

UNIVERSIDADE FEDERAL DO PARANÁ

THALIS DIAS VASCONCELOS

MAPEAMENTO DO USO E OCUPAÇÃO DO SOLO UTILIZANDO A PLATAFORMA  
DO GOOGLE EARTH ENGINE

JANDAIA DO SUL

2021

THALIS DIAS VASCONCELOS

MAPEAMENTO DO USO E OCUPAÇÃO DO SOLO UTILIZANDO A PLATAFORMA  
DO GOOGLE EARTH ENGINE

Trabalho de conclusão de curso apresentado ao curso de Graduação em Engenharia Agrícola, Campus Avançado de Jandaia do Sul, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Engenharia Agrícola.

Orientador: Prof. Dr. Carlos Henrique Wachholz de Souza

JANDAIA DO SUL

2021

V331m Vasconcelos, Thalís Dias  
Mapeamento do uso e ocupação do solo utilizando a plataforma do Google Earth Engine. / Thalís Dias Vasconcelos. – Jandaia do Sul, 2021. 37 f.

Orientador: Prof. Dr. Carlos Henrique Wachholz de Souza  
Trabalho de Conclusão do Curso (graduação) – Universidade Federal do Paraná. Campus Jandaia do Sul. Graduação em Engenharia Agrícola.

1. Geoprocessamento. 2. Sensoriamento remoto. 3. Landsat 8.  
I. Souza, Carlos Henrique Wachholz de. II. Título. III. Universidade Federal do Paraná.

CDD 631



UNIVERSIDADE FEDERAL DO PARANÁ

**PARECER Nº** 01/2022/UFPR/R/JA/CCEAG  
**PROCESSO Nº** 23075.000604/2022-00  
**INTERESSADO:** @INTERESSADOS\_VIRGULA\_ESPACO@

### TERMO DE APROVAÇÃO DE TRABALHO DE CONCLUSÃO DE CURSO

**Título: MAPEAMENTO DO USO E OCUPAÇÃO DO SOLO UTILIZANDO A PLATAFORMA DO GOOGLE EARTH ENGINE**

**Autor(a): THALIS DIAS VASCONCELOS**

Trabalho de Conclusão de Curso apresentado como requisito parcial para a obtenção do título de Bacharel em Engenharia Agrícola, aprovado pela seguinte banca examinadora:

Prof. Dr. Carlos Henrique Wachholz de Souza (Orientador)

Prof. Dr. André Luiz Justi

Prof. Dr. Marcelo José da Silva



Documento assinado eletronicamente por **ANDRE LUIZ JUSTI, PROFESSOR DO MAGISTERIO SUPERIOR**, em 06/01/2022, às 11:47, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **MARCELO JOSE DA SILVA, PROFESSOR DO MAGISTERIO SUPERIOR**, em 06/01/2022, às 12:16, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **CARLOS HENRIQUE WACHHOLZ DE SOUZA, PROFESSOR DO MAGISTERIO SUPERIOR**, em 06/01/2022, às 12:16, conforme art. 1º, III, "b", da Lei 11.419/2006.



A autenticidade do documento pode ser conferida [aqui](#) informando o código verificador **4165845** e o código CRC **2E294B0B**.

## **AGRADECIMENTOS**

Agradeço primeiro a Deus por ter me dado força e me guiado nesta jornada acadêmica.

Agradeço aos meus pais Osvaldo Martins de Vasconcelos e Suely Josefa Dias de Vasconcelos, e as minhas irmãs Thamiris Dias Vasconcelos e Thaís Dias de Vasconcelos pelo apoio e incentivo ao longo de todos esses anos.

Sou grato ao meu professor orientador Dr. Carlos Henrique W. de Souza pela confiança depositada em meu Projeto de Pesquisa, sem sua disposição, incentivo e principalmente conhecimento a mim transmitido, este trabalho não seria possível.

Agradeço ainda a todos os professores que colaboraram com a minha formação profissional e pessoal, a excelência do trabalho de vocês tornou este sonho uma realidade.

Por fim, mas não menos importante, deixo minha gratidão aos colegas de turma que tornaram esta longa jornada mais leve.

## RESUMO

Os mapas de uso e ocupação do solo são fundamentais para o monitoramento ambiental e para subsidiar a tomada de decisão em atividades agrícolas. Uma alternativa para a obtenção desses produtos de forma automatizada, sem demandar elevada capacidade computacional local (*in loco*), é o uso de plataformas de processamento em nuvem, como o Google Earth Engine (GEE). Essa ferramenta possibilita o desenvolvimento e a execução de algoritmos em um ambiente de programação com interface amigável e dinâmica, fornecendo resultados de maneira eficiente ao longo do processo de construção dos scripts. Nesse contexto, a aplicação de classificadores supervisionados, tais como Random Forest, Support Vector Machine e Classification and Regression Trees, permite a geração de mapas temáticos por meio da automatização das etapas de processamento em linhas de código, viabilizando análises ambientais em grandes escalas com resultados consistentes e reproduzíveis. Assim, este trabalho teve como objetivo elaborar um mapa de uso e ocupação do solo, com a quantificação das respectivas áreas, bem como comparar o desempenho de diferentes classificadores no mapeamento do território do Vale do Ivaí (PR), utilizando a plataforma GEE e imagens Landsat 8. A eficiência dos classificadores foi avaliada por métricas de acurácia, resultando na produção de mapas temáticos de uso e ocupação do solo. De modo geral, os algoritmos apresentaram elevado desempenho nas análises de acurácia, com destaque para o classificador Support Vector Machine, que obteve eficiência média de 98%.

