se destaca mundialmente na área da produção agrícola, figurando entre os maiores produtores mundiais das culturas de soja, milho e de culturas de inverno (trigo, cevada e aveia), tendo grande importância no mercado mundial na produção de alimentos.

Dentro deste contexto, o estado do Paraná figura como um dos maiores produtores nacionais destas culturas, estando entre os primeiros estados na produção de grãos no país. A divulgação das informações sobre as safras brasileiras é de responsabilidade da Companhia Nacional de Abastecimento (CONAB), do Instituto Brasileiro de Geografia e Estatística (IBGE) e da Secretaria da Agricultura e Abastecimento (SEAB/Deral). Tais órgãos realizam suas estimativas anuais de previsão de safras, adotando metodologias indiretas que levam em conta alguns aspectos subjetivos. Porém, não levam em conta a distribuição espacial das lavouras agrícolas sobre o território nacional, nem suas divisões por culturas, dificultando os planejamentos logísticos e a criação de políticas de apoio ao setor agrícola.

Nesse sentido, é importante o uso de técnicas de sensoriamento remoto orbital, as quais possibilitam o monitoramento agrícola de tipo de cobertura vegetal em escala regional, e seu estado de desenvolvimento, obtidos com maior antecedência, precisão e menor custo operacional em relação às técnicas tradicionais, possibilitando a identificação e a quantificação das áreas agrícolas de forma objetiva e rápida.

Um dos softwares atualmente utilizado para se realizar este trabalho é a plataforma online Google Earth Engine (GEE). O GEE é uma plataforma de processamento geoespacial da Google que envolve conjuntos de dados geoespaciais, sendo uma ferramenta para executar o desenvolvimento de algoritmos interativos em escala global. Através desta ferramenta de análise de dados globais é possível ter acesso a vários bancos de dados e suas séries históricas para todo o planeta, sem a necessidade de armazenar e processar estas informações para depois poder utilizá-las, facilitando o emprego de técnicas de processamentos de dados de sensoriamento remoto orbital.

Trabalhos já foram desenvolvidos pelo mundo utilizando a plataforma GEE, com a finalidade de gerar mapas de uso e ocupação da terra em diversas regiões, os quais obtiveram ótimos resultados. Essas pesquisas também vêm empregando o uso de dados de satélites. Um deles é o Sentinel-2 (2A e 2B), que, possuindo uma resolução temporal de 5 dias com os dois satélites e espacial de no mínimo 10m, tem se mostrado muito eficiente para a observação precisa da Terra, especialmente para mapeamento e monitoramento agrícola e florestal.

Outro satélite que se utiliza em pesquisas é o Landsat, que representa a mais longa coleção de dados de sensoriamento terrestre de resolução moderada. Quatro décadas de imagens fornecem a possibilidade de vários estudos com diversas finalidades, pois é possível

analisar também o comportamento temporal dos alvos. Os produtos mais recentes são do satélite Landsat-8, que possuem resolução temporal de 16 dias e espacial de 30 m.

Outra fonte de dados que tem grande importância para a realização de mapeamento são os dados de modelo digital de elevação (SRTM), que é um esforço de pesquisa internacional para obter modelos de elevação digital em uma escala quase global. Esses dados são de grande importância a estudos referentes a uso e ocupação do solo, devido a este influenciar diretamente nessa dinâmica de ocupação do território.

No processo de mapeamento, além do uso direto destes dados, vem sendo utilizado com frequência o pré-processamento dos dados com uso de segmentação das imagens, o que tem se mostrado eficaz, pois transforma uma imagem de pixels em pequenos clusters de pixels semelhantes entre si, chamados de superpixels. Um algoritmo utilizado é o SNIC (Simple Non-Iterative Clustering), que é executado em uma única iteração e não usa um mapa de distância – portanto, requer menos memória.

A classificação bayesiana é uma técnica que tem se tornado cada vez mais popular nos últimos anos, em parte devido ao desenvolvimento recente no aprendizado com redes de crenças bayesianas. O classificador bayesiano mais simples é o Naive Bayes, um classificador probabilístico presente no GEE que calcula um conjunto de probabilidades contando a frequência e as combinações de valores em um determinado conjunto de dados. O algoritmo usa o teorema de Bayes e assume que todos os atributos são independentes, dado o valor da variável de classe.

Portanto, o objetivo desse trabalho foi desenvolver um algoritmo de inteligência artificial para mapear e mapear as áreas agrícolas de verão e inverno no estado do Paraná com imagens de alta resolução, para os anos-safra 2016/2017 e 2017/2018. Nesse sentido, a hipótese da dissertação é que, com o uso da plataforma GEE e planos de informação obtidos de satélite, é possível mapear culturas agrícolas de verão e de inverno no Paraná, de forma mais automática, rápida e fácil.

## **2 OBJETIVOS**

### **2.1 Objetivo geral**

Mapear as principais culturas agrícolas de verão e de inverno no estado do Paraná, para os anos-safra 2016/2017 e 2017/2018, utilizando a plataforma online Google Earth Engine (GEE).

### **2.2 Objetivos específicos**

- Desenvolver uma metodologia para realizar mapeamentos de culturas agrícolas por meio da plataforma GEE com imagens de satélite;
- Mapear e estimar as áreas com culturas de verão (soja e milho primeira safra) e de inverno (milho segunda safra e culturas de inverno – trigo, cevada e aveia) no estado do Paraná nos anos-safra 2016/2017 e 2017/2018;
- Realizar a validação espacial destes mapeamentos com composições falsa-cor RGB dos sensores MSI ou OLI e com dados obtidos em campanhas de campo.

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 Principais commodities agrícolas

O estado do Paraná se destaca na produção nacional de grãos e matéria vegetal, produzindo uma quantidade considerável de grãos no âmbito tanto nacional quanto internacional. A produção paranaense da cultura da soja corresponde a aproximadamente 17 milhões de toneladas, representando praticamente 17% da produção nacional (Tabela 1), superior à total do quarto maior produtor mundial da cultura, a Índia, com um total de 14 milhões de toneladas (FAOSTAT, 2016b).

A produção de milho no estado tanto da primeira, quanto da segunda safra é de 13,89 milhões de toneladas, o que representa 21,75% do total nacional (Tabela 1). Esta quantidade supera a produção do Canadá, que é o 10º colocado no ranking mundial do grão (FAOSTAT, 2016b).

O Paraná também se destaca, a nível nacional, na produção de culturas de inverno de trigo, cevada e aveia, que respondem, respectivamente, por 49,14; 53,32 e 19,13% da produção nacional (Tabela 1). Os totais das demais culturas (Tabela 1) do Paraná não serão abordados por não serem o objetivo deste trabalho.

Tabela 1 Produção Agrícola brasileira em Toneladas Comparando o estado do Paraná ao Brasil no ano de 2016

Culturas	Brasil (t)	Paraná (t)	% Paraná vs Brasil
Cana-de-açúcar	768.657.662	47.466.596	6,18
Soja (em grão)	96.062.826	17.025.112	17,72
Milho (em grão)	63.850.940	13.887.103	21,75
Mandioca	21.064.827	3.888.111	18,46
Trigo (em grão)	6.832.027	3.357.449	49,14
Feijão (em grão)	2.590.037	590.296	22,79
Cevada (em grão)	379.375	202.273	53,32
Aveia (em grão)	878.713	168.133	19,13

Fonte: IBGE (2018).

##### 3.1.1 Cultura do milho

O milho (*Zea mays L.*) é uma espécie que pertence à família *Gramineae/Poaceae*, sendo cultivada há mais de 8000 anos em muitas partes do mundo. A importância econômica do milho é caracterizada pelas diversas formas de sua utilização, que vai desde a alimentação animal até a indústria de alta tecnologia. No entanto, o uso do milho em grão como alimentação animal representa a maior parte do consumo desse cereal, isto é, cerca de 70% da produção mundial. Nos Estados Unidos, cerca de 50% é destinado a esse fim, enquanto

que no Brasil, varia de 60 a 80%, dependendo da fonte da estimativa (CRUZ; FERRARI; MATOSO, 2016).

O Brasil é o segundo maior exportador mundial de milho. Isso mostra a importância estratégica do país na oferta desse produto, tendo em vista o aumento do consumo. Além disso, o Brasil tem uma grande vantagem frente aos seus concorrentes diretos, que é a possibilidade de cultivo de duas safras no mesmo ano agrícola. O levantamento do custo de produção, realizado pela Conab, mostra que, apesar da produtividade média na segunda safra ser menor do que na primeira safra, o gasto médio da produção por saca na primeira safra é muito semelhante ao gasto médio na segunda safra (CONAB, 2018a).

Esses fatores fizeram crescer a importância do milho segunda safra. Nos últimos 30 anos, a área de milho primeira safra reduziu 2,8% ao ano, em média, enquanto a área de milho segunda safra aumentou 12,1% ao ano, em média. Com isso, na safra 2011/12, as áreas de ambas as safras agrícolas ficaram muito próximas. A partir daí, o milho cultivado na segunda safra se tornou o mais importante do país (CONAB, 2018a).

Os Estados Unidos são os maiores produtores e consumidores de milho, respondendo pela produção de 384 milhões de toneladas. Na 2ª posição está a China, responsável por produzir 231 milhões de toneladas, e o Brasil é o 3º maior produtor, com um total de 64 milhões de toneladas na safra 2015/2016 (FAOSTAT, 2016a). O estado com maior produção de milho no Brasil é o Mato Grosso, com uma produção total de mais de 26 milhões de toneladas, seguido do Paraná, com quase 12 milhões, e em terceiro lugar está o estado de Goiás, produzindo mais de 8 milhões de toneladas de milho (CONAB, 2018b).

### 3.1.1.1 Épocas de semeadura do milho primeira e segunda safra no Paraná

A SEAB/Deral divulga anualmente o percentual de área semeada e colhida das principais culturas agrícolas do Paraná, de milho primeira e segunda safras. Também é possível observar o percentual de semeadura e colheita e seus respectivos períodos de ocorrência (Tabela 2 e Tabela 3).

Tabela 2 Porcentagem mensal de semeadura e colheita do milho 1ª safra para o estado em 2016/2017

Cultura	Situação	ago	set	out	nov	dez	jan	fev	mar	abr	maio
Milho 1 Safra	Semeadura	2	48	43	7						
	Colheita							14	55	27	4

Fonte: Adaptado de SEAB; DERAL (2018).

Tabela 3 Porcentagem mensal de semeadura e colheita do milho 2ª safra para o estado em 2016/2017

Cultura	Situação	jan	fev	mar	abr	maio	jun	jul	ago	set	out
Milho 2 Safra	Semeadura	3	45	46	6						
	Colheita					1	3	39	43	14	

Fonte: Adaptado de SEAB; DERAL (2018).

### 3.1.2 Cultura da soja

A soja (*Glycine max (L.) Merrill*) tem como centro de origem o continente asiático, mais precisamente, a região correspondente à China antiga. Há referências bibliográficas segundo as quais a base alimentar do povo chinês constituía-se desta leguminosa há mais de 5.000 anos (CÂMARA, 2015).

Segundo a FAO (2016) o Brasil superará os Estados Unidos como o maior produtor mundial de soja na próxima década, de acordo com o novo relatório da Perspectiva Agrícola 2017-2026 da FAO. As exportações de soja em 2026 serão dominadas por Brasil e Estados Unidos, que em conjunto representarão quase 80% das exportações mundiais.

Atualmente os maiores produtores mundiais de soja são: Estados Unidos, com 117 milhões de toneladas; Brasil, com 96 milhões de toneladas; e a Argentina, com 58 milhões de toneladas em 2016. Juntos, os três países respondem por mais de 82% da produção global na safra 2015/2016 (FAOSTAT, 2016a). O consumo mundial de soja estimado para a safra 2017/18 foi estimado em 344 milhões de toneladas, segundo o USDA, sendo que Estados Unidos e China são responsáveis por cerca de 50% deste consumo (SEAB, 2018).

Os maiores produtores brasileiros de soja no ano-safra 2017/18 foram Mato Grosso, com cerca de 32 milhões de toneladas; Paraná, com quase 19 milhões; Rio Grande do Sul, produzindo cerca de 17 milhões; Goiás, com 12 milhões; e Mato Grosso do Sul, com 9,6 milhões de toneladas (CONAB, 2018b). O Paraná se consolidou como o segundo maior produtor de soja do país. Nos últimos dados oficiais sobre a safra 2017/18, os produtores paranaenses foram responsáveis por mais de 16% da produção nacional, sendo que o Brasil produziu 119 milhões de toneladas (CONAB, 2018b).

#### 3.1.2.1 Épocas de semeadura e colheita da soja no Paraná.

A SEAB/Deral divulga anualmente o percentual de área semeada e colhida das principais culturas agrícolas do Paraná, como de soja. Também é possível observar o percentual de semeadura e colheita e seus respectivos período de ocorrência (Tabela 4).

Tabela 4 Porcentagem mensal de semeadura e colheita de soja para o estado em 2016/2017

Cultura	Situação	set	out	nov	dez	jan	fev	mar	abr	maio	jun
Soja	Semeadura	14	46	35	5						
	Colheita						1	30	46	22	1

Fonte: Adaptado de SEAB; DERAL (2018).

### 3.1.3 Culturas de inverno

As culturas de inverno são cultivadas nas regiões Sul, Sudeste e Centro-Oeste do Brasil; porém, cerca de 90% da produção dessas culturas está na região Sul, que compreende os estados do Rio Grande do Sul, Santa Catarina e Paraná.

O trigo (*Triticum aestivum* L.) tem uma importância significativa na alimentação da humanidade. Os registros sobre o surgimento desta cultura datam de antes de Cristo. Com o passar dos anos, a tecnologia de produção deste cereal disseminou-se pelo mundo. No Brasil, este se desenvolveu com a vinda dos colonizadores europeus para o continente americano, sendo que região Sul do Brasil apresentou as melhores condições para o desenvolvimento do cereal (CAMPONOGARA et al., 2015).

O trigo representa, aproximadamente, 30% da produção mundial de grãos. O cereal é empregado na alimentação humana (farinha, macarrão, biscoitos, bolos, pães, etc.), na elaboração de produtos não alimentícios, bem como na alimentação animal, na forma de forragem, de grão ou na composição de ração. No Brasil, estima-se que 94,5% da produção sejam destinada ao processamento industrial, 2,5% seja reserva de semente e, aproximadamente, 3% utilizada diretamente na alimentação animal (DE MORI; IGNACSAK, 2011).

Embora o Brasil tenha uma produção expressiva, de 6,83 milhões de toneladas de trigo (Tabela 1), ele não figura entre os maiores produtores mundiais, pois o primeiro colocado, a China, tem a produção de aproximadamente 131 milhões de toneladas, seguida da Índia, com 93 milhões, e a Rússia com 73 milhões (FAOSTAT, 2016a). O Paraná é o maior produtor nacional, com mais 3 milhões de toneladas; em segundo lugar está o estado do Rio Grande do Sul, com mais de 1,4 milhões de toneladas; e em terceiro lugar está Minas Gerais, com 207 mil toneladas no ano-safra 2017/2018 (CONAB, 2018b).

Aparentemente, a aveia (*Avena sativa*) teve origem na Ásia, enquanto as *Avena byzantina* e *Avena sterilis*, no Mediterrâneo e Oriente Médio. Uma das primeiras referências sobre consumo de aveia pela humanidade é o das tribos germânicas no século I. Atualmente, as principais espécies cultivadas no país são a aveia branca (*Avena sativa* L.), a aveia amarela (*Avena byzantina* C. Koch), espécies de duplo propósito com produção de forragem e grãos, e a aveia preta (*Avena strigosa* Schreb) empregada como pastagem, de forma isolada ou em

consorciação com outras forrageiras, e como adubo verde (MORI; FONTANELI; SANTOS, 2012).

O maior produtor mundial de aveia é a Rússia, com uma produção de 4,7 milhões de toneladas, seguida do Canadá, com uma produção de 3 milhões de toneladas, e em terceiro está a Polônia, com uma produção de 1,3 milhões de toneladas (FAOSTAT, 2016b). O estado do Rio Grande do Sul é o maior produtor nacional, com 717 mil toneladas; em segundo está o estado do Paraná, com mais de 186 mil toneladas; e em terceiro lugar está Mato Grosso do Sul, com 45 mil toneladas (CONAB, 2018b).

A cevada (*Hordeum sp.*), originária do Oriente Médio, é o quinto grão em ordem de importância mundial após arroz, milho, trigo e soja. Com quantidade anual média de aproximadamente 140 milhões de toneladas, a produção do cereal está concentrada nas regiões temperadas da Europa, Ásia e América do Norte (DE MORI; MINELLA, 2012).

Os maiores produtores mundiais de cevada são a Rússia, com 17,99 milhões de toneladas; em segundo a Alemanha, com 10,73 milhões de toneladas; e na sequência a França, com 10,31 milhões de toneladas na safra 2015/2016 (FAOSTAT, 2016b). O Brasil não figura entre os maiores produtores mundiais, pois possui uma produção de 379 mil toneladas no ano-safra 2016 (Tabela 1). O Paraná é o maior produtor nacional, com mais 253 mil toneladas; em segundo está o estado do Rio Grande do Sul, com mais de 139 mil toneladas; e em terceiro lugar está Santa Catarina, com 2,2 mil toneladas no ano-safra 2017/2018 (CONAB, 2018b).

### 3.1.3.1 Épocas de semeadura e colheita das culturas de inverno no Paraná.

A SEAB/Deral divulga anualmente o percentual de área semeada e colhida das principais culturas agrícolas do Paraná, de culturas de inverno. Também é possível observar o percentual de semeadura e colheita e seus respectivos intervalos de ocorrência (Tabela 5).

Tabela 5 Porcentagem mensal de semeadura e colheita das culturas de inverno para o estado em 2016/2017

Situação	Cultura	abr	maio	jun	jul	ago	set	out	nov	dez
Semeadura	Trigo	12	53	27	7	1				
	Aveia	15	37	36	6	6				
	Cevada			67	33					
Colheita	Trigo					2	63	18	16	1
	Aveia					2	51	28	19	
	Cevada							15	82	3

Fonte: Adaptado de SEAB; DERAL (2018).