**Palavras-chave:** Geoprocessamento; Sensoriamento Remoto; Landsat 8.

## **ABSTRACT**

Land use and land cover (LULC) maps are essential for environmental monitoring and for supporting decision-making in agricultural activities. Cloud-based processing platforms, such as Google Earth Engine (GEE), provide an efficient alternative for producing these maps in an automated manner without requiring high local computational capacity. GEE enables the development and execution of algorithms in a dynamic programming environment, facilitating near real-time inspection of results during script refinement. In this context, supervised classifiers - including Random Forest (RF), Support Vector Machine (SVM), and Classification and Regression Trees (CART) - allow the automation of key processing steps through code, enabling large-scale environmental analyses with consistent and reproducible outputs. This study aimed to generate a LULC map and quantify class areas for the Vale do Ivaí region (Paraná State, Brazil), as well as to compare the performance of different supervised classifiers within the GEE platform using Landsat 8 imagery. Classifier efficiency was assessed using accuracy metrics, resulting in thematic LULC products for the study area. Overall, the evaluated algorithms showed high accuracy, with SVM achieving the best performance, with an average efficiency of 98%.

**Keywords:** Geoprocessing; Remote Sensing; Landsat 8.

## LISTA DE FIGURAS

|                                                                                                             |    |
|-------------------------------------------------------------------------------------------------------------|----|
| FIGURA 1: LINHA DO TEMPO DA SÉRIE <i>LANDSAT</i> .....                                                      | 13 |
| FIGURA 2: INTERFACE DA PLATAFORMA DO <i>GOOGLE EARTH ENGINE</i> .....                                       | 16 |
| FIGURA 3: REPRESENTAÇÃO DE TOMADA DE DECISÃO DO CLASSIFICADOR<br>RF. ....                                   | 17 |
| FIGURA 4: REPRESENTAÇÃO DA TOMADA DE DECISÃO DO CLASSIFICADOR<br>SVM. ....                                  | 18 |
| FIGURA 5: MAPA DE LOCALIZAÇÃO DO VALE DO IVAÍ.....                                                          | 20 |
| FIGURA 6: FLUXOGRAMA DO DESENVOLVIMENTO DO ALGORITMO.....                                                   | 21 |
| FIGURA 7: SCRIPT DE SELEÇÃO DE IMAGENS. ....                                                                | 21 |
| FIGURA 8: <i>SCRIPT</i> DO ALGORITMO DE CRIAÇÃO DE MOSAICO.....                                             | 22 |
| FIGURA 9: <i>SCRIPT</i> DO ALGORITMO PARA DEMARCAÇÃO DA ÁREA DE<br>ESTUDO. ....                             | 22 |
| FIGURA 10: <i>SCRIPT</i> DO ALGORITMO PARA RECORTE DA ÁREA DE ESTUDO.....                                   | 22 |
| FIGURA 11: AMOSTRAS DA CLASSE SOJA UTILIZANDO AS BANDAS RGB - 456.<br>.....                                 | 23 |
| FIGURA 12: AMOSTRAGEM REALIZADA PARA ENSINAMENTO DOS<br>CLASSIFICADORES. ....                               | 24 |
| FIGURA 13: <i>SCRIPT</i> DE SEPARAÇÃO DE AMOSTRAGEM PARA TREINAMENTO<br>E TESTE.....                        | 24 |
| FIGURA 14: <i>SCRIPT</i> DO ALGORITMO PARA CHAMADA DO CLASSIFICADOR<br><i>RANDOM FOREST</i> .....           | 25 |
| FIGURA 15: <i>SCRIPT</i> DO ALGORITMO PARA CHAMADA DO CLASSIFICADOR<br><i>SUPPORT VECTOR MACHINE</i> . .... | 25 |
| FIGURA 16: <i>SCRIPT</i> DO ALGORITMO PARA CHAMADA DO CLASSIFICADOR<br>CART. ....                           | 25 |
| FIGURA 17: <i>SCRIPT</i> DO ALGORITMO PARA MÉTRICAS DE ACURÁCIA. ....                                       | 26 |
| FIGURA 18: <i>SCRIPT</i> DO ALGORITMO PARA EXPORTAÇÃO DO MAPA<br>CLASSIFICADO.....                          | 26 |
| FIGURA 19: <i>SCRIPT</i> DE SELEÇÃO DAS CLASSES.....                                                        | 26 |
| FIGURA 20: <i>SCRIPT</i> DO CÁLCULO DA ÁREA DE PIXELS EM KM². ....                                          | 27 |
| FIGURA 21: <i>SCRIPT</i> DE REDUÇÃO DE PIXELS DE UMA MESMA CLASSE EM<br>UMA ÚNICA.....                      | 27 |