### 3.2 Caracterização climatológica do estado do Paraná

Situado na região sul do Brasil, o estado do Paraná ocupa uma área de 199.307,94 km<sup>2</sup>, possuindo aproximadamente 11.320.892 milhões de pessoas, situado entre os paralelos 22°29'S e 26°43'S e os meridianos 48°2'W e 54°38'W. o estado conta com 399 municípios, agrupados em 39 microrregiões e em 10 mesorregiões, possuindo divisas com outros três estados (São Paulo, Mato Grosso do Sul e Santa Catarina) (IBGE, 2017).

A agricultura no estado tem grande variabilidade devido às condições favoráveis de crescimento de diversas plantas. Culturas comuns ao Paraná incluem soja, milho, feijão, café, algodão, trigo, mandioca, cevada, cana-de-açúcar e aveia (APARECIDO et al., 2016).

De forma geral o estado do Paraná possui uma temperatura do ar média anual variando entre 15 e 24 °C (Figura 1), em que se nota que a região sul do estado possui um clima mais ameno que o resto do estado, e sua temperatura sobe gradualmente quando se em comparação com as regiões norte e litorânea.

A precipitação anual no estado do Paraná (Figura 2) varia de 1.100 a 1.920 mm ano<sup>-1</sup>. A região sul do estado tem os maiores índices de precipitações anuais (>1.800 mm ano<sup>-1</sup>), enquanto que na região norte do estado tem-se as menores precipitações anuais (<1.200 mm ano<sup>-1</sup>). Esses dados foram obtidos depois de se analisar a série histórica de dados de 1989 até 2014 (APARECIDO et al., 2016).




Figura 1 Temperatura média anual no estado do Paraná.

Fonte: Adaptado de Aparecido et al. (2016).




Figura 2 Precipitação anual média total no Estado do Paraná.  
Fonte: Adaptado de Aparecido et al. (2016).

Ao analisar as classes climáticas no estado do Paraná (Figura 3), identifica-se que existem 2 grupos (A e C) e 4 classes climáticas. A classe climática com maior predominância no Estado do Paraná é subtropical úmido com clima oceânico sem estação seca e verão quente (Cfa), representando 50% da área. A classe Clima subtropical úmido com clima oceânico, sem estação seca e verão temperado (Cfb) foi a segunda maior, representando 39,8% da área e ocorrendo em áreas de grande altitude, principalmente nas terras altas de Ponta Grossa e Curitiba. As classes clima tropical com inverno seco (Aw), e clima subtropical úmido com inverno seco e verão quente (Cwa), foram observadas apenas no norte, representando apenas 5,7 e 4,3% do estado, respectivamente (APARECIDO et al., 2016)




Figura 3 Zoneamento climático com classes climáticas do estado do Paraná.  
Fonte: Adaptado de Aparecido et al. (2016).

### 3.3 Satélites para mapeamento agrícola

Uma importante informação que deve ser utilizada em estudos de mapeamento de culturas agrícolas, são as séries temporais de imagens orbitais de média-baixa resolução espacial, que são utilizadas com muita intensidade e apresentam boas condições temporal, espacial, espectral e radiométrica, proporcionando uma confiabilidade nos dados a serem analisados, assim, tornando possível a identificação de áreas agrícolas menores com mais precisão e obtendo melhor confiabilidade devido à melhor qualidade dos dados obtidos.

#### 3.3.1 Sentinel 2

Os produtos Sentinel-2 representam os dados de satélite multiespectrais de resolução espacial média-alta mais acessíveis. Após o lançamento dos dois satélites Sentinel-2, o potencial de uso destes cria boas oportunidades para a observação precisa da Terra (ESA.INT, 2018a).

A missão Sentinel-2 compreende uma constelação de dois satélites colocados na mesma órbita polar, divididos em 180° entre si e a altitude orbital média de 786 km, a inclinação da órbita é 98,62°. Destina-se a monitorar a variabilidade nas condições da superfície terrestre, e sua ampla largura de faixas espectrais e baixa resolução temporal (10 dias no equador com um satélite e 5 dias com 2 satélites sob condições sem nuvens) monitoramento de mudanças na vegetação dentro da estação de crescimento (ESA.INT, 2018b).

O instrumento multiespectral presente nos satélites Sentinel é o MultiSpectral Instrument (MSI) (ESA.INT, 2018b), que usa um conceito de vassoura manual. Um sensor de vassoura funciona coletando fileiras de dados de imagem através da faixa orbital e utiliza o movimento de avanço da espaçonave ao longo do caminho da órbita para fornecer novas linhas de aquisição. O período médio de observação sobre a terra e as áreas costeiras é de aproximadamente 17 minutos, e o período máximo de observação é de 32 minutos. A luz refletida até o instrumento MSI da Terra e sua atmosfera é coletada por um telescópio de três espelhos (M1, M2 e M3) e focalizada, por meio de um divisor de feixe, em dois conjuntos de planos focais (FPAs): um para os dez Comprimentos de onda VNIR e um para os três comprimentos de onda SWIR (ESA.INT, 2018b).

O Sentinel-2 possui 13 bandas espectrais (Tabela 6) para uma nova perspectiva da terra e a vegetação presente nela. A combinação de alta resolução, novas capacidades espectrais, uma largura de faixa de 290 km e frequentes tempos de revisitação o caracterizam com um grande potencial de uso em mapeamento e monitoramento agrícola e florestal, além de ajudar na gestão da segurança alimentar. Ele também poderá ser utilizado para previsão efetiva da produtividade de culturas agrícolas e aplicações relacionadas ao acompanhamento ou monitoramento de crescimento da vegetação da Terra. Além disso, é usado para mapear

mudanças na cobertura da terra (BRAZ et al., 2017; OLIVEIRA et al., 2017), fornece informações sobre poluição em lagos e águas costeiras, inundações, erupções vulcânicas, deslizamentos de terra, ou seja, contribuem para o mapeamento de desastres (ESA.INT, 2018a).

Tabela 6 Comprimentos de onda e resolução espacial das bandas espectrais dos satélites Sentinel-2

Resolução	Nº da banda	Nome da banda	Comprimento de onda central (nm)
10 m	B02	Blue (Azul)	490
	B03	Green (Verde)	560
	B04	Red (Vermelho)	665
	B08	NIR (Infravermelho Próximo)	842
20 m	B05	Red Edge 1	705
	B06	Red Edge 2	740
	B07	Red Edge 3	783
	B08A	Red Edge 4	865
	B11	SWIR 1	1610
	B12	SWIR 2	2190
60 m	B01	Aerossol	443
	B09	Water Vapor	940
	B10	Cirrus	1375

Fonte: Adaptado de ENGESAT (2017).

### 3.3.2 Landsat-8

O Landsat representa a mais longa coleção de dados de sensoriamento terrestre de resolução moderada baseados em espaço do mundo. Quatro décadas de imagens fornecem um recurso exclusivo para aqueles que trabalham em agricultura, geologia, silvicultura, planejamento regional, educação, mapeamento e pesquisa sobre mudanças globais. As imagens Landsat também são inestimáveis para a resposta de emergência e alívio de desastres (USGS, 2018).

O Landsat 8 (L8) foi lançado em 11 de fevereiro de 2013 e as operações normais começaram em 30 de maio de 2013. Possui um tempo de travessia equatorial às 10h (VANHELLEMONT; RUDDICK, 2014). As imagens de satélite Landsat 8 possuem uma resolução temporal de 16 dias. A informação recolhida pelos instrumentos a bordo do satélite estão disponíveis para download sem custo a partir EarthExplorer, GloVis, ou o Visualizador LandsatLook dentro de 24 horas de aquisição (USGS, 2018).

O Landsat 8 transporta dois instrumentos de vassoura: o Operational Land Imager (OLI) e o Thermal Infravermelho Sensor (TIRS). O Operational Land Imager (OLI) em L8 é um scanner de vassoura de nove bandas (Tabela 7) com uma largura de faixa de 185 km e oito canais a 30 metros (Tabela 7), um canal pancromático com resolução espacial de 15 metros (VANHELLEMONT; RUDDICK, 2014). Esses sensores fornecem desempenho radiométrico

de sinal-ruído (SNR) melhorado, quantificado em uma faixa dinâmica de 12 bits – isso se traduz em 4096 níveis de cinza em potencial em uma imagem em comparação com apenas 256 níveis de cinza nos instrumentos de 8 bits anteriores. O desempenho melhorado do sinal ao ruído permite uma melhor caracterização do estado e da condição da cobertura da terra. Os produtos são entregues como imagens de 16 bits (dimensionados para 55.000 níveis de cinza). Uma banda de Avaliação da Qualidade também está incluída em cada produto de dados do Landsat 8. Essa faixa permite que os usuários apliquem filtros por pixel aos produtos de dados combinados LANDSAT 8 Operational Land Imager (OLI) (USGS, 2018).

As larguras de várias bandas OLI são refinadas para evitar os recursos de absorção atmosférica nas bandas ETM+. A maior mudança ocorre na banda OLI 5 (0,845–0,885  $\mu\text{m}$ ) para excluir um recurso de absorção de vapor de água a 0,825  $\mu\text{m}$  no meio da banda ETM+ infravermelho próximo (faixa 4; 0,775–0,900  $\mu\text{m}$ ). A banda pancromática OLI, banda 8, também é mais estreita em relação à banda pancromática ETM+ para criar maior contraste entre áreas com vegetação e superfícies sem vegetação em imagens pancromáticas (IRONS; DWYER; BARSI, 2012).

Tabela 7 Comprimentos de onda e resolução espacial das bandas espectrais dos satélites Landsat-7 e Landsat-8

Bandas espectrais OLI			Bandas espectrais ETM+		
Nº da banda	Comprimentos de ondas (nm)	Resolução espacial (m)	Bandas	Comprimentos de ondas ETM+ (nm)	Resolução espacial (m)
B1	0,433-0,453				
B2	0,450-0,515		B1	0,450-0,515	
B3	0,525-0,600		B2	0,525-0,605	
B4	0,630-0,680	30	B3	0,630-0,690	
B5	0,845-0,885		B4	0,775-0,900	30
B6	1,560-1,660		B5	1,550-1,750	
B7	2,100-2,300		B7	2,090-2,350	
B8	0,500-0,680	15	B8	0,520-0,900	
B9	1,360-1,390	30			

Fonte: Adaptado de Irons; Dwyer; Barsi (2012).

### 3.4 Modelo digital de elevação

Os dados do modelo digital de elevação (SRTM – Shuttle Radar Topography Mission) foram gerados a partir de pesquisa internacional para que se tivesse o modelo de elevação digital em uma escala global (FARR et al., 2007).

Atualmente, o produto SRTM V3 (SRTM Plus) é fornecido pela NASA com uma resolução espacial de 30m. Este produto (SRTM V3.0, 1 arcsec<sup>2</sup>) é um aprimoramento dos dados topográficos SRTM de menor resolução espacial de 90 m (3 arcsegundos, que é 1 / 1200<sup>o</sup> de grau de latitude e longitude) que cobria regiões fora dos Estados Unidos (EUA), divulgada publicamente em 2003 (SANTILLAN; MAKINANO-SANTILLAN, 2016).

A NASA lançou uma versão completa do modelo de elevação digital, conhecido como "SRTM Plus". O SRTM Plus usa SRTM Versão 2 (Figura 4). A maioria dos vazios foi preenchida com dados de elevação do ASTER GDEM2 (Global Digital Elevation Model Version 2). O ASTER é um sensor do satélite Terra, da NASA, que usa imagens estereoscópicas para medir elevações por paralaxe ótica, onde não são obscurecidas pelas nuvens. O preenchimento de espaços vazios adicionais de pequenas áreas utilizou o modelo de elevação GMTED2010 compilado pelo Serviço Geológico dos EUA. O SRTM Plus foi produzido no âmbito do programa "Making Earth System Data Records for Use in Research Environments" (MEaSURES) da NASA (NASA, 2018).




Figura 4 Modelo Digital de Elevação para o estado do Paraná.  
Fonte: Adaptado de Gorelick et al. (2017).

Alguns autores vêm trabalhando com esse produto, como Binam Mandeng et al. (2018), que utilizou imagens de SRTM juntamente com imagens Landsat-7 para mapeamento de campo geológico convencional. Já Fayad et al. (2014) combinaram as imagens SRTM com os dados do GLASS para discriminar os cinco tipos de paisagem florestal na Guiana Francesa, onde os resultados mostraram uma precisão de classificação geral de 81,3%. Já Malahlela et al. (2018) usou imagens SRTM e dados do Sentinel-2 para prever a distribuição de *L. Javanica* (planta comumente utilizada no combate à malária) no município de Vhembe (África do Sul), conseguindo uma acurácia perto de 91%.

### 3.5 Segmentação

Além do uso direto destes dados em tarefas de classificação, a segmentação tem sido muito utilizada como um pré-processamento dos dados para posterior aplicação de algoritmos de classificação de imagens, tendo em vista que simplifica-se a imagem (ACHANTA; SUSSTRUNK, 2017). A ideia é de em vez de classificar cada pixel da imagem separadamente, que se faça uma simplificação de uma imagem, gerando-se pequenos clusters de pixels conectados chamados superpixels (PAPON et al., 2013). A segmentação de superpixels tem se tornado, cada vez mais, uma ferramenta de pré-processamento para simplificar uma imagem de, potencialmente, milhões de pixels para cerca de milhares de clusters de pixels semelhantes (Figura 5).



Figura 5 SNIC: Exemplo de aplicação de segmentação de uma imagem.  
Fonte: Adaptado de Achanta e Susstrunk (2017).

Um dos mais promissores algoritmos de segmentação de superpixels é o algoritmo de agrupamento iterativo linear simples (SLIC), que satisfaz esses critérios e é muito eficiente em termos de requisitos de computação e memória. Apesar do seu uso generalizado, o SLIC tem algumas deficiências (ACHANTA; SUSSTRUNK, 2017). Por isso, foi desenvolvido o algoritmo SNIC (Simple Non-Iterative Clustering), que é uma versão não-iterativa do algoritmo SLIC, sendo executado em uma única iteração; não usa um mapa de distância e, portanto, requer menos memória (ACHANTA; SUSSTRUNK, 2017).

Pesquisadores também vêm trabalhando com esse tipo de pré-processamento. Yin et al. (2018) utilizaram imagens Landsat de 1985 a 2015 e processos de segmentação LandTrendr mapeando terras agrícolas abandonadas no Cáucaso, cobrindo partes da Rússia e da Geórgia, obtendo precisão geral de aproximadamente 82%. Schneibel et al. (2017) utilizaram ferramentas de segmentação com uma série temporal de dados de taxa de queimada normalizada (NBR) e informações temporais e espaciais sobre as mudanças da superfície terrestre e passadas de 1989 a 2013 usando dados do Landsat 5–8, para mapear o desmatamento de florestas de Miombo no sul de Angola, obtendo uma precisão geral de 72%.

### 3.6 Plataforma Google Earth Engine (GEE)

O Google Earth Engine (GEE) é uma plataforma de processamento geoespacial da Google (Figura 6), a fim de fazer avanços substanciais em desafios globais que envolvem

grandes conjuntos de dados geoespaciais. É uma ferramenta para prover dados para que algoritmos sejam desenvolvidos escala global (GOOGLE INC., 2018a).




Figura 6 Interface inicial da Plataforma Google Earth Engine (GEE).

Fonte: Adaptado de Gorelick et al. (2017).

O GEE é uma plataforma baseada no processamento em nuvem para análise de dados ambientais em escala planetária, sendo seus principais componentes (GOOGLE INC., 2018b):

- Conjuntos de dados: arquivos de imagens de vários satélites, disponíveis gratuitamente aos usuários. É possível explorar categorias de dados no arquivo ou navegar e procurar conjuntos de dados;
- Poder de computação: infra-estrutura computacional do Google otimizada para processamento paralelo de dados geoespaciais;
- APIs: APIs para JavaScript e Python (hospedado no GitHub) para fazer solicitações aos servidores do GEE. É necessário o desenvolvimento de scripts ou utilização de scripts já prontos, que, em geral, são documentos em JavaScript (Figura 7);
- Editor de código: um ambiente de desenvolvimento integrado on-line (IDE) para prototipagem rápida e visualização de análises espaciais complexas usando a API de Javascript (Figura 8).




Figura 7 Interface de scripts criados (A) e edição/criação de scripts (B) no GEE.  
Fonte: Adaptado de Gorelick et al. (2017).




Figura 8 Interface de visualização de camadas de processamento no GEE.  
Fonte: Adaptado de Gorelick et al. (2017).

### 3.6.1 Operações matemáticas

O GEE suporta muitos operadores matemáticos básicos, executando operações de matemática por pixel. Eles compartilham algumas características comuns. Quando um operador é aplicado a uma imagem, é aplicado a cada pixel. No caso de operações em duas imagens, a operação é aplicada somente nos locais onde os pixels em ambas as imagens estão sobrepostas (GOOGLE INC., 2018b).

O algoritmo de registro de imagem do GEE (Figura 9) foi projetado para ser um passo final, após ser georreferenciada e alinhadas às imagens. Supõe-se que as imagens a serem registradas já passaram por estágios de alinhamento inicial (GOOGLE INC., 2018b).




Figura 9 Aba de registro e importação de imagens e shapes no GEE.  
Fonte: Adaptado de Gorelick et al. (2017).

### 3.6.2 Processamento de dados

O método de computação do GEE é eficiente, pois paraleliza automaticamente as análises para que elas funcionem simultaneamente em vários computadores nos data centers do Google (just-in-time). Também executa cálculos, solicitando apenas os dados de entrada necessários para preencher a tela ou calcular os valores solicitados (GOOGLE INC., 2018a).

Este modelo de computação distribuída just-in-time permite a exploração em tempo real de resultados e análise de dados experimentais. Após o processamento, os resultados são armazenados em caches de modo que múltiplas solicitações para a mesma imagem ou valores não resultem em nova computação. O quadro computacional do GEE facilita uma abordagem interativa para o desenvolvimento de algoritmos e um ciclo rápido de testes e melhorias para o processamento de dados em larga escala (GOOGLE INC., 2018a).