|                                                                                                                                                                                                               |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 22: FLUXOGRAMA CONFECÇÃO DOS MAPAS.....                                                                                                                                                                | 27 |
| FIGURA 23: RESULTADO DA CLASSIFICAÇÃO E ÁREA GERADA UTILIZANDO<br>OS ALGORITMOS <i>RANDOM FOREST</i> (RF), <i>SUPPORT VECTOR<br/>MACHINE</i> (SVM) E <i>CLASSIFICATION AND REGRESSION TREE</i><br>(CART)..... | 28 |
| FIGURA 24: MAPA DE USO E OCUPAÇÃO DO SOLO (CART).....                                                                                                                                                         | 29 |
| FIGURA 25: MAPA DE USO E OCUPAÇÃO DO SOLO (RF).....                                                                                                                                                           | 30 |
| FIGURA 26: MAPA DE USO E OCUPAÇÃO DO SOLO (SVM).....                                                                                                                                                          | 33 |

## **LISTA DE TABELAS**

|                                                                          |    |
|--------------------------------------------------------------------------|----|
| TABELA 1: Áreas de cana de açúcar (CA) plantadas no ano de 2017 .....    | 29 |
| TABELA 2: Áreas de milho (M) e soja (S) plantadas no ano de 2017.....    | 31 |
| TABELA 3: Métricas de Acurácia para os classificadores.....              | 31 |
| TABELA 4: Erros de omissão e comissão obtidos pelos classificadores..... | 32 |

## **LISTA DE SIGLAS**

CART – Classification and Regression Tree

GEE – Google Earth Engine

RF – Random Forest

SR – Sensoriamento Remoto

SVM – Support Vector Machine

## SUMÁRIO

|                                                             |           |
|-------------------------------------------------------------|-----------|
| <b>1 INTRODUÇÃO .....</b>                                   | <b>10</b> |
| <b>2 OBJETIVO GERAL.....</b>                                | <b>11</b> |
| 2.1 OBJETIVOS ESPECÍFICOS .....                             | 11        |
| <b>3 REVISÃO DE LITERATURA .....</b>                        | <b>12</b> |
| 3.1 SENSORIAMENTO REMOTO ORBITAL .....                      | 12        |
| 3.2 SISTEMA LANDSAT .....                                   | 12        |
| 3.3 MAPEAMENTO DE USO E OCUPAÇÃO DO SOLO .....              | 13        |
| 3.4 GOOGLE EARTH ENGINE .....                               | 15        |
| 3.5 RANDON FOREST (RF) .....                                | 16        |
| 3.6 SUPPORT VECTOR MACHINE (SVM).....                       | 17        |
| 3.7 CLASSIFICATION AND REGRESSION TREES (CART).....         | 18        |
| <b>4 MATERIAIS E MÉTODOS .....</b>                          | <b>19</b> |
| 4.1 ÁREA DE ESTUDO.....                                     | 19        |
| 4.2 PLATAFORMA DO GOOGLE EARTH ENGINE .....                 | 20        |
| 4.3 CRIAÇÃO DO ALGORITMO .....                              | 20        |
| 4.4 SELEÇÃO DE IMAGENS.....                                 | 21        |
| 4.5 CRIAÇÃO DO MOSAICO E DERMACAÇÃO DA ÁREA DE ESTUDO ..... | 22        |
| 4.6 AMOSTRAGEM OU TREINAMENTO .....                         | 22        |
| 4.7 CLASSIFICAÇÃO.....                                      | 24        |
| 4.8 MÉTRICA DE ACURÁCIA.....                                | 25        |
| 4.9 CÁLCULO DA ÁREA.....                                    | 26        |
| 4.10 CONFECÇÃO DOS MAPAS .....                              | 27        |
| <b>5 RESULTADOS E DISCUSÃO .....</b>                        | <b>28</b> |
| <b>6 CONCLUSÕES.....</b>                                    | <b>34</b> |
| <b>7 REFERÊNCIAS BIBLIOGRÁFICAS.....</b>                    | <b>35</b> |

## 1 INTRODUÇÃO

A finalidade do sensoriamento remoto através de processamentos digitais é fornecer informações contidas nas imagens de satélites, para que posteriormente forneça dados que possam ser interpretados, facilitando a tomada de decisões importantes.

Uma dessas informações importantes, é o mapeamento do uso e ocupação do solo de uma determinada área de estudo. Esse mapeamento nos permite a obtenção da distribuição espacial de diferentes classes estudadas, como, solo exposto, diferentes culturas, corpos d'água e área florestais. Desse modo, algumas variáveis importantes podem ser estudadas por meio de uma avaliação temporal de um determinado evento natural, sendo eles, erosão do solo, desmatamento, degradação de pastagem, entre outros. Tais informações facilitam ações para correção ou prevenção desses eventos.

No entanto, o monitoramento de grandes áreas em um intervalo de tempo por meio de imagens de satélites, requer recursos