A funcionalidade do GEE é exposta através de uma API disponível em JavaScript e em Python. A API suporta análises geoespaciais complexas, incluindo sobreposição, álgebra de mapas, operações de matriz, processamento de imagem, classificação, detecção de alterações, análise de séries temporais, juntas, extração vetorial de estatísticas de imagens e muito mais (KTH SPACE CENTER, 2018). O GEE é uma plataforma em nuvem projetada para processar imensas quantidades de dados de sensoriamento remoto. Ele fornece recursos de processamento à escala planetária, geolocalizados, incluindo todo o arquivo de 40 anos de dados Landsat, 14 anos de dados MODIS e produtos derivados, todas as imagens Sentinel-1 e Sentinel-2 e muitos outros conjuntos de dados ambientais, geofísicos e

climatológicos, todos processados para uma forma pronta para análise (KTH SPACE CENTER, 2018).

O GEE está disponível on-line para cientistas, pesquisadores independentes e nações que queiram explorar esse banco de dados (big data) para detectar mudanças, dimensionar tendências e quantificar as diferenças na superfície terrestre. As aplicações incluem: detectar o desmatamento, classificar a cobertura do solo, estimar a biomassa da floresta e o carbono, e medir a disponibilidade de água (GOOGLE INC., 2018a).

### **3.6.3 Uso do Google Earth Engine em pesquisas de mapeamento de culturas**

Vários trabalhos já foram desenvolvidos pelo mundo utilizando a plataforma GEE, com a finalidade de gerar mapas de uso e ocupação do solo em diversas regiões do mundo como feito por Gorelick et al. (2017), Huang et al. (2017) e Xiong et al. (2017), os quais obtiveram ótimos resultados. Segundo Vasconcelos (2015), no ano de 2015 existiam mais de 3 mil cientistas e instituições ao redor do mundo que empregam a plataforma em suas pesquisas.

Xiong et al. (2017) utilizaram a plataforma GEE e o índice NDVI do sensor MODIS para mapear Terras agrícolas no continente africano no ano de 2014 e obtiveram uma precisão global de 90%. Huang et al. (2017) utilizaram a plataforma GEE e o índice NDVI das imagens Landsat, para detectar mudanças na cobertura da terra em 30 anos (1985-2015) para o território de Beijing obtendo uma precisão global de 86,13%. Teluguntla et al. (2018) utilizaram a plataforma GEE e imagens Landsat e o NDVI para determinar a extensão de terras cultiváveis da Austrália e China de 2013 a 2015, obtendo uma precisão global de 97,6% para a Austrália e de 98,8% para a China.

O Projeto de Mapeamento Anual da Cobertura e uso do solo do Brasil (MapBiomias) é uma iniciativa que envolve uma rede colaborativa com especialistas nos biomas, usos da terra, sensoriamento remoto, SIG e ciência da computação que utiliza processamento em nuvem e classificadores automatizados desenvolvidos e operados a partir da plataforma Google Earth Engine para gerar uma série histórica de mapas anuais de cobertura e uso da terra do Brasil (MAPBIOMAS, 2016).

Os desenvolvedores e programadores criaram um aplicativo que organiza o fluxo de trabalho e permite que cada analista e membro da equipe consiga operar em paralelo, na mesma plataforma e com total controle de todas as variáveis importantes para gerar o melhor mosaico de imagens e a melhor classificação para cada carta ou região de trabalho (MAPBIOMAS, 2016).

Lançada no dia 28 de abril de 2016, em Brasília, a segunda coleção de mapas do MapBiomias (Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil) trouxe dados sobre as transformações do território brasileiro ao longo do século XXI, com imagens de satélite que vão de 2000 a 2016 (MAPBIOMAS, 2016).

Os produtos obtidos através do MapBiomias são: mapas de cobertura e uso do solo no formato matricial (pixel de 30x30m). A legenda destes mapas assim como o período coberto evolui ao longo das coleções. Mosaicos de imagens de satélite para cada ano da série histórica com resolução espacial máxima de 30 metros formada pela composição dos pixels representativos de cada conjunto de imagens de um local num determinado período de tempo (ex. filtrando as nuvens) (MAPBIOMAS, 2016).

Os períodos do ano em que são selecionadas as imagens variam conforme a região (ex. período úmido na caatinga). Cada mosaico contém 28 camadas de informação, incluindo as bandas espectrais, frações e índices (ex. NDFI, NDVI etc). Os mosaicos podem ser acessados diretamente no Google Earth Engine para processamento ou por download.

Os dados do MapBiomias revelaram algumas más notícias, como a perda de 20% da área de manguezais entre 2001-2015, em parte destruídos pela expansão urbana. No mesmo período, 13% do Pantanal, bioma brasileiro mais preservado, viraram área de pastagem. Já o Cerrado teve perdas proporcionalmente três vezes mais elevadas do que a Amazônia. Por outro lado, há boas notícias, como o ganho de 2,5 milhões de hectares de Mata Atlântica (o equivalente a quase uma Bélgica) (MAPBIOMAS, 2016).

Cobrindo, atualmente, o período de 2000 a 2016, o MapBiomias prevê também a inclusão de imagens mais antigas em sua plataforma, desde o ano de 1985. Esses dados foram disponibilizados em 2018, abrangendo informações sobre mudanças na cobertura e uso do solo, estatísticas e download de dados na plataforma (MAPBIOMAS, 2016).

### **3.7 Mineração de dados**

Mineração de Dados é um ramo da computação que teve início nos anos 80, quando os profissionais das empresas e organizações começaram a se preocupar com os grandes volumes de dados informáticos estocados e inutilizados dentro da empresa. Nesta época, Data Mining consistia essencialmente em extrair informação de gigantescas bases de dados da maneira mais automatizada possível. Atualmente, Data Mining consiste, sobretudo na análise dos dados após a extração (AMO, 2004).

De forma geral, a mineração de dados se trata de extrair ou minerar conhecimento de grandes volumes de dados. Muitas pessoas consideram o termo Mineração de Dados como sinônimo de Knowledge Discovery in Databases (KDD) ou Descoberta de Conhecimento em Banco de Dados. Na verdade, KDD é um processo mais amplo consistindo das seguintes etapas: 1) Limpeza dos dados, em que os dados inconsistentes são eliminados; 2) Integração dos dados, em que diferentes fontes de dados são combinadas; 3) Seleção, em que são selecionados os fatores ou atributos que interessam ao usuário; 4) transformação de dados, em que os dados são transformados para atenderem os algoritmos de mineração; 5) Mineração, em que são aplicadas técnicas inteligentes com a finalidade de obter padrões de

interesse do banco de dados; 6) avaliação ou pós-processamento: etapa para identificar padrões de acordo com a necessidade do usuário; e, por último, 7) Visualização dos resultados (AMO, 2004).

As tarefas de mineração de dados são geralmente divididas em duas categorias principais: tarefas de previsão e de descrição. As tarefas de previsão objetivam prever o valor de um determinado atributo baseado nos valores de outros atributos. As tarefas de previsão ainda subdividem em classificação, usada para variáveis discretas, e regressão, usada para variáveis contínuas. As tarefas de descrição subdividem em associação (extração de padrões) e agrupamento (agrupa conjuntos de dados similares) (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Para Criveleni et al. (2009), as árvores de decisão (também chamadas de árvores de classificação ou de regressão) são técnicas de mineração de dados utilizadas para classificação e predição das amostras conhecidas através de aprendizado de máquina, ou seja, dados de treinamento. Para tal, efetua-se a construção de padrões com os dados de treinamento e, a partir da árvore obtida, pode-se classificar novas amostras desconhecidas. Tais árvores (Figura 10) consistem em uma hierarquia de nós internos e externos que são conectados por ramos. Cada nó representa uma decisão sobre uma variável através de teste lógico, que ramifica para o próximo nó descendente ou resultado, chamada folha (CRIVELENTI et al., 2009).




Figura 10 Ilustração de uma árvore de decisão.

### 3.7.1 Classificador naive bayes

Uma abordagem bem estabelecida é a classificação bayesiana, uma técnica que se tornou cada vez mais popular nos últimos anos, em parte devido a desenvolvimentos recentes no aprendizado com redes de crenças bayesianas. O classificador bayesiano mais simples é o classificador Naive Bayes. Ele simplifica muito o aprendizado, assumindo que os recursos são independentes (RISH; HELLERSTEIN; JAYRAM, 2001).

Os classificadores Naive Bayes apresentam um bom desempenho em uma ampla gama de problemas de classificação, incluindo diagnóstico médico, categorização de texto, filtragem colaborativa e por e-mail e recuperação de informações, mas ainda é pouco utilizado no processamento de imagens de satélite (CIRELO; COZMAN, 2003; BRAGA; LADEIRA, 2006; SILVA et al., 2013). Em comparação com algoritmos mais sofisticados, os classificadores Naive Bayes geralmente apresentam melhor desempenho. Além disso, Naive Bayes pode lidar com um grande número de variáveis e grandes conjuntos de dados, além de lidar com variáveis de atributos discretos e contínuos (BOUCKAERT, 2005).

O algoritmo Continuous Naive Bayes é um classificador probabilístico simples que calcula um conjunto de probabilidades contando a frequência e as combinações de valores em um determinado conjunto de dados. O algoritmo usa o teorema de Bayes e assume que todos os atributos são independentes, dado o valor da variável de classe. Essa suposição de independência condicional raramente é verdadeira em aplicações no mundo real, daí a caracterização como ingênuo, mas o algoritmo tende a funcionar bem e a aprender rapidamente em vários problemas de classificação supervisionada (PATIL, 2013).

Rish, Hellerstein e Jayram (2001) demonstraram empiricamente que o Naive Bayes atinge o desempenho ideal em dois casos extremos: recursos completamente independentes e recursos funcionalmente dependentes. Continuous Naive Bayes tem seu pior desempenho entre esses extremos – também que uma distribuição conjunta e sua aproximação pelo produto de marginais convergem com entropia decrescente da distribuição.

## 4 MATERIAL E MÉTODOS

### 4.1 Área de estudo

A área de estudo compreende o estado do Paraná, na região Sul do Brasil, situado entre os paralelos 22°29'S e 26°43'S e os meridianos 48°2'W e 54°38'W. É constituído por 399 municípios, subdividido em 10 mesorregiões, e ainda possui a divisão com 39 microrregiões (Figura 11). De forma geral, o estado do Paraná possui uma temperatura média anual do ar variando entre 15 e 24 °C, sendo que a região sul do estado possui um clima mais ameno. A precipitação anual do estado do Paraná varia de 1.100 a 1.920 mm ao ano. Com maiores índices de precipitações anuais (>1.800 mm ano<sup>-1</sup>) ao sul e menores precipitações anuais (<1.200 mm ano<sup>-1</sup>) ao norte (APARECIDO et al., 2016).




Figura 11 Mapa de localização do estado do Paraná e suas 39 microrregiões e dados de campo coletados nos dois anos em estudo.

Fonte: Próprio autor.

Os mapeamentos das culturas de verão (soja e milho primeira safra) e de inverno (milho segunda safra e culturas de inverno – trigo, aveia e cevada) foram realizados separadamente por cultura e divididas por microrregiões, seguindo o fluxograma (Figura 12), devido à grande variação de clima, solo, precipitação, datas de semeadura e colheita (Tabela 8) presentes no estado. Desta forma, se trabalha com regiões mais homogêneas, diminuindo a confusão entre alvos na hora da realização da classificação.




Figura 12 Fluxograma da sequência de passos realizados para o mapeamento de cada cultura, por ano-safra.  
 Fonte: Próprio autor.

Tabela 8 Calendário agrícola do Paraná para Soja, Milho 1ª e 2ª safras e culturas de inverno

Culturas	Situação	set	out	nov	dez	jan	fev	mar	abr	mai	jun	jul	ago
Soja	Semeadura	X	X	X	X								
	Colheita						X	X	X	X	X		
Milho 1º	Semeadura	X	X	X									X
	Colheita						X	X	X	X			
Milho 2º	Semeadura					X	X	X	X				
	Colheita	X	X							X	X	X	X
Culturas de inverno	Semeadura								X	X	X	X	X
	Colheita	X	X	X	X								X

Fonte: Adaptado de SEAB; DERAL, (2018).

## 4.2 Plataforma de processamento utilizada

O GEE possibilita uma grande capacidade de processamento em nuvem sem ser necessária a utilização de estrutura física para o processamento. Esta plataforma também possui a disposição um banco de dados e de scripts bastante amplo (Figura 13), auxiliando muito no momento de criar novos scripts.





Figura 13 Biblioteca do GEE com exemplos de scripts livres disponíveis para uso.

Fonte: Adaptado de Gorelick et al. (2017).

Esta estrutura necessita que o usuário desenvolva scripts ou utilize alguns já existentes e disponíveis de forma gratuita na biblioteca da plataforma. O usuário deve possuir conhecimento prévio em alguma linguagem de programação devido à plataforma suportar várias linguagens (Javascript, Python, R, entre outras); a linguagem de programação utilizada foi a Javascript.

Possui uma Interface de criação e edição dos scripts (Figura 14), sendo bastante simples de se buscar um banco de dados (Figura 15), e possui a janela inspector (Figura 16), na qual é possível verificar as informações presentes nas propriedades da imagem, série histórica ou classificação gerada por um script, o qual mostra todas as informações presentes

no pixel selecionado: valor de pixel, quais bandas estão presentes no RGB criado, mostra o gráfico de todas as bandas de uma imagem, etc.



```

SentinelCentroSulSojaMeio
Imports (6 entries)
  var imageCollection: ImageCollection "Sentinel-2 MSI: MultiSpectral Instrument,..."
  var table: Table users/alexlpaludo/CentroSulmeio
  var Soja: FeatureCollection (24 elements)
  var Soja2: Feature 0 (GeometryCollection, 1 property)
  var Mata: Feature 0 (GeometryCollection, 1 property)
  var Agua: Feature 0 (MultiPolygon, 1 property)

1 // Import Sentinel-2 image collection and filter
2 var S2_Oeste = imageCollection
3   .filterDate('2017-06-01', '2017-07-30')
4   .filterBounds(table)
5   .filterMetadata('CLOUD_COVERAGE_ASSESSMENT', 'less_than', 0.05)
6   .filterMetadata('MGRS_TILE', 'equals', 'TILE');
7
8 // List
9
10 var Lista = S2_Oeste.toList(100);
11 print(Lista);
12
13 // Upload images
14 var T22JBT = ee.Image.load('COPERNICUS/S2/20170918T134211_20170918T134207_T22JBT');
15 var T22JCT = ee.Image.load('COPERNICUS/S2/20170920T133209_20170920T133212_T22JCT');
16 var T22JDT = ee.Image.load('COPERNICUS/S2/20170920T133209_20170920T133212_T22JDT');
17 var T22JBS = ee.Image.load('COPERNICUS/S2/20170918T134211_20170918T134207_T22JBS');
18 var T22JCS = ee.Image.load('COPERNICUS/S2/20170920T133209_20170920T133212_T22JCS');
19 var T22JDR = ee.Image.load('COPERNICUS/S2/20170920T133209_20170920T133212_T22JDR');
20 var T22JCR = ee.Image.load('COPERNICUS/S2/20170920T133209_20170920T133212_T22JCR');
21

```

Figura 14 Interface de criação e edição dos scripts no GEE.

Fonte: Adaptado de Gorelick et al. (2017).



Figura 15 Ambiente de busca no banco de dados da plataforma GEE.

Fonte: Adaptado de Gorelick et al. (2017).




Figura 16 Janela inspetor da plataforma GEE.

Fonte: Adaptado de Gorelick et al. (2017).

Ao rodar as rotinas, são apresentados os resultados (Figura 17), (imagens, RGB, classificação, etc.) de forma leve e sobre um mapa de localização ou sobre a imagem do Google Earth, tornando fácil a localização e a identificação. Nesta janela é possível desabilitar

camadas, mover o mapa, trabalhar com zoom, criar polígonos e pontos sobre as imagens, possibilitando a verificação do produto final.




Figura 17 Interface de exibição espacial de camadas geradas pelo script do GEE.

Fonte: Adaptado de Gorelick et al. (2017).

### 4.3 Etapas de processamento

O desenvolvimento do script no GEE seguiu os passos descritos na **Erro! Fonte de referência não encontrada.**, o fluxograma do processo realizado durante o desenvolvimento do mapeamento. As imagens selecionadas do sensor OLI e MSI, Figura 12, foram as que tivessem o mínimo de nuvens possível, variando para cada microrregião. O período escolhido contempla o máximo desenvolvimento vegetativo em cada microrregião (fase de frutificação) das culturas de interesse, pois essas datas podem variar em função do zoneamento da cultura no estado.

#### 4.3.1 Imagens multiespectrais

As imagens utilizadas para a realização do mapeamento foram obtidas do satélite Sentinel-2 (Figura 12), onde as bandas 8, 4 (vermelho e infravermelho) possuem resolução espacial de 10 m, a qual torna possível a detecção de áreas menores, o que seria impossível com sensores de menor resolução espacial. Também é possível e viável se trabalhar com a banda 11 (SWIR 1) deste satélite, pois esta ajuda na diferenciação dos alvos e tem uma resolução espacial de 20 m. Outra fonte de dados utilizada foram as imagens do satélite Landsat-8 (Figura 12), analisadas as bandas 5, 6 e 4 (Infravermelho próximo, SWIR1 e Vermelho), que destacam mais as características das culturas de interesse e possuem uma resolução de 30 m.

A primeira parte do script é determinar as imagens a serem utilizadas para a classificação; assim, realizou-se uma pré-filtragem (Figura 12) das imagens em relação às presentes no período das culturas agrícolas de verão ou inverno na lavoura (Tabela 9), e na sequência outra filtragem foi necessária para retirar imagens com excesso de nuvens que dificultasse o mapeamento em cada microrregião (Tabela 9). O valor máximo de nuvem foi

determinado por cada microrregião, onde se focou em realizar o mosaico com o menor número possível de pixels cobertos por nuvem. Em seguida, são analisadas as imagens resultantes deste processo e escolhidas as melhores imagens com mesma data para a formação do mosaico para cada microrregião do estado. As datas mínimas e máximas utilizadas por cultura e a média de porcentagem de nuvem utilizadas nos mapeamentos estão especificadas na Tabela 9. As datas por microrregião e porcentagem de nuvens utilizadas por mapeamento, são mostradas no Apêndice 1, onde algumas microrregiões necessitaram rodar o mapeamento em mais de um intervalo de datas devido à grande presença de nuvens.

Tabela 9 Datas mínimas, máximas e média da porcentagem de nuvem utilizadas em cada cultura na realização do mapeamento

Culturas	Data mínima	Data máxima	Média de% de nuvens
Soja	01/12	28/02	28,24
Milho primeira safra	01/12	28/02	24,62
Milho segunda safra	01/03	01/06	23,89
Culturas de inverno	15/07	31/08	20,70

Fonte: Próprio autor.

#### 4.3.1 Criação do mosaico

Após finalizar o processo anterior, as imagens determinadas como as melhores para a microrregião são importadas e mosaicadas (Figura 12), gerando um mosaico único em cima do qual são obtidas as amostras de treinamento, rodado o processo de segmentação, e no qual também é realizado o processo de verificação visual do mapeamento.

Ao se gerar esta imagem, é utilizado um operador matemático de mediana para realizar a operação em regiões de sobreposição, pois uma única imagem do satélite Sentinel-2 ou Landsat-8 não é suficientemente grande para cobrir algumas microrregiões por completo. Desta forma, o operador de mediana analisa cada pixel de cada banda sobreposto por N imagens utilizadas e gera um único valor de pixel, assim obtendo o mosaico pela melhor forma possível para a visualização dos alvos.

#### 4.3.2 SRTM digital elevation data

Outro fator relevante é a elevação do terreno no local sobre estudo, que influencia no uso e na ocupação do espaço agrícola. Neste sentido, foi utilizado o modelo digital de elevação (SRTM Plus) para obtenção do grau de elevação aplicando-se a função slop (Figura 12), que cria uma imagem mostrando a inclinação em graus de um terreno. Este plano de informação foi necessário para diminuir a confusão entre os alvos de interesse e os demais em regiões com muita declividade.

### 4.3.3 Simple non-iterative clustering (SNIC)

Com o intuito de auxiliar a diferenciação entre os alvos, antes da classificação aplicou-se uma segmentação no mosaico RGB falsa cor (Figura 12). O algoritmo de segmentação utilizado foi o Simple Non-Iterative Clustering (SNIC). Os parâmetros utilizados na aplicação do algoritmo da segmentação foram: Seeds, que é a quantidade de pixels semelhantes que pertencerão a cada cluster, o valor utilizado nesta variável teve a finalidade de abranger áreas menores, este valor foi de 25, os valores das demais variáveis seguiu os configurados no default; Size, que é o espaçamento de localização dos centros dos superpixel, em pixels o valor utilizado foi de 300; Compactness, que é o fator de compactação igual a 1; Connectivity, que é a conectividade entre clusters igual a 8; e Neighborhoodsize, que é o tamanho da análise da vizinhança do cluster referente às divisas dos mesmos, e foi nulo. Ao finalizar a segmentação se obtém uma imagem de resposta, contendo clusters (superpixels), a qual será uma das variáveis de entradas no processo de classificação

### 4.3.4 Amostragem dos alvos

A partir do mosaico falsa-cor RGB, selecionaram-se amostras de treinamento de forma aleatória direcionada estratificada (Figura 12), ou seja, que fossem totalmente de uma das culturas. Foram coletadas amostras em cada uma das microrregiões de forma independente, divididas em classes de alvos presentes no período em estudo. As amostras selecionadas têm formato de polígonos amostrais distribuídos pela região de estudo, sendo que cada amostra contém aproximadamente 30 pixels da imagem. As quantidades de amostras utilizadas por microrregião por classe de estudo são mostradas no Apêndice 1.

### 4.3.5 Classificação

A classificação foi realizada por microrregião utilizando-se o algoritmo Continuous Naive Bayes (Figura 12). Os dados de entrada do classificador foram: as amostras de treinamento; bandas B4 (0,64 – 0,67  $\mu\text{m}$ ), B5 (0,85 – 0,88  $\mu\text{m}$ ) e B6 (1,57 – 1,65  $\mu\text{m}$ ) do OLI ou bandas B8 (842  $\mu\text{m}$ ), B11(1610  $\mu\text{m}$ ) e B4 (665  $\mu\text{m}$ ) do MSI; a imagem segmentada e a imagem de slop (Figura 12). Dependendo da microrregião, imagens Sentinel não estavam disponíveis devido à grande presença de nuvens; nestas, foram utilizadas imagens do sensor OLI do satélite Landsat-8.

Após a classificação foram exportadas as máscaras binárias (0 e 1), onde o valor 1 é a cultura de interesse e 0 os demais alvos (Figura 12), obtendo, o mapeamento final por microrregião. Assim que se obtiveram todas as máscaras baixadas, utilizando o software ArcMap 10.0 (Figura 12), aplicou-se o filtro FocalStatistic circular 2 para eliminar ruídos presentes (Figura 12), como os pixels do mapeamento que estão isolados, longe dos demais.

Foram retiradas as áreas com menos que 5.000 m<sup>2</sup>, pois, na maioria das vezes, constituem de erros na classificação.

A área resultante obtida por cultura do mapeamento foi comparada com os dados oficiais (Figura 12) do IBGE disponíveis (<https://sidra.ibge.gov.br/>), a fim de se analisar a diferença entre os valores. Outra análise realizada foi utilizando da amostragem estratificada aleatória com 300 pontos verificados no mapeamento de milho primeira safra e 500 pontos na análise das culturas de inverno, 1.200 pontos verificados no mapeamento da soja e 1.000 pontos para o milho segunda safra e 500 pontos para os demais alvos, totalizando desta forma 2.000 pontos por safra verão e safra inverno, essa distribuição se deu devido à porcentagem de área de cada cultura referente a sua respectiva safra. Assim, para o estado, fez-se a matriz de confusão determinando a exatidão global (EG – Equação 1) e o índice kappa (Equação 2), os erros de Inclusão [EI] e Erros de Omissão [EO], tendo como referência terrestre imagens falsa-cor do Landsat-8 e Sentinel-2.

Para tanto, quantificou-se o erro médio (ME – Equação 3), erro quadrático médio (RMSE – Equação 4), o coeficiente de correlação de Pearson (r) e o índice de concordância melhorado de Willmott (dr – Equação 5), que mede a concordância entre a tendência (medida pela nuvem de pontos entre os dados oficiais e os mapeados – medida pela r) e a linha 1:1 de um gráfico de dispersão. Seus valores variam de zero (nenhuma concordância) a um (concordância perfeita).

$$EG = \frac{A}{m} * 100 \quad \text{Eq. (1)}$$

$$IK = \frac{[m * \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i * x_j)]}{[m^2 - \sum_{i=1}^r (x_i * x_j)]} \quad \text{Eq. (2)}$$

$$ME = \frac{1}{n} \sum_{i=1}^n (O - E) \quad \text{Eq. (3)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O - E)^2} \quad \text{Eq. (4)}$$

$$dr = 1 - \frac{\sum_{i=1}^n |E - O|}{2 \sum_{i=1}^n |E - O|} \quad \text{Eq. (5)}$$

em que: A - acerto geral (pontos amostrais com acertos); m - número de pontos amostrais; n - número de observações;  $x_{ij}$  - observação na linha  $i$  e coluna  $j$ ;  $x_i$  - total marginal da linha  $i$ ;  $x_j$  - total marginal da coluna  $j$ ; O - área colhida (soja e milho) informada pelo IBGE; E - área obtida pela máscara;

Também se validaram os mapeamentos realizados os comparando com dados de campo (Figura 11) levantados durante o período das safras de inverno 2017 e 2018, verão 2017/2018, utilizando as estatísticas r, dr, ME e RMSE.

## 5 RESULTADOS E DICUSSÃO

A princípio na realização do mapeamento foram utilizados índices de vegetação (EVI2, NDVI, SAVI) sem a segmentação e sem o modelo digital de elevação, porém os resultados obtidos em um estudo piloto apresentaram dois problemas. Ao mapear a cultura da soja utilizando os índices, observou-se confusão com áreas de pastagem em terrenos com inclinação elevada. Outro problema observado foi que talhões com variação no índice de vegetação foram classificados parcialmente, isto é, apenas uma parte do talhão era classificado corretamente, apresentando várias falhas em vez de uma área homogênea. Para solucionar esses problemas utilizaram-se imagens de elevação (SRTM+) e a segmentação das imagens RGB.

Outro fator importante observado foi a vantagem na utilização da plataforma online Google Earth Engine, a qual diminuiu consideravelmente a estrutura física necessária para a realização deste trabalho. Assim, não foi necessário baixar imagens de satélite para os computadores, pois os resultados dos testes e do mapeamento final são processados quase que instantaneamente, o que normalmente levaria horas para ser processado para grandes áreas em computadores. Este fato torna possível ao usuário realizar vários testes, com diferentes dados de entrada e/ou diferentes algoritmos e métodos de classificação, verificando com muita rapidez o resultado da simulação, tendo em vista que é feita a programação diretamente na plataforma GEE.

### 5.1 Mapeamento de verão

No mapeamento de verão do ano-safra 2016/2017 obteve-se uma área total de soja 4,17 milhões de ha (Figura 18a) contra 5,21 milhões de ha (Tabela 10) informados pelos dados oficiais (IBGE, 2018), ou seja, a área mapeada foi 1,04 milhões de ha (20%) menor que área oficial no estado do Paraná. Para o ano-safra 2017/2018, a área mapeada de soja foi de 4,57 milhões de ha (Figura 18b) contra 5,55 milhões de ha estimado pelos órgãos oficiais (IBGE, 2018); portanto, uma subestimação de 0,98 milhões de ha (18%). Entretanto, não foi possível a análise comparativa por municípios e mesorregiões para este ano-safra 2017/2018, pois os dados não foram disponibilizados ainda nesta granulometria.

As mesorregiões Oeste, Norte Central, Centro Ocidental e Centro-Sul (Tabela 10) possuem 59,3% de toda área semeada de soja do estado em 2016/2017, segundo os dados oficiais. Porém, pelo mapeamento existem 2,84 milhões de ha de soja nessas mesorregiões, ou seja, 68,2% da área do estado. Nestas, as diferenças de área (Tabela 10) variaram entre 2% (Oeste) e -17% (Norte Central) entre o mapeamento e os dados oficiais, totalizando uma subestimação de 249,5 mil ha (8%). As demais mesorregiões que apresentaram maiores porcentagens de diferenças entre os dados oficiais e os mapeados (Tabela 10) representam apenas 31,8% da área total mapeada. Por exemplo, a mesorregião Metropolitana de Curitiba,

que apresentou a maior diferença (Tabela 10), tem apenas 3,1% da área total de soja do Paraná, tendo baixa representatividade na área total.

Tabela 10 Área mapeada (ha) e oficial de soja por mesorregião para os anos-safra 2016/2017 e 2017/2018 e comparação entre áreas mapeadas dos anos-safra

Mesorregião	Área Mapeada (ha) [AM]		Área Oficial (ha) [AO]	Diferença (AM-AO) (ha)	Diferença (AM-AO) (%)	Diferença AM (ha) <sup>1</sup>	Diferença AM <sup>1</sup> (%)
	2016/17	2017/18		2016/17	2016/17		
Oeste	1.018.005	949.624	998.348	19.657	2	68.380	7
Norte Central	727.682	934.826	881.459	-153.777	-17	-207.145	-28
Centro Ocidental	551.228	529.260	646.928	-95.700	-15	21.966	4
Centro-Sul	546.499	479.899	566.270	-19.771	-3	66.599	12
Centro Oriental	300.996	331.574	495.135	-194.139	-39	-30.578	-10
Norte Pioneiro	345.499	340.847	483.048	-137.549	-28	4.650	1
Sudoeste	238.211	379.915	427.925	-189.714	-44	-141.704	-59
Sudeste	210.852	232.543	309.000	-98.148	-32	-21.691	-10
Noroeste	161.149	298.668	237.604	-76.455	-32	-137.520	-85
Metr. Curitiba	71.694	96.551	162.450	-90.756	-56	-24.857	-35
<b>Total</b>	<b>4.171.814</b>	<b>4.573.713</b>	<b>5.208.167</b>	<b>-1.036.353</b>	<b>-20</b>	<b>401.899</b>	<b>-10</b>

Nota: <sup>1</sup>(AM 2016/17 – AM 2017/18) ÷ AM 2016/2017.

A correlação linear (r) entre a área mapeada e a oficial, por município, foi de 0,92, mostrando uma proximidade entre os dados. Pelo índice de concordância melhorado de Willmott (dr), que relaciona a tendência entre os dados oficiais e os mapeados, obteve-se 0,81 (Figura 19a), ou seja, uma boa concordância. Isto mostra que embora tenha-se constatado diferenças na análise por mesorregiões (Tabela 10), quando faz-se a análise da área de soja mapeada e oficial, por município, identifica-se semelhança e mesma tendência de área de soja, pois a nuvem de pontos aproxima-se da linha 1:1 da Figura 19a, o que explica a alta concordância (dr). Destaca-se também que dos 399 municípios do estado, em 289 o mapeamento subestimou a área de soja referente aos dados oficiais, em 98 superestimou a área e em 12 deles os valores foram iguais. Segundo os dados oficiais, 19 municípios não possuem produção de soja, já no mapeamento encontrou-se 13 municípios sem área semeada de soja para o ano-safra 2016/2017.

Como os dados oficiais do ano-safra 2017/2018 não foram disponibilizados, fez-se uma análise entre este e o ano-safra 2016/2017 (Tabela 10 e Figura 19b). As quatro principais mesorregiões (Oeste, Norte Central, Centro Ocidental e Centro-Sul) responderam por 63% da área de soja de 2017/2018. Vê-se claramente a alta dinâmica intra-anual de produção de soja entre as mesorregiões do Paraná (Tabela 10), principalmente em relação às oscilações de preços das culturas (CONAB, 2018b), tendo em vista que entre os dois anos-safra houve variações entre -207 mil ha (Norte Central) e 68 mil ha (Oeste), o que totalizou cerca de 402 mil ha a mais de soja em 2017/2018. A correlação entre as áreas mapeadas nos dois anos-

safra foi de 0,93 com dr de 0,84 (Figura 19b), semelhante ao que foi encontrado entre os dados oficiais e a área de soja mapeada em 2016/2017.




Figura 18 Mapeamento de soja e milho primeira safra para os anos-safra 2016/2017 (a) e 2017/2018 (b).

Pelo erro médio (ME) verificou-se que a área total de soja foi subestimada no ano agrícola 2016/2017 (Figura 19a) em -2.598 ha. Já na comparação entre os anos-safra, o ME foi de 1.007 ha (Figura 19b), mostrando que para 2017/2018 houve maior área cultivada de soja em relação a 2016/2017. Valores semelhantes também foram encontrados por Johann et al. (2012), Patel et al. (2015) e Júnior et al. (2017) obtiveram valores de ME variando de 759 até 1.897 ha. O erro quadrático médio (RMSE) na comparação com os dados oficiais foi de 6.066 ha (Figura 19a), enquanto que na comparação entre as safras foi de 4.624 ha (Figura

19b), também semelhantes aos resultados obtidos por Johann et al. (2012), Patel et al. (2015) e Congalton e Green (2010), que observaram RMSE entre 1.346 ha e 6.573 ha.




Figura 19 Relação entre área mapeada e dados oficiais de soja no ano-safra 2016/2017 (a) e entre áreas mapeadas 2016/2017 e 2017/2018 (b).

O mapeamento da área total de milho primeira safra, do ano-safra 2016/2017, foi de 568,3 mil ha (Figura 18a) contra 550 mil ha (Tabela 11) informados pelos dados oficiais (IBGE, 2018), ou seja, a área oficial foi 18,2 mil ha (3,31%) maior que área oficial no estado do Paraná. Para o ano-safra 2017/2018, a área foi de 384.519 ha (Figura 18b) contra 330.201 ha informados pelos órgãos oficiais (IBGE, 2018); portanto, uma superestimação de 54.318 ha (16,4%). Também não foi possível a análise comparativa por municípios e mesorregiões para este ano-safra, pois os dados não foram disponibilizados ainda nesta granulometria pelos órgãos oficiais.

As mesorregiões Centro-Sul, Centro Oriental, Oeste, Sudeste e Sudoeste (Tabela 11) representam 71% de toda área semeada de milho do estado em 2016/2017, segundo os dados oficiais. Porém, pelo mapeamento foram encontrados 345.927 ha de milho primeira safra nessas mesorregiões, ou seja, 60,3% da área do estado. Nestas, as diferenças de área (Tabela 11) variaram entre 30% (Centro Oriental) e -51% (Centro Sul) entre o mapeamento e os dados oficiais, totalizando uma subestimação de 44.756 ha (-13%). As demais mesorregiões que apresentaram maiores porcentagens de diferenças entre os dados oficiais e os mapeados (Tabela 11) representam apenas 29% da área total mapeada. Por exemplo, a mesorregião Norte Central, que apresentou a maior diferença (Tabela 11), tem apenas 4,3% da área total de milho primeira safra do Paraná, tendo baixa representatividade na área total.

Como os dados oficiais do ano-safra 2017/2018 não foram disponibilizados, fez-se uma análise entre este e o ano-safra 2016/2017 (Tabela 11 e Figura 20b). A correlação entre as áreas mapeadas nos dois anos-safra foi de 0,77 com dr de 0,58 (Figura 20b), resultados melhores ao que foi encontrado entre os dados oficiais e a área de milho primeira safra mapeada em 2016/2017. A correlação linear (r) entre a área mapeada e a oficial, por município, foi de 0,59, mostrando uma média proximidade entre os dados. Pelo índice de concordância melhorado de Willmott (dr), que relaciona a tendência entre os dados oficiais e

os mapeados, obteve-se 0,53 (Figura 20a), ou seja, uma média concordância. Isto mostra que embora tenha-se constatado diferenças na análise por mesorregiões (Tabela 11), quando faz-se a análise da área de milho primeira safra mapeada e oficial, por município, identifica-se pouca semelhança, pois a nuvem de pontos não aproxima-se bem da linha 1:1 da Figura 20a.

Tabela 11 Área mapeada (ha) e oficial de milho primeira safra por mesorregião para os anos-safra 2016/2017 e 2017/2018 e comparação entre áreas mapeadas dos anos-safra

Mesorregião	Área Mapeada (ha) [AM]		Área Oficial (ha) [AO]	Diferença (AM-AO) (ha)	Diferença (AM-AO) (%)	Diferença AM (ha) <sup>1</sup>	Diferença AM <sup>1</sup> (%)
	2016/17	2017/18	2016/17	2016/17	2016/17		
Centro Sul	46.226	56.914	93.400	-47.173	-51	-10.687	-23
Centro Oriental	114.610	75.686	88.290	26.320	30	38.924	34
Oeste	47.310	25.462	75.446	-28.135	-37	21.848	46
Sudeste	60.398	34.493	69.600	-9.201	-13	25.905	43
Sudoeste	77.383	32.189	63.950	13.433	21	45.194	58
Metr. Curitiba	22.730	25.596	63.435	-40.704	-64	-2.866	-13
Norte Pioneiro	75.483	59.101	38.600	36.883	96	16.382	22
Centro Ocidental	45.985	26.061	29.083	16.902	58	19.924	43
Norte Central	78.211	49.012	23.545	54.666	232	29.199	37
Noroeste	5.644	6.332	4.764	880,08	18	-687	-12
Total	573.980	390.846	550.113	23.871	4	183.136	31

Nota: <sup>1</sup>(AM 2016/17 – AM 2017/18) ÷ AM 2016/2017.

Esse valor baixo das estatísticas indica que a área mapeada difere da área oficial. Se observou que o mapeamento apresentou áreas de milho em uma região, enquanto que os dados oficiais indicam outras regiões, como por exemplo: na microrregião de Guarapuava dados oficiais informam haver 69 mil ha de milho, porém, no mapeamento foram encontrados apenas 23,5 mil ha. Na microrregião de Jaguariaiva os dados oficiais dizem que se cultiva cerca de 18,6 mil ha; entretanto, foram encontrados 48 mil ha pelo mapeamento. Além disso, observaram-se também algumas inconsistências nos dados oficiais, por exemplo, o município de São Miguel do Iguaçu possui uma área de 45.636 ha de soja e 45.236 ha de milho primeira safra para 2016/2017, totalizando assim 90.872 ha de áreas agrícolas nesse município, portanto, valor superior a área territorial do município (85.417 ha). Para este município, foram mapeados, em 2016/2017 um total de 46.737 ha de área de soja e apenas 988 ha de milho, totalizando 47.724 ha. Em função desta inconsistência no dado oficial, os dados deste município foram desconsiderados no cálculo das estatísticas. Ao se compararem os dados por município verifica-se que o mapeamento superestimou a área de milho primeira safra em 289 dos municípios, em 12 deles não houve cultivo de milho primeira safra (ano-safra 2016/2017), e em 98 municípios o mapeamento subestimou a área de milho.




Figura 20 Relação entre área mapeada e dados oficiais de milho primeira safra no ano-safra 2016/2017 (a) e entre áreas mapeadas 2016/2017 e 2017/2018 (b).

Pelo erro médio (ME), verificou-se que a área total de milho primeira safra foi superestimada no ano agrícola 2016/2017 (Figura 20a) em 157 ha. Já na comparação entre os anos-safra o ME foi de 459 ha (Figura 20b), mostrando que para 2017/2018 houve menor área cultivada de milho primeira safra em relação a 2016/2017. Valores maiores foram encontrados por Johann et al. (2012), Patel et al. (2015) e Júnior et al. (2017), que obtiveram valores de ME variando de 759 até 1.897 ha. O erro quadrático médio (RMSE) na comparação com os dados oficiais foi de 2.062 ha (Figura 20a), enquanto que na comparação entre as safras o RMSE foi de 1.541 ha (Figura 20b), também semelhantes aos resultados obtidos por Johann et al. (2012), Patel et al. (2015) e Congalton e Green (2010), que observaram RMSE entre 1.346 ha e 6.573 ha.

Na avaliação da acurácia dos mapeamentos realizados, a Exatidão Global (EG), variou entre 90,5% (milho primeira safra 2017/2018) e 93,7% (soja 2016/2017) (Tabela 12), o que indica que das 2000 amostras utilizadas para avaliação de qualidade do mapeamento, esta proporção de amostras foram corretamente mapeadas. Já o índice kappa (K) variou entre 78% (milho primeira safra 2017/2018) e 84% (soja 2016/2017) (Tabela 12). Teluguntla et al. (2018) mapearam áreas agrícolas na Austrália e na China utilizando a plataforma online GEE e imagens Landsat-8. Na Austrália, obtiveram EG de 97,6% e na China EG de 94%. Huang et al. (2017) também utilizou a plataforma GEE para classificar a cobertura de uso do solo de Pequim, com EG de 86,61% e K de 0,82, obtendo resultados próximos aos dados relatados no Anuário Estatístico de Pequim em 2013. Xiong et al. (2017) mapearam, com imagens Modis, áreas agrícolas do continente Africano com EG superior a 89%; no entanto, ao comparar os resultados com outros estudos informaram que o mapeamento realizado tinha incertezas variando entre 15 e 25%.

Os melhores resultados foram obtidos para os mapeamentos de soja, que são considerados com concordância excelente (CONGALTON; GREEN, 2010). Já os mapeamentos de milho tiveram K menores considerados como concordância muito boa.

Tabela 12 Valores de exatidão global (EG), índice kappa (K) e erros de omissão e inclusão para os mapeamentos de soja e milho primeira safra

Cultura	Ano-safra	EG (%)	K	Erros de Omissão (%)	Erros de Inclusão (%)
Soja	2016/2017	93,7	0,84	6	3
	2017/2018	92,9	0,83	5	6
Milho Primeira Safra	2016/2017	92,9	0,84	7	18
	2017/2018	90,5	0,78	2	25

Para se compreender melhor as questões relacionadas à acurácia dos mapeamentos, determinaram-se os erros de omissão (EO) e erros de inclusão (EI). Os EO representam a proporção de amostras em que o alvo de interesse (soja ou milho) não foram mapeados pela metodologia aplicada. Já os EI referem-se àquelas amostras que foram mapeadas como sendo soja ou milho, porém, na inspeção visual das amostras eram outros alvos, como pastagem ou mata.

Neste trabalho, os erros de omissão variaram entre 2 e 7% (Tabela 12), respectivamente, para o milho primeira safra 2017/2018 e milho primeira safra 2016/2017, nos dois anos estudados, valores iguais aos encontrados por Teluguntla et al. (2018), que encontraram erros de omissão de 1,2%, assim, superestimando a área agrícola da Austrália, e 20% de EO para China. Já Júnior et al. (2017) e Johann et al. (2012) encontraram EO entre 3,6 e 13%.

Os erros de inclusão referem-se aquelas áreas que não eram de soja ou milho, mas que foram mapeadas como sendo destas culturas. Variaram de 3% (soja 2016/2017) a 25% (milho 2017/2018, Tabela 12), valores semelhantes aos encontrados por Júnior et al. (2017), Johann et al. (2012) e Teluguntla et al. (2018) que encontraram valores ente 3,5 e 21%. Os mapeamentos de soja tiveram menor proporção de erros de inclusão. Em contrapartida, os mapeamentos de milho tiveram confusão com áreas de matas presentes, principalmente, nas bordas dos talhões de milho, os quais acabaram apresentando comportamento semelhante ao do milho em certas regiões do estado. Portanto, ao analisar esses trabalhos que também estudaram uso e ocupação do solo por meio da plataforma GEE, constatam-se discordâncias com outros estudos e valores relativamente altos de erros de inclusão ou omissão.

Já na análise de comparação dos mapeamentos e dados de campo coletados durante as safras, a correlação entre a área mapeada de milho primeira safra no ano de 2017/2018 foi de 0,96 com dr de 0,86 (Figura 21a). A correlação entre os dados de campo e áreas de soja no ano-safra 2017/2018 foi de 0,96 com dr de 0,92 (Figura 21b). Pelo erro médio (ME), verificou-se que a área de milho primeira safra mapeada foi subestimada no ano agrícola 2017/2018 (Figura 21a) em -4,07 ha em relação aos dados de campo e o erro quadrático médio (RMSE) na comparação com os dados de campo foi de 8,5 ha. Já na comparação entre o mapeamento de soja e os dados de campo o ME foi de -3,05 ha (Figura 21b), mostrando

que houve menor área de soja mapeada do que se deveria haver, sendo o erro quadrático médio (RMSE) de 8,7 ha.




Figura 21 Relação entre dados de campo e área mapeada de milho primeira safra no ano-safra 2017/2018 (a) e entre dados de campo e áreas mapeadas de soja 2017/2018 (b).

## 5.2 Mapeamento de milho segunda safra e culturas de inverno

No mapeamento de inverno do ano-safra 2017 obteve-se uma área total de milho segunda safra de 2,178 milhões de ha (Figura 22a) contra 2,249 milhões de ha (Tabela 13) informados pelos dados oficiais (IBGE, 2018), ou seja, a área mapeada foi 71.414 mil ha (3,1%) menor que a área oficial no estado do Paraná. Para o ano-safra 2018 a área mapeada de milho segunda safra foi de 1,78 milhões de ha (Figura 22b) contra 2,11 milhões de ha estimado pelos órgãos oficiais (IBGE, 2018), portanto, uma subestimação de 323,8 mil de ha (15,3%). Entretanto, não foi possível a análise comparativa por municípios e mesorregiões para este ano-safra, pois os dados não foram disponibilizados ainda nesta granulometria.

Tabela 13 Área mapeada (ha) e oficial de milho segunda safra por mesorregião para os anos-safra 2017 e 2018 e comparação entre áreas mapeadas dos anos-safra

Mesorregião	Área Mapeada (ha) [AM]		Área Oficial (ha) [AO]	Diferença (AM-AO) (ha)	Diferença (AM-AO) (%)	Diferença AM (ha) <sup>1</sup>	Diferença AM <sup>1</sup> (%)
	2017	2018	2017	2017	2017		
Oeste	710.610	579.941	739.933	-29.322	-3,96	-130.669	-18,39
Norte Central	526.363	437.978	566.858	-40.494	-7,14	-88.384	-16,79
Centro Ocidental	359.164	264.077	365.790	-6.625	-1,81	-95.086	-26,47
Norte Pioneiro	210.770	177.847	228.235	-17.464	-7,65	-32.922	-15,62
Noroeste	81.144	134.090	171.509	-90.364	-52,69	52.945	65,25
Sudoeste	59.736	94.625	116.650	-56.913	-48,79	34.888	58,40
Sudeste	23.460	11.651	23.950	-489	-2,04	-11.809	-50,34
Centro Oriental	42.682	35.798	22.020	20.662	93,83	-6.883	-16,13
Centro-Sul	147.182	51.010	14.170	133.012	938	-96.17	-65,34
Metr. de Curitiba	17.575	0	0	17.575	100	-17.575	-100,00
Total	2.178.690	1.787.021	2.249.115	-70.424	-3,13	-391.669	-17,98

Nota: <sup>1</sup>(AM 2017 – AM 2018) ÷ AM 2017.

As mesorregiões Oeste, Norte Central, Centro Ocidental, Norte Pioneiro (Tabela 13) têm 84,5% de toda área semeada de milho segunda safra do estado em 2017, segundo os dados oficiais. Porém, pelo mapeamento existem 1,80 milhões de ha de milho nessas mesorregiões, ou seja, 82,9% da área do estado. Nestas, as diferenças de área (Tabela 13) variaram entre -1,8% (Centro Ocidental) e -7,6% (Norte Pioneiro) entre o mapeamento e os dados oficiais, totalizando uma subestimação de 93.908 milhões ha (4,9%). As demais mesorregiões que apresentaram maiores porcentagens de diferenças entre os dados oficiais e os mapeados (Tabela 13) representam apenas 17% da área total mapeada. Por exemplo, a mesorregião Centro Sul, Centro Oriental e Metr. Curitiba que apresentaram as maiores diferenças (Tabela 13), têm apenas 1,6% da área total de milho segunda safra do Paraná, tendo quase nenhuma representatividade na área total.




Figura 22 Mapeamento de milho segunda safra e culturas de inverno para os anos-safra 2017 (a) e 2018 (b).

A correlação linear ( $r$ ) entre a área mapeada e a oficial, por município, foi de 0,95, mostrando uma proximidade entre os dados. Pelo índice de concordância melhorado de Willmott ( $dr$ ), que relaciona a tendência entre os dados oficiais e os mapeados, obteve-se 0,83 (Figura 23a), ou seja, uma boa concordância. Isto mostra que, embora tenha-se constatado diferenças na análise por mesorregiões (Tabela 13), quando faz-se a análise da área de milho segunda safra mapeada e oficial, por município, identifica-se semelhança e mesma tendência de área de milho, pois a nuvem de pontos aproxima-se da linha 1:1 da Figura 23a, o que explica a alta concordância ( $dr$ ). Destaca-se também que dos 399 municípios do estado, em 217 o mapeamento subestimou a área de milho referente aos dados oficiais, em 156

superestimou a área e em 26 deles os valores foram iguais. Segundo os dados oficiais, 65 municípios não possuem produção de milho, já no mapeamento encontrou-se 31 municípios sem área semeada de milho para o ano-safra 2017.




Figura 23 Relação entre área mapeada e dados oficiais de milho segunda safra no ano-safra 2017 (a) e entre áreas mapeadas 2017 e 2018 (b).

Como os dados oficiais do ano-safra 2018 não estão disponíveis, fez-se uma análise entre este e o ano-safra 2017 (Tabela 13 e Figura 23b). As quatro principais mesorregiões (Oeste, Norte Central, Centro Ocidental, Norte Pioneiro) responderam por 69,1% da área de milho de 2018. Vê-se claramente a alta dinâmica intra-anual de produção de milho entre as mesorregiões do Paraná (Tabela 13), principalmente em relação às oscilações de preços das culturas (CONAB, 2018b), tendo em vista que entre os dois anos-safra houveram variações entre -130 mil ha (Oeste) e -96 mil ha (Centro Sul), o que totalizou cerca de 391 mil ha a mais de milho em 2018. A correlação entre as áreas mapeadas nos dois anos-safra foi de 0,94 com  $dr$  de 0,83 (Figura 23b), semelhantes ao que foi encontrado entre os dados oficiais e a área de milho mapeada em 2017.

Pelo erro médio (ME) verificou-se que a área total de milho foi subestimada no ano agrícola 2017 (Figura 23a) em -176,5 ha. Já na comparação entre os anos-safra, o ME foi de -981,63 ha (Figura 23b), mostrando que para 2018 houve menor área cultivada de milho em relação a 2017. O erro quadrático médio (RMSE) na comparação com os dados oficiais foi de 3.869 ha (Figura 23a), enquanto que na comparação entre as safras foi de 3.198 ha (Figura 23b).

O mapeamento da área total das culturas de inverno, do ano-safra 2017, foi de 1,07 milhões ha (Figura 22a) contra 1,06 milhões ha (Tabela 14) informados pelos dados oficiais (IBGE, 2018), ou seja, a área oficial foi 11,6 mil ha (1,09%) menor que a área mapeada no estado do Paraná. Para o ano-safra 2018, a área foi de 1,47 milhões ha (Figura 22b) contra 1,23 milhões ha informados pelos órgãos oficiais (IBGE, 2018); portanto, uma superestimação de 236.357 ha (19,16%). Também não foi possível a análise comparativa por municípios e mesorregiões para este ano-safra, pois os dados não foram disponibilizados ainda nesta granulometria pelos órgãos oficiais.

As mesorregiões Norte Central, Norte Pioneiro, Centro Oriental, Oeste e Centro Sul (Tabela 14) representam 75,5% de toda a área semeada de culturas de inverno em 2017, segundo os dados oficiais. Porém, pelo mapeamento foram encontrados 785.880 ha de culturas de inverno nessas mesorregiões, ou seja, 73% da área do estado. Nestas, as diferenças de área (Tabela 14) variaram entre -46% (Norte Pioneiro) e 38,2% (Centro Sul) entre o mapeamento e os dados oficiais, totalizando uma subestimação de 17.348 ha (2%). As demais mesorregiões que apresentaram maiores porcentagens de diferenças entre os dados oficiais e os mapeados (Tabela 14) representam apenas 24,5% da área total mapeada. Por exemplo, a mesorregião Noroeste e Sudeste, que apresentou a maior diferença (Tabela 14), tem apenas 10,6% da área total de culturas de inverno do Paraná, tendo pouca representatividade na área total.

Tabela 14 Área mapeada (ha) e oficial de culturas de inverno por mesorregião para os anos-safra 2017 e 2018 e comparação entre áreas mapeadas dos anos-safra

Mesorregião	Área Mapeada (ha) [AM]		Área Oficial (ha) [AO]	Diferença (AM-AO) (ha)	Diferença (AM-AO) (%)	Diferença AM (ha) <sup>1</sup>	Diferença AM <sup>1</sup> (%)
	2017	2018	2017	2017	2017		
Norte Central	236.613	177.646	228.717	7.896	3,45	-58.967	-24,92
Norte Pioneiro	182.636	60.080	182.682	-46	-0,03	-122.556	-67,10
Centro Oriental	105.559	229.475	146.560	-41.001	-27,98	123.917	117,39
Centro Sul	165.718	252.289	127.495	38.223	29,98	86.571	52,24
Oeste	95.355	178.628	117.774	-22.419	-19,04	83.273	87,33
Sudoeste	75.970	225.676	111.360	-35.390	-31,78	149.706	197,06
Centro Ocidental	109.205	210.821	91.038	18.167	19,96	101.615	93,05
Sudeste	97.918	110.454	43.194	54.724	126,69	12.536	12,80
Metr. de Curitiba	7.361	21.115	13.880	-6.519	-46,97	13.754	186,85
Noroeste	0	3.429	2.042	-2.042	-100,00	3.429	100,00
Total	1.076.335	1.469.612	1.064.742	11.593	1,09	393.277	37,50

Nota: <sup>1</sup>(AM 2017 – AM 2018) ÷ AM 2017.

Como os dados oficiais do ano-safra 2018 não estão disponíveis, fez-se uma análise entre este e o ano-safra 2017 (Tabela 14 e Figura 24b). A correlação entre as áreas mapeadas nos dois anos-safra foi de 0,72 com dr de 0,60 (Figura 24b). A correlação linear (r) entre a área mapeada e a oficial, por município, foi de 0,78, mostrando uma boa proximidade entre os dados. Pelo índice de concordância melhorado de Willmott (dr), que relaciona a tendência entre os dados oficiais e os mapeados, obteve-se 0,76 (Figura 24a), ou seja, uma boa concordância. Isto mostra que, embora tenha-se constatado diferenças na análise por mesorregiões (Tabela 14), quando faz-se a análise da área de culturas de inverno mapeada e oficial, por município, não identifica-se alta semelhança, pois a nuvem de pontos não aproxima-se bem da linha 1:1 da Figura 24a.




Figura 24 Relação entre área mapeada e dados oficiais de culturas de inverno no ano-safra 2017 (a) e entre áreas mapeadas 2017 e 2018 (b).

Pelo erro médio (ME), verificou-se que a área total de culturas de inverno foi superestimada no ano agrícola 2017 (Figura 24a) em 29,06 ha. Já na comparação entre os anos-safra, o ME foi de 981 ha (Figura 24b), mostrando que para 2018 houve maior área cultivada de culturas de inverno em relação a 2017. O erro quadrático médio (RMSE) na comparação com os dados oficiais foi de 2.840 ha (Figura 24a), enquanto que na comparação entre as safras o RMSE foi de 4.376 ha (Figura 24b).

Na avaliação da acurácia dos mapeamentos realizados, a Exatidão Global (EG) variou entre 95% (Cultura de inverno 2018) e 96,7% (milho segunda safra 2017) (Tabela 15) o que indica que das 2000 amostras utilizadas para avaliação de qualidade do mapeamento, esta proporção de amostras foram corretamente mapeadas. Já o índice kappa (K) variou entre 90% (culturas de inverno 2018) e 92% (milho segunda safra 2017) (Tabela 15). Todos os resultados que foram obtidos para os mapeamentos são considerados com concordância excelente (CONGALTON; GREEN, 2010).

Tabela 15 Valores de exatidão global (EG), índice kappa (K) e erros de omissão e inclusão para os mapeamentos de milho segunda safra e culturas de inverno

Cultura	Ano-safra	EG (%)	K	Erros de Omissão (%)	Erros de Inclusão (%)
Milho Segunda Safra	2017	96,7	0,92	3	2
	2018	96,4	0,91	2	3
Culturas de Inverno	2017	95,5	0,91	5	4
	2018	95,0	0,90	4	6

Neste trabalho, os erros de omissão variaram entre 2 e 5% (Tabela 15), respectivamente, para o milho segunda safra 2018 e as culturas de inverno 2017, nos dois anos estudados. Os erros de inclusão variaram de 2% (milho segunda safra 2017) a 6% (culturas de inverno 2017) (Tabela 15). Os mapeamentos de milho segunda safra teve menor proporção de erros de inclusão. Portanto, ao analisar esses trabalhos que também estudaram uso e ocupação do solo por meio da plataforma GEE, constatam-se discordâncias com outros estudos e valores relativamente altos de erros de inclusão ou omissão.

Já na análise de comparação dos mapeamentos e dados de campo coletados durante as safras, a correlação para as áreas mapeadas de culturas de inverno, no ano-safra 2017,

foi de 0,80 com dr de 0,72 (Figura 25a). A correlação entre os dados de campo e as áreas mapeadas de milho segunda safra no ano-safra 2017 foi de 0,79 com dr de 0,71 (Figura 25b). Pelo erro médio (ME), verificou-se que a área de culturas de inverno mapeada foi subestimada no ano agrícola 2017 (Figura 25a) em -12,12 ha em relação aos dados de campo, e o erro quadrático médio (RMSE) na comparação com os dados de campo foi de 23,5 ha. Já na comparação entre o mapeamento de milho segunda safra e os dados de campo, o ME foi de -7,00 ha (Figura 25b), mostrando que a área de milho mapeada foi menor que a real. O RMSE na comparação com os dados de campo foi de 13,20 ha.




Figura 25 Relação entre dados de campo e área mapeada de culturas de inverno no ano-safra 2017 (a) e entre dados de campo áreas mapeadas de milho segunda safra 2017 (b).

Na análise dos diagramas de dispersão (Figura 25), verifica-se a presença de áreas existentes em campo das culturas, mas que não foram mapeadas, o que claramente foi quantificado pelas estatísticas  $r$  e  $dr$ . A justificativa para isto, na maioria dos casos, foi de que que na data da imagem escolhida para realização do mapeamento da microrregião, essas áreas ainda não haviam atingido o máximo desenvolvimento vegetativo (período ideal para realização do mapeamento e separação de culturas semeadas na mesma época) ou haviam sido recentemente semeadas, o que faz com que a reflectância destas áreas seja diferente da demais e, sendo assim, não são selecionadas pelo classificador no mapeamento.

A correlação entre os dados de campo e áreas mapeadas de culturas de inverno no ano-safra 2018 foi de 0,71 com dr de 0,78 (Figura 26a). A correlação entre os dados de campo e áreas mapeadas de milho segunda safra, ano-safra 2018, foi de 0,88 com dr de 0,86 (Figura 26b). Pelo ME verificou-se que a área de culturas de inverno mapeada foi subestimada no ano agrícola 2018 (Figura 26a) em -13,8 ha em relação aos dados de campo, sendo a RMSE de 38,3 ha. Já na comparação entre o mapeamento de milho segunda safra e os dados de campo, o ME foi de -5,89 ha (Figura 26b), com o RMSE de 15,30 ha, mostrando que houve menor área de milho mapeada.




Figura 26 Relação entre dados de campo e área mapeada de culturas de inverno no ano-safra 2018 (a) e entre dados de campo áreas mapeadas de milho segunda safra 2018 (b).

Durante a validação com os dados de campo, percebeu-se alguns fatores climáticos ou formas de manejo das áreas influenciaram na subestimação dos mapeamentos. Entre esses fatores está a presença de nuvens nas imagens utilizadas tanto para o mapeamento de milho primeira safra e soja: como demonstrado nas Figura 27a e Figura 27b, a presença de nuvens influenciou diretamente no mapeamento de áreas, pois não se obtiveram imagens totalmente livres de nuvens no período de máximo desenvolvimento das culturas. Outra fonte de subestimação de áreas semeadas de milho em relação aos dados de campo foram áreas de milho silagem, como demonstrado na Figura 27c. A imagem utilizada no mapeamento foi a de máximo desenvolvimento vegetativo da cultura na microrregião mapeada; no entanto, na data desta imagem as áreas utilizadas para milho silagem já tinham sido cortadas, sendo assim não mapeadas.

Também observaram-se erros de inclusão em mapeamentos de milho, incluindo áreas de matas presentes nas bordas dos talhões e pequenas faixas florestais existentes no meio do talhão (Figura 27d). Esses erros de inclusão foram observados tanto na comparação com dados de campo, como na verificação da exatidão global e do índice kappa com as imagens falsa cor.

Já na comparação do mapeamento de soja com dados de campo, verificou-se que houve erros de omissão de áreas de soja em talhões que apresentavam grandes quantidades de terraços recém feitos ou reformados como demonstrado nas Figura 27e e Figura 27f. Por conta disto, estes talhões apresentaram grande desuniformidade nas imagens orbitais, o que fez com que o classificador não as identificasse completamente como áreas de soja.




Figura 27 Fatores que levaram a erros de classificação no mapeamento das culturas, detectados na validação com dados de campo.

## 6 CONCLUSÕES

A utilização da plataforma online Google Earth Engine (GEE) tornou o trabalho de mapeamento de culturas agrícolas mais rápido e versátil, com possibilidade de visualização dos resultados de forma instantânea, tornando mais dinâmicos a criação e os testes com diferentes planos de informação para mapeamentos de culturas. A plataforma GEE traz grande versatilidade, tendo em vista que permite que o usuário faça a programação para o fim desejado, além de existirem um grande número de processos já implementados e disponíveis para uso imediato.

A utilização da segmentação e a utilização do plano de informação slop nas imagens digitais de elevação trouxeram grandes melhorias no mapeamento das culturas estudadas, pois sem eles ocorriam confusões com outros alvos; entre elas, as regiões com pastagem em terrenos com alta declividade eram confundidas com soja e milho. Outro erro comumente observado sem a utilização desses planos de informação era o não mapeamento destas culturas em áreas com alta variabilidade na resposta espectral, seja por conta da presença de ervas daninhas ou a existência de curvas de nível nas áreas agrícolas que mostravam culturas com diferentes padrões espectrais em relação ao restante da área.

No começo do trabalho se objetivava realizar o mapeamento para o estado do Paraná de uma única vez, mas não foi possível, devido à grande variação de épocas de semeadura entre as regiões do estado. Sendo assim, não foi possível criar um único mosaico de forma automática para o estado que contemplasse todas as imagens de pico vegetativo de cada região e sem a presença de nuvens. Outro fator limitante para se realizar esse mapeamento para o estado é a limitação de memória da plataforma GEE, que se dá na quantidade de amostras de treinamento do classificador. Em um teste realizado com esta metodologia, a plataforma apresentou erro de “capacidade de memória excedida” já com um total de 14 amostras de treinamento, quantidade insuficiente para se obter uma boa classificação para todo o estado. Desta forma, para contornar essas limitações, optou-se por realizar o mapeamento por microrregião do estado, sendo possível se obter imagens que contemplem os picos vegetativos de cada região com o mínimo de nuvens possível, e não ter problemas com limites de amostras de treinamento para o classificador, tornando possível obter bons resultados na classificação.

Por fim, o mapeamento por meio do GEE mostrou ser possível mapear áreas com culturas de verão de forma rápida, precisa e eficiente. Os mapeamentos de soja apresentaram melhor acurácia espacial (EG e K) e menores erros de inclusão e omissão, quando comparados ao mapeamento de milho primeira safra no Paraná. Os resultados obtidos para o milho segunda safra e culturas de inverno não foram tão bons como os das culturas de verão, mas apresentaram também ótimos resultados, tanto na análise com dados oficiais, como também na comparação com os dados de campo. Pelos mapeamentos, é possível ter-

se a distribuição espacial das culturas por talhão das lavouras, bem como a quantificação de áreas por região de abrangência de uma empresa, município, microrregião, mesorregião e para todo o estado, o que pode ser usado como uma ferramenta de gestão de empresas ou como dados de área para órgãos oficiais.

Apesar dos resultados do mapeamento do milho terem sido piores do que para a soja, quando se compararam as áreas municipais de milho mapeado com os dados oficiais em 2016/2017, constataram-se inconsistências nos dados oficiais, pois a soma da área de soja e milho de um município foi maior que a área territorial do próprio.

## 7 CONSIDERAÇÕES FINAIS

Um obstáculo encontrado neste trabalho foi a grande presença de nuvens nas imagens orbitais, principalmente nas imagens utilizadas para realizar o mapeamento de culturas de verão, o que limitou consideravelmente a escolha de imagens que podiam ser utilizadas no processo de classificação. Outra limitação encontrada foi a grande variação de datas de semeadura e colheita para a mesma cultura de interesse, muitas vezes até mesmo dentro de uma mesma microrregião, o que resultou numa grande variabilidade de resposta espectral das culturas em função destas diferenças de datas e uso de diferentes cultivares, com ciclos de desenvolvimento muito diferentes, o que altera a época de ocorrência do máximo desenvolvimento vegetativo das culturas.

Com vistas a contornar estas limitações, sugere-se que em trabalhos futuros o processo de mapeamento seja realizado em várias datas próximas ao máximo desenvolvimento vegetativo das culturas, não em uma única imagem por mesorregião, como foi feito neste estudo. Com isto, espera-se que parte dos problemas que fizeram com que determinados talhões não fossem mapeados seja minimizada com a geração de um único mapeamento a partir de pelo menos duas imagens diferentes dentro do ciclo da cultura.

Também sugere-se o uso de imagens de maior resolução espacial e temporal, como as do sensor MODIS, que permitem a confecção de perfis espectro-temporais de índices de vegetação. Desta forma, estas informações poderiam entrar, juntamente com os demais planos de informação usados neste estudo, para melhorar algumas inconsistências que foram encontradas.

## 8 REFERÊNCIAS

- ACHANTA, R.; SUSSTRUNK, S. Superpixels and Polygons using simple non-iterative clustering. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Ic, **Anais** [...], 2017a. Disponível em: <http://ieeexplore.ieee.org/document/8100003/>. Acesso em: 23 abr. 2018.
- ACHANTA, R.; SUSSTRUNK, S. Superpixels and Polygons Using Simple Non-iterative Clustering. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Ic, **Anais** [...], 2017b. Disponível em: [http://openaccess.thecvf.com/content\\_cvpr\\_2017/papers/Achanta\\_Superpixels\\_and\\_Polygon\\_s\\_CVPR\\_2017\\_paper.pdf](http://openaccess.thecvf.com/content_cvpr_2017/papers/Achanta_Superpixels_and_Polygon_s_CVPR_2017_paper.pdf). Acesso em: 05 abr. 2018.
- AMO, S. de. **Técnicas de mineração de dados**. 2004. 43 p. Disponível em: <http://files.sistemas2012.webnode.com.br/200000095-bf367bfb43/Tecnicas de Mineração de Dados.pdf>. Acesso em: 15 jun. 2018.
- APARECIDO, L. E. de O.; ROLIM, G. S.; RICHETTI, J.; SOUZA, P. S.; JOHANN, J. A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, n. 4, p. 405-417, ago. 2016. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1413-70542016000400405&lng=en&nrm=iso&tlng=en](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-70542016000400405&lng=en&nrm=iso&tlng=en). Acesso em: 28 fev. 2018.
- BINAM MANDENG, E. P.; BIDJECK, L. M. B.; WAMBO, J. D. T.; JR, A. T.; BETSI, T. B.; IPAN, A. S.; NFADA, L. T.; DIEUDONNÉ, L. B. Lithologic and structural mapping of the Abiete–Toko gold district in southern Cameroon, using Landsat 7 ETM+/SRTM. **Comptes Rendus - Geoscience**, v. 350, n. 3, p. 130-140, 2018.
- BOUCKAERT, R. R. Naive Bayes Classifiers that perform well with continuous variables. **Advances in Artificial Intelligence**, n. Ai 04, p. 1089-1094, 2005.
- BRAGA, Í. A.; LADEIRA, M. **Um Modelo Adaptativo para a Filtragem de Spam**. Departamento de Ciência da Computação Universidade de Brasília, 2006.
- BRAZ, A. M.; BRAZ, A. M.; BARROS, M. H. S.; GARCIA, P. H. M. Validação das Classificações das Imagens dos Satélites Landsat 8 E Sentinel-2 na Bacia Hidrográfica do Córrego Ribeirãozinho/MS. **Revista Eletrônica AGB-TL**, v. 1, n. 26, p. 47-58, 2017. Disponível em: <http://seer.ufms.br/ojs/index.php/RevAGB/article/view/5286/4004>. Acesso em: 13 dez. 2018.
- CÂMARA, G. M. de S. **Introdução ao Agronegócio Soja**. Departamento de Produção Vegetal da USP/ESALQ, p. 1-29, 2015.
- CAMPONOGARA, A.; GALLIO, E.; BORBA, W. F.; GEORGIN, J. O atual contexto da produção de trigo no Rio Grande do Sul. **Revista eletrônica em gestão, educação e tecnologia ambiental**, v. 19, p. 246-257, 2015.
- CIRELO, M. C.; COZMAN, F. G. **Aprendizado de Semi-Supervisionado de Classificadores Bayesianos utilizando Testes de Independência**. Escola Politécnica da Universidade de São Paulo, 2003.
- COALIZÃO BRASIL. **MapBiomias lança dados inéditos sobre cobertura e uso do solo brasileiro**. Disponível em: <http://www.coalizaobr.com.br/home/index.php/boletim-n-22/430-mapbiomas-lanca-dados-ineditos-sobre-cobertura-e-uso-do-solo-brasileiro>. Acesso em: 17 abr. 2018.
- CONAB. **5º Levantamento - Safra 2017/18 - Grãos - Safra - 5 Levantamento**, Brasília,

2018a. Disponível em: [http://www.conab.gov.br/OlalaCMS/uploads/arquivos/18\\_02\\_08\\_17\\_09\\_36\\_fevereiro\\_2018.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/18_02_08_17_09_36_fevereiro_2018.pdf). Acesso em: 1 abr. 2018.

CONAB. **Acompanhamento da safra brasileira - Grãos - Safra - 12 Levantamento**. Brasília, 2018b.

CONAB. **Acompanhamento da Safra Brasileira - Grãos - Safra - 2017/2018 9 - Levantamento**. Brasília, 2018c.

CONGALTON, R. G.; GREEN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. **The Photogrammetric Record**, v. 25, n. 130, p. 204-205, 2010. Disponível em: [http://doi.wiley.com/10.1111/j.1477-9730.2010.00574\\_2.x](http://doi.wiley.com/10.1111/j.1477-9730.2010.00574_2.x). Acesso em: 08 dez. 2018.

CRIVELENTI, R. C.; COELHO, R. M.; ADAMI, S. F.; OLIVEIRA, S. R. M. Mineração de dados para inferência de relações solo-paisagem em mapeamentos digitais de solo. **Pesquisa Agropecuária Brasileira**, v. 44, n. 12, p. 1707-1715, 2009.

CRUZ, L. T. da; FERRARI, J. V.; MATOSO, A. de O. Qualidade e Composição Bromatológica do Milho em Diferentes Épocas de Corte. **Revista do Agronegócio**, v. 5, p. 67-75, 2016.

DE MORI, C.; IGNACSAK, J. C. **Aspectos econômicos do complexo agroindustrial do trigo. Trigo no Brasil: bases para produção competitiva e sustentável**, p. 41-76, 2011. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/931524/aspectos-economicos-do-complexo-agroindustrial-do-trigo>. Acesso em: 02 dez. 2018.

DE MORI, C.; MINELLA, E. **Aspectos econômicos e conjunturais da cultura da cevada**. Londrina: Embrapa Trigo, 2012.

ENGESAT. **Sentinel-2**. Disponível em: <http://www.engesat.com.br/sentinel-2/>. Acesso em: 18 maio. 2018.

ESA.INT. **Introducing Sentinel-2**. Disponível em: [https://www.esa.int/Our\\_Activities/Observing\\_the\\_Earth/Copernicus/Sentinel-2/Introducing\\_Sentinel-2](https://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel-2/Introducing_Sentinel-2). Acesso em: 20 abr. 2018a.

ESA.INT. **Sentinela-2 - Missões - Sentinel Online**. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>. Acesso em: 20 abr. 2018b.

FAO. **Perspectivas Agrícolas OCDE-FAO: Brasil superará a Estados Unidos como el mayor productor de soja para 2026**. Disponível em: <http://www.fao.org/americas/noticias/ver/es/c/979790/>. Acesso em: 17 abr. 2018.

FAOSTAT. **Crops**. Disponível em: <http://www.fao.org/faostat/en/#data/QC/visualize>. Acesso em: 28 nov. 2018a.

FAOSTAT. **Countries by commodity**. Disponível em: [http://www.fao.org/faostat/en/#rankings/countries\\_by\\_commodity](http://www.fao.org/faostat/en/#rankings/countries_by_commodity). Acesso em: 25 abr. 2018b.

FARR, T. G.; ROSEN, P. A.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY, S.; KOBRICK, M.; PALLER, M.; RODRIGUEZ, E.; ROTH, L.; SEAL, D.; SHAFFER, S.; SHIMADA, J.; UMLAND, J.; WERNER, M.; OSKIN, M.; BURBANK, D.; ALSDORF, D. The Shuttle Radar Topography Mission. **American Geophysical Union**, n. 2005, p. 1-33, 2007.

FAYAD, I.; BAGHDADI, N.; GOND, V.; BAILLY, J.; BARBIER, N.; HAJJ, M. E.; FABRE, F. Coupling potential of ICESat / GLAS and SRTM for the discrimination of forest landscape types

in French Guiana. **International Journal of Applied Earth Observations and Geoinformation**, v. 33, p. 21-31, 2014. Disponível em: <http://dx.doi.org/10.1016/j.jag.2014.04.005>. Acesso em: 17 abr. 2018.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. Knowledge Discovery and Data Mining: Towards a Unifying Framework. **Int Conf on Knowledge Discovery and Data Mining**, p. 82-88, 1996. Disponível em: <http://www.aaai.org/Papers/KDD/1996/KDD96-014>. Acesso em: 24 abr. 2018.

GOOGLE INC. **Google Earth Engine**. 2018a. Disponível em: <https://earthengine.google.com/>. Acesso em: 17 abr. 2018.

GOOGLE INC. **Google Earth Engine API**. 2018b. Disponível em: <https://developers.google.com/earth-engine/>. Acesso em: 17 abr. 2018.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, n. 202, p. 18-27, 2017.

HUANG, H.; CHEN, Y.; CLINTON, N.; WANG, J.; WANG, X.; LIU, C.; GONG, P.; YANG, J.; BAI, Y.; ZHENG, Y.; ZHU, Z. Mapping major land cover dynamics in Beijing using all Landsat images in Google Earth Engine. **Remote Sensing of Environment**, v. 202, p. 166-176, dez. 2017.

IBGE. **Paraná**. Disponível em: <https://cidades.ibge.gov.br/brasil/pr/panorama>. Acesso em: 17 abr. 2018.

IBGE. **Banco de Dados Agregados**. Disponível em: <https://sidra.ibge.gov.br/tabela/1612>. Acesso em: 25 abr. 2018.

IRONS, J. R.; DWYER, J. L.; BARSÍ, J. A. The next Landsat satellite: the Landsat Data Continuity Mission. **Remote Sensing of Environment**, v. 122, p. 11-21, 2012.

JOHANN, J. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, R. A. C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI / Modis. **Pesquisa Agropecuária Brasileira**, Brasília, n. 1, p. 1295-1306, 2012.

JÚNIOR, C. C.; ANTUNES, J. F. G.; JOHANN, J. A.; ESQUERDO, J. C. D. M. Mapping of Summer Agricultural Crops in the Alto Paraguai Basin Through Evi/Modis Time Series. **Especial - GeoPantanal**, v. 6, n. 3, p. 129-143, 2017.

KTH SPACE CENTER. **Lecture - Google Earth Engine | KTH**. Disponível em: <https://www.kth.se/en/sci/centra/rymdcenter/forelasningar-och-ev/lecture-google-earth-engine-1.687736>. Acesso em: 17 abr. 2018.

MALAHLELA, O. E.; ADJORLOLO, C.; OLWOCH, J. M. Mapping the spatial distribution of *Lippia javanica* (Burm. f.) Spreng using Sentinel-2 and SRTM-derived topographic data in malaria endemic environment. **Ecological Modelling**, v. 392, p. 147-158, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0304380018304083>. Acesso em: 20 dez. 2018.

MAPBIOMAS. **Projeto MapBiomas – Coleção [versão] da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil**. Disponível em: <http://www.mapbiomas.org/>. Acesso em: 17 abr. 2018.

MORI, C. de; FONTANELI, R. S.; SANTOS, H. P. dos. Aspectos econômicos e conjunturais da cultura da aveia. **Ministério da Agricultura, Pecuária e Abastecimento**, p. 18, 2012.

Disponível em: [http://www.infoteca.cnptia.embrapa.br/bitstream/doc/969149/1/2013\\_documentosonline142.pdf](http://www.infoteca.cnptia.embrapa.br/bitstream/doc/969149/1/2013_documentosonline142.pdf). Acesso em: 07 jun. 2018.

NASA. **U.S. Releases Enhanced Shuttle Land Elevation Data**. Disponível em: <https://www2.jpl.nasa.gov/srtm/>. Acesso em: 2 out. 2018.

OLIVEIRA, G. P. de; TAVARES, B. de A. C.; ARAÚJO, F. C. M. D. de. O uso de imagens Sentinel-2 e do software livre QGIS no zoneamento ambiental: um estudo de caso no município de São Bento, Paraíba, nordeste do Brasil. XVII Simpósio Brasileiro de geografia Física Aplicada. **Anais [...]**. p. 4871-4883, 2017.

PAPON, J.; WORGOTTER, A. A. F.; SCHOELER, M. Voxel cloud connectivity segmentation - Supervoxels for point clouds. IEEE Computer Society Conference on Computer Vision and Pattern Recognition. **Proceedings [...]**. p. 2027-2034, 2013.

PATEL, N. N.; ANGIULI, E.; GAMBA, P.; GAUGHAN, A.; LISINI, G.; STEVENS, F. R.; TATEM, A. J.; TRIANNI, G. Multitemporal settlement and population mapping from Landsat using Google Earth Engine. **International Journal of Applied Earth Observation and Geoinformation**, v. 35, p. 199-208, mar. 2015. Disponível em: <http://dx.doi.org/10.1016/j.jag.2014.09.005>. Acesso em: 18 nov. 2018.

PATIL, T. R. Performance Analysis of Naive Bayes and J48 Classification Algorithm for Data Classification. **International Journal of Computer Science and Applications**, v. 6, n. 2, p. 256-261, 2013. ISSN: 0974-1011. Disponível em: <http://keddiyan.com/files/AHCI/week2/9.pdf>. Acesso em: 26 jun. 2018.

PESSANHA, M. S.; SILVA, C. D. da. Mapeamento do uso e ocupação do solo utilizando imagens de satélite do Sensor Msi/Sentinel-2a para o município de Volta Redonda-RJ. 6º Simpósio de Gestão Ambiental e Biodiversidade. **Anais [...]**. p. 1-4, 2017.

RISH, I.; HELLERSTEIN, J.; JAYRAM, T. **An analysis of data characteristics that affect naive Bayes performance**. 2001. Disponível em: <http://web.cs.iastate.edu/~honavar/rish-bayes.pdf>. Acesso em: 19 jun. 2018.

SANTILLAN, J. R.; MAKINANO-SANTILLAN, M. Vertical accuracy assessment of 30-m Resolution Alos, Aster, and SRTM Global Dems over Northeastern Mindanao, Philippines. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLI-B4, p. 149-156, 2016. Disponível em: [https://www.researchgate.net/profile/Jojene\\_Santillan/publication/307530141\\_VERTICAL\\_ACCURACY\\_ASSESSMENT\\_OF\\_30-M\\_RESOLUTION\\_ALOS\\_ASTER\\_AND\\_SRTM\\_GLOBAL\\_DEMS\\_OVER\\_NORTHEASTER\\_N\\_MINDANAO\\_PHILIPPINES/links/57d755ac08ae0c0081ea84ee.pdf](https://www.researchgate.net/profile/Jojene_Santillan/publication/307530141_VERTICAL_ACCURACY_ASSESSMENT_OF_30-M_RESOLUTION_ALOS_ASTER_AND_SRTM_GLOBAL_DEMS_OVER_NORTHEASTER_N_MINDANAO_PHILIPPINES/links/57d755ac08ae0c0081ea84ee.pdf). Acesso em: 2 out. 2018.

SCHNEIBEL, A.; STELLMES, M.; RODER, A.; FRANTZ, D.; KOWALSKI, B.; HAB, E.; HILL, J. Assessment of spatio-temporal changes of smallholder cultivation patterns in the Angolan Miombo belt using segmentation of Landsat time series. **Remote Sensing of Environment**, v. 195, p. 118-129, 2017. Disponível em: <http://dx.doi.org/10.1016/j.rse.2017.04.012>. Acesso em: 02 jul. 2018.

SEAB. **SOJA - Análise da Conjuntura**. p. 1-6, 2018. Disponível em: [http://www.agricultura.pr.gov.br/arquivos/File/deral/Prognosticos/2018/Soja\\_2017\\_18.pdf](http://www.agricultura.pr.gov.br/arquivos/File/deral/Prognosticos/2018/Soja_2017_18.pdf). Acesso em: 18 dez. 2018.

SEAB; DERAL. **Previsão e Estimativa de Safras**, 2018a. Disponível em: <http://www.agricultura.pr.gov.br/modules/conteudo/conteudo.php?conteudo=75>. Acesso em: 15 dez. 2018.

SILVA, R.; AIRES, K.; SANTOS, T.; ABDALLA, K.; VERAS, R. Segmentação, classificação e detecção de motociclistas sem capacete. XI Simpósio Brasileiro de Automação Inteligente (SBAI 2013). **Anais** [...]. 2013.

TELUGUNTLA, P.; THENKABAIL, P. S.; OLIPHANT, A.; XIONG, J.; GUMMA, M. K.; CONGALTON, R. G.; YADAV, K.; HUETE, A. A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 144, p. 325-340, 2018. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2018.07.017>. Acesso em: 09 dez. 2018.

USGS - Science for a Changing World. **Landsat 8 | Landsat Missions**. Disponível em: <https://landsat.usgs.gov/landsat-8>. Acesso em: 26 maio 2018.

VANHELLEMONT, Q.; RUDDICK, K. Turbid wakes associated with offshore wind turbines observed with Landsat 8. **Remote Sensing of Environment**, v. 145, p. 105-115, 2014. Disponível em: <http://dx.doi.org/10.1016/j.rse.2014.01.009>. Acesso em: 26 maio 2018.

VASCONCELOS, Y. **Colaboração do céu**. Tecnologia Ciência da Computação, p. 64-69, 2015.

XIONG, J.; THENKABAIL, P. S.; GUMMA, M. K.; TELEGUNTLA, P.; POEHNELT, J.; CONGALTON, R. G.; YADAV, K.; THAU, D. Automated cropland mapping of continental Africa using Google Earth Engine cloud computing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 126, p. 225-244, 2017. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0924271616301575>. Acesso em: 17 nov. 2018.

YIN, H.; PRISHCHEPOV, A. V.; KUEMMERLE, T.; BLEYHL, B.; BUCHNER, J.; RADELOFF, V. C. Mapping agricultural land abandonment from spatial and temporal segmentation of Landsat time series. **Remote Sensing of Environment**, v. 210, p. 12-24, 2018.

## APÊNDICE 1

Tabela dos parâmetros utilizados no mapeamento de soja por microrregião no ano-safra 2016/2017

Microrregião	Satelite	DataIn	DataFim	% Nuvem	Classe Soja	Classe Milho	Classe Outros
Apucarana	S	31/12/16	30/01/17	10	8	5	3
Assai	S	31/12/16	30/01/17	40	4	2	3
Astorga	S	31/12/16	30/01/17	10	6	3	2
Campo Mourão	L	01/12/16	01/01/17	20	11	4	3
Capanema	L	31/12/16	30/01/17	10	10	7	5
Cascavel	L	31/12/16	15/01/17	20	7	3	3
Cerro Azul	L	31/12/16	28/02/17	20	2	2	3
Cianorte	L	01/12/16	01/01/17	20	6	2	2
Cornélio Procópio	S	01/12/16	10/01/17	40	3	3	2
Cornélio Procópio	S	31/12/16	15/02/17	20	11	6	8
Curitiba	L	31/12/16	28/01/17	20	4	3	3
Curitiba	L	01/12/16	28/01/17	30	3	2	2
Faxinal	S	31/12/16	28/01/17	20	4	3	4
Florai	L	01/12/16	01/01/17	30	3	2	3
Foz do Iguaçu	L	01/12/16	15/01/17	10	8	4	7
Francisco Beltrão	L	31/12/16	28/01/17	30	4	3	2
Francisco Beltrão	L	31/12/16	15/01/17	30	6	3	3
Goioerê	L	01/12/16	01/01/17	30	4	2	2
Guarapuava	S	01/12/16	15/02/17	30	4	2	4
Guarapuava	S	31/12/16	28/02/17	30	6	4	5
Guarapuava	L	01/12/16	28/02/17	30	4	2	5
Ibaiti	L	31/12/16	15/01/17	30	4	4	4
Irati	L	31/12/16	30/01/17	30	7	2	5
Ivaiporã	L	31/12/16	28/02/17	30	5	2	2
Ivaiporã	S	31/12/16	01/02/17	70	9	2	4
Jacarezinho	L	31/12/16	15/01/17	20	4	4	2
Jaguariaiva	L	31/12/16	01/02/17	10	4	4	2
Lapa	L	31/12/16	15/01/17	10	6	4	2
Londrina	S	31/12/16	31/01/17	20	4	2	3
Maringá	S	31/12/16	31/01/17	30	7	3	5
Palmas	L	31/12/16	01/02/17	50	6	3	5
Palmas	S	15/01/17	15/02/17	30	3	4	2
Paranaguá							
Paranavaí	L	01/12/16	01/01/17	10	3	3	2
Pato Branco	L	31/12/16	15/01/17	40	8	5	6
Pitanga	S	15/01/17	15/02/17	20	8	4	7
Pitanga	L	15/01/17	01/02/17	50	5	2	2
Ponta Grossa	L	31/12/16	01/02/17	20	5	1	4
Porecatu	S	31/12/16	31/01/17	10	5	2	3
Prudentópolis	L	31/12/16	15/01/17	10	6	3	3
Prudentópolis	S	15/01/17	28/02/17	15	4	2	3
Rio Negro	L	31/12/16	28/02/17	20	2	2	2
São Mateus do Sul	L	31/12/16	31/01/17	30	5	3	2
Telêmaco Borba	L	31/12/16	28/02/17	30	8	6	4
Toledo	L	01/12/16	15/01/17	10	10	3	4
Umuarama	L	15/12/16	15/01/17	30	9	5	3
União da Vitória	L	31/12/16	05/02/17	20	4	2	2
União da Vitória	S	31/01/17	28/02/17	20	5	4	3
Wenceslau Braz	L	15/12/16	15/01/17	20	2	2	2

Tabela dos parâmetros utilizados no mapeamento de Milho Primeira Safra por microrregião no ano-safra 2016/2017

Microrregião	Satelite	DataIn	DataFim	% Nuvem	Classe Milho	Classe Soja	Classe Outros
Apucarana	S	31/12/16	30/01/17	10	8	7	7
Assai	S	31/12/16	30/01/17	40	4	4	3
Astorga							
Campo Mourão	L	01/12/16	01/01/17	20	13	8	4
Capanema	L	01/12/16	01/01/17	20	13	3	4
Cascavel	L	01/12/16	15/01/17	10	4	3	2
Cerro Azul							
Cianorte							
Cornélio Procópio	S	01/12/16	15/02/17	30	3	2	2
Curitiba	L	31/12/16	28/01/17	20	7	3	2
Faxinal	S	31/12/16	28/01/17	20	6	6	2
Floraí	L	15/12/16	31/01/17	20	4	2	2
Foz do Iguaçu	L	01/12/16	15/01/17	20	4	2	6
Francisco Beltrão	L	31/12/16	15/01/17	20	5	6	2
Goioerê	L	31/12/16	15/01/17	20	6	5	2
Guarapuava	S	01/12/16	15/02/17	30	3	2	2
Guarapuava	S	31/12/16	28/02/17	30	3	2	2
Ibaiti	L	15/11/16	01/01/17	20	4	2	2
Irati	L	31/12/16	15/01/17	20	5	5	2
Ivaiporã	S	01/12/16	15/02/17	20	2	6	5
Jacarezinho	L	31/12/16	15/01/17	40	4	3	2
Jaguariaíva	L	31/12/16	15/01/17	40	5	5	3
Lapa	L	31/12/16	15/01/17	40	6	3	3
Londrina	S	31/12/16	31/01/17	20	4	5	2
Maringá	S	31/12/16	31/01/17	20	3	3	2
Palmas	L	31/12/16	15/01/17	40	4	2	1
Paranaguá							
Paranavaí							
Pato Branco	L	31/12/16	15/01/17	40	3	2	1
Pitanga	S	15/01/17	01/02/17	50	3	2	3
Pitanga	L	15/01/17	01/02/17	50	5	2	2
Ponta Grossa	L	31/12/16	01/02/17	20	4	2	2
Porecatu	S	31/12/16	31/01/17	10	6	4	2
Prudentópolis	L	01/12/16	01/02/17	20	9	4	4
Prudentópolis	S	01/11/16	01/01/17	20	3	3	2
Rio Negro	L	31/12/16	28/02/17	20	3	7	3
São Mateus do Sul	L	31/12/16	28/02/17	20	5	5	3
Telêmaco Borba	L	31/12/16	28/02/17	30	4	7	4
Toledo	L	01/12/16	15/01/17	10	6	3	2
Umuarama							
União da Vitória	S	01/12/16	28/02/17	20	4	5	3
Wenceslau Braz	L	01/12/16	15/02/17	20	6	4	2

Tabela dos parâmetros utilizados no mapeamento de soja por microrregião no ano-safra 2017/2018

Microrregião	Satelite	DataIn	DataFim	% Nuvem	Classe Soja	Classe Milho	Classe Outros
Apucarana	L	01/01/18	01/02/18	20	7	4	2
Assai	S	31/12/17	15/02/18	20	5	1	5
Astorga	L	01/12/17	01/02/18	20	6	4	3
Campo Mourão	S	15/12/17	15/01/18	30	8	6	7
Campo Mourão	S	31/12/17	01/02/18	10	5	4	5
Capanema	S	31/12/17	05/02/18	30	6	3	3
Capanema	L	15/12/17	05/02/18	30	6	2	3
Cascavel	L	01/12/17	15/01/18	40	3	4	2
Cascavel	S	15/01/18	01/02/18	30	4	4	4
Cerro Azul	S	01/01/18	15/01/18	30	4	3	3
Cianorte	L	01/12/17	01/02/18	70	5	3	3
Cianorte	L	15/12/17	28/02/18	70	4	6	4
Cianorte	S	15/12/17	30/01/18	20	5	3	3
Cornélio Procópio	L	01/12/17	30/01/18	20	5	4	3
Curitiba	S	01/01/18	01/02/18	30	5	5	3
Faxinal	S	15/01/18	31/01/18	30	4	7	5
Floral	S	15/01/18	05/02/18	30	4	4	3
Foz do Iguaçu	L	15/12/17	15/01/18	30	5	3	6
Francisco Beltrão	S	15/12/17	05/02/18	30	10	5	7
Francisco Beltrão	L	01/12/17	01/02/18	40	5	3	2
Goioerê	S	15/12/17	05/02/18	30	3	5	7
Goioerê	L	01/12/17	05/02/18	80	4	3	3
Guarapuava	S	15/01/18	15/02/18	30	6	3	3
Guarapuava	S	15/01/18	31/01/18	30	11	4	5
Guarapuava	L	31/12/17	31/01/18	30	5	4	3
Ibaiti	S	31/12/17	01/02/18	30	6	4	5
Irati	S	31/12/17	05/02/18	30	5	3	4
Irati	L	15/12/17	15/02/18	60	4	8	0
Ivaiporã	L	15/12/17	15/01/18	60	6	6	6
Jacarezinho	S	31/12/17	01/02/18	20	4	3	2
Jaguariaiva	S	01/01/18	31/01/18	30	5	4	4
Jaguariaiva	S	15/12/17	15/02/18	30	6	5	3
Lapa	S	01/01/18	31/01/18	30	5	6	5
Londrina	L	31/12/17	31/01/18	20	7	4	3
Maringá	L	31/12/17	31/01/18	20	5	3	3
Palmas	L	15/12/17	05/02/18	20	3	3	4
Palmas	S	01/01/18	31/01/18	30	5	4	3
Paranaguá							
Paranavaí	L	01/12/17	15/01/18	30	7	3	3
Pato Branco	S	01/01/18	31/01/18	30	5	3	3
Pitanga	S	15/12/17	05/02/18	20	8	3	4
Pitanga	S	01/01/18	28/02/18	10	6	2	4
Ponta Grossa	S	15/12/17	15/02/18	30	7	3	2
Ponta Grossa	S	31/12/17	31/01/18	30	4	5	2
Porecatu	L	31/12/17	31/01/18	50	4	3	3
Prudentópolis	S	31/12/17	28/02/18	30	6	5	4
Rio Negro	S	01/01/18	31/01/18	20	5	3	4
Rio Negro	L	31/12/17	28/02/18	30	4	3	3
São Mateus do Sul	S	01/01/18	15/02/18	30	3	3	3
São Mateus do Sul	S	01/01/18	31/01/18	30	6	5	6
Telêmaco Borba	S	31/12/17	28/02/18	30	5	6	4
Toledo	L	15/12/17	05/02/18	20	7	2	3
Toledo	S	15/12/17	05/02/18	60	5	0	3
Umuarama	L	01/12/17	05/02/18	20	4	3	3
União da Vitória	S	31/12/17	15/02/18	50	6	4	3
Wenceslau Braz	S	31/12/17	15/02/18	20	9	5	5

Tabela dos parâmetros utilizados no mapeamento de Milho Primeira Safra por microrregião no ano-safra 2017/2018

Microrregião	Satélite	DataIn	DataFim	% Nuvem	Classe Milho	Classe Soja	Classe Outros
Apucarana	L	01/01/18	01/02/18	20	5	3	2
Assai	S	31/12/17	15/02/18	20	2	5	3
Astorga							
Campo Mourão	L	01/12/17	01/01/18	20	6	9	2
Capanema	L	01/12/17	01/01/18	20	4	4	2
Cascavel	L	01/12/17	01/01/18	20	4	3	3
Cerro Azul							
Cianorte							
Cornélio Procópio	L	01/12/17	31/01/18	20	4	5	3
Curitiba	S	31/12/17	15/01/18	20	6	3	3
Faxinal	S	15/01/18	31/01/18	30	5	3	1
Floraí	S	15/01/18	31/01/18	30	5	8	4
Foz do Iguaçu	L	15/12/17	15/01/18	30	6	5	2
Francisco Beltrão	L	01/12/17	01/02/18	40	2	1	1
Goioerê	L	01/12/17	05/02/18	30	3	3	2
Guarapuava	L	01/12/17	05/02/18	30	6	4	2
Ibaiti	S	01/12/17	15/01/18	30	3	3	2
Irati	L	01/12/17	05/02/18	30	5	2	2
Ivaiporã	L	15/12/17	15/01/18	30	5	2	2
Jacarezinho	S	31/12/17	01/02/18	20	4	3	3
Jaguariaíva	S	15/12/17	15/02/18	30	3	3	3
Lapa	S	31/12/17	31/01/18	30	7	2	2
Londrina	L	31/12/17	31/01/18	20	3	2	2
Maringá	L	31/12/17	31/01/18	20	2	2	1
Palmas	L	31/12/17	31/01/18	20	3	2	2
Paranaguá							
Paranavaí							
Pato Branco	S	31/12/17	31/01/18	30	8	5	2
Pato Branco	L	01/12/17	31/01/18	20	7	2	2
Pitanga	S	15/12/17	31/01/18	20	5	4	2
Ponta Grossa	S	15/12/17	31/01/18	30	11	8	2
Porecatu							
Prudentópolis	S	01/12/17	01/02/18	15	3	3	4
Rio Negro	S	31/12/17	01/02/18	15	3	2	2
São Mateus do Sul	S	01/12/17	31/01/18	20	9	4	3
Telêmaco Borba	L	01/11/17	15/02/18	20	4	6	2
Toledo	L	01/12/17	15/01/18	30	4	2	2
Umuarama							
União da Vitória	S	31/12/17	15/02/18	20	5	3	2
Wenceslau Braz	S	01/12/17	15/01/18	20	4	7	2

Tabela dos parâmetros utilizados no mapeamento de culturas de inverno por microrregião no ano-safra 2017

Microrregião	Satélite	DataIn	DataFim	% Nuvem	Classe Cul. Inv.	Classe Outros
Apucarana	L	15/07/2017	01/08/2017	30	6	2
Assai	L	15/07/2017	01/08/2017	30	7	5
Astorga						
Campo Mourão	L	15/07/2017	01/08/2017	30	3	3
Capanema	L	15/07/2017	01/08/2017	30	7	3
Cascavel	L	15/07/2017	01/08/2017	30	5	6
Cerro Azul						
Cianorte						
Cornélio Procópio	L	15/07/2017	01/08/2017	30	2	3
Curitiba	L	15/07/2017	01/08/2017	30	4	3
Faxinal	L	15/07/2017	01/08/2017	30	5	3
Floraí	L	15/07/2017	01/08/2017	30	4	6
Foz do Iguaçu	L	15/07/2017	01/08/2017	30	5	3
Francisco Beltrão	L	15/07/2017	01/08/2017	30	2	2
Goioerê	L	15/07/2017	01/08/2017	30	5	3
Guarapuava	L	15/07/2017	01/08/2017	30	5	5
Ibaiti	L	15/07/2017	01/08/2017	30	4	3
Irati	L	15/07/2017	15/08/2017	15	5	4
Ivaiporã	L	15/07/2017	01/08/2017	15	5	4
Jacarezinho	L	15/07/2017	01/08/2017	15	5	3
Jaguariaíva	L	15/07/2017	01/08/2017	15	4	3
Lapa	L	15/07/2017	01/08/2017	20	3	2
Londrina	L	15/07/2017	01/08/2017	20	5	3
Maringá	L	15/07/2017	01/08/2017	20	4	4
Palmas	L	15/07/2017	01/08/2017	20	3	2
Paranaguá						
Paranavaí						
Pato Branco	L	15/07/2017	01/08/2017	20	4	2
Pitanga	L	15/07/2017	01/08/2017	20	2	3
Ponta Grossa	L	15/07/2017	01/08/2017	20	2	3
Porecatu						
Prudentópolis	L	15/07/2017	01/08/2017	20	4	2
Rio Negro	L	15/07/2017	15/08/2017	20	3	3
São Mateus do Sul	L	15/07/2017	15/08/2017	20	3	3
Telêmaco Borba	L	15/07/2017	01/08/2017	20	3	2
Toledo	L	15/07/2017	01/08/2017	20	4	2
Umuarama						
União da Vitória						
Wenceslau Braz	L	15/07/2017	01/08/2017	20	3	2

Tabela dos parâmetros utilizados no mapeamento de Milho segunda Safra por microrregião no ano-safra 2017

Microrregião	Satélite	DataIn	DataFim	% Nuvem	Classe Milho	Classe Outros
Apucarana	L	01/04/2017	01/06/2017	30	5	5
Assai	L	01/04/2017	01/06/2017	30	4	2
Astorga	L	01/04/2017	01/06/2017	20	4	2
Campo Mourão	L	01/04/2017	01/05/2017	20	4	3
Capanema	L	01/04/2017	01/05/2017	20	3	3
Cascavel	L	01/04/2017	01/05/2017	20	3	4
Cerro Azul						
Cianorte	L	01/04/2017	01/05/2017	50	4	4
Cornélio Procópio	L	01/04/2017	15/05/2017	20	4	2
Curitiba						
Faxinal	L	01/04/2017	15/05/2017	30	3	3
Florai	L	01/04/2017	01/05/2017	30	3	3
Foz do Iguaçu	L	01/04/2017	01/06/2017	20	3	2
Francisco Beltrão	L	01/04/2017	01/05/2017	20	3	2
Goioerê	L	01/04/2017	01/05/2017	20	3	2
Guarapuava	L	01/04/2017	01/06/2017	20	2	2
Ibaiti	L	01/04/2017	01/06/2017	20	2	4
Irati						
Ivaiporã	L	01/04/2017	01/05/2017	40	3	2
Jacarezinho	L	01/04/2017	01/05/2017	20	5	3
Jaguariaiva	L	01/04/2017	01/06/2017	50	2	2
Lapa	L	01/04/2017	01/06/2017	20	4	3
Londrina	L	01/04/2017	01/06/2017	20	3	2
Maringá	L	01/04/2017	01/06/2017	30	4	3
Palmas	L	01/04/2017	15/05/2017	20	2	2
Paranaguá						
Paranavaí	L	01/04/2017	01/05/2017	30	2	5
Pato Branco	L	01/04/2017	01/05/2017	30	2	3
Pitanga	L	01/04/2017	15/05/2017	20	3	3
Ponta Grossa	L	01/04/2017	01/06/2017	50	2	2
Porecatu	L	01/04/2017	01/06/2017	10	4	3
Prudentópolis	L	01/04/2017	01/06/2017	50	2	2
Rio negro	L	01/04/2017	01/06/2017	30	2	3
São Mateus do Sul	L	01/04/2017	01/06/2017	10	3	6
Telêmaco Borba	L	01/03/2017	01/06/2017	50	5	2
Toledo	L	01/04/2017	01/06/2017	20	4	2
Umuarama	L	01/04/2017	01/06/2017	20	3	3
União da Vitoria	L	01/04/2017	01/06/2017	10	2	2
Wenceslau Braz	L	01/03/2017	01/06/2017	30	4	2

Tabela dos parâmetros utilizados no mapeamento de culturas de inverno por microrregião no ano-safra 2018

Microrregião	Satélite	DataIn	DataFim	% Nuvem	Classe Cul. Inv.	Classe Outros
Apucarana	L	15/07/2018	01/08/2018	30	4	4
Assai	L	15/07/2018	01/08/2018	30	3	2
Astorga	L	15/07/2018	01/08/2018	30	3	2
Campo Mourão	L	15/07/2018	01/08/2018	30	3	4
Capanema	L	31/07/2018	31/08/2018	20	3	3
Cascavel	L	31/07/2018	31/08/2018	20	6	3
Cerro Azul						
Cianorte	L	31/07/2018	31/08/2018	20	3	3
Cornélio Procópio	L	31/07/2018	31/08/2018	20	3	3
Curitiba						
Faxinal	L	15/07/2018	01/08/2018	20	5	2
Florai	L	15/07/2018	01/08/2018	10	5	2
Foz do Iguaçu	L	15/07/2018	15/08/2018	20	2	2
Francisco Beltrão	L	15/07/2018	31/08/2018	30	5	2
Goioerê	L	15/07/2018	15/08/2018	8	4	5
Guarapuava	L	15/07/2018	31/08/2018	10	3	2
Ibaiti	L	15/07/2018	31/08/2018	10	2	3
Irati		15/07/2018	15/08/2018	8	3	2
Ivaiporã	L	15/07/2018	15/08/2018	8	3	1
Jacarezinho	L	15/07/2018	01/08/2018	20	4	2
Jaguariaiva	L	15/07/2018	15/08/2018	15	6	3
Lapa	L	15/07/2018	15/08/2018	15	4	5
Londrina	L	15/07/2018	15/08/2018	15	3	3
Maringá	L	15/07/2018	15/08/2018	15	5	2
Palmas	L	15/07/2018	15/08/2018	15	5	3
Paranaguá						
Paranavaí						
Pato Branco	L	15/07/2018	31/08/2018	30	5	3
Pitanga	L	15/07/2018	15/08/2018	10	3	3
Ponta grossa	L	15/07/2018	15/08/2018	10	5	3
Porecatu						
Prudentópolis	L	15/07/2018	15/08/2018	20	4	4
Rio negro	L	15/07/2018	15/08/2018	20	6	4
São Mateus do Sul	L	15/07/2018	15/08/2018	20	4	3
Telêmaco Borba	L	15/07/2018	15/08/2018	20	5	4
Toledo	L	15/07/2018	20/08/2018	10	7	3
Umuarama						
União da Vitoria	L	31/07/2018	31/08/2018	10	3	3
Wenceslau Braz	L	31/07/2018	31/08/2018	10	2	3

Tabela dos parâmetros utilizados no mapeamento de Milho Segunda Safra por microrregião no ano-safra 2018

Microrregião	Satélite	DataIn	DataFim	% Nuvem	Classe Milho	Classe Outros
Apucarana	L	01/04/2018	01/05/2018	30	3	2
Assai	L	01/04/2018	01/05/2018	30	4	2
Astorga	L	01/04/2018	01/05/2018	30	3	2
Campo Mourão	L	01/04/2018	01/05/2018	30	5	2
Capanema	L	01/03/2018	01/05/2018	10	6	3
Cascavel	L	01/04/2018	01/05/2018	10	3	2
Cerro Azul						
Cianorte	L	01/04/2018	01/05/2018	30	5	3
Cornélio Procópio	L	01/04/2018	15/05/2018	10	3	2
Curitiba						
Faxinal	L	01/04/2018	01/05/2018	20	3	2
Florai	L	01/04/2018	01/05/2018	20	4	3
Foz do Iguaçu	L	01/04/2018	01/05/2018	20	3	4
Francisco Beltrão	L	01/04/2018	01/05/2018	10	3	3
Goioerê	L	01/04/2018	01/05/2018	20	8	2
Guarapuava	L	01/04/2018	01/05/2018	20	5	4
Ibaiti	L	01/04/2018	01/05/2018	20	2	4
Irati	L	01/04/2018	01/05/2018	20	4	3
Ivaiporã	L	01/04/2018	01/05/2018	20	4	3
Jacarezinho	L	01/04/2018	01/05/2018	20	4	2
Jaguariaíva	L	01/04/2018	01/02/2018	20	6	3
Lapa						
Londrina	L	01/04/2018	01/05/2018	30	4	2
Maringá	L	01/04/2018	01/05/2018	20	4	3
Palmas	L	01/04/2018	01/05/2018	20	5	3
Paranaguá						
Paranavaí	L	01/04/2018	01/05/2018	20	4	2
Pato Branco	L	01/04/2018	01/05/2018	20	4	3
Pitanga	L	01/04/2018	15/05/2018	20	4	2
Ponta grossa	L	01/03/2018	01/06/2018	30	5	2
Porecatu	L	01/03/2018	01/05/2018	40	5	3
Prudentópolis	L	01/04/2018	01/06/2018	20	2	2
Rio negro						
São Mateus do Sul	L	01/03/2018	01/06/2018	30	4	4
Telêmaco Borba	L	01/03/2018	01/05/2018	30	3	2
Toledo	L	01/04/2018	01/05/2018	10	2	2
Umuarama	L	01/04/2018	01/05/2018	10	3	3
União da Vitoria						
Wenceslau Braz	L	01/04/2018	01/05/2018	10	2	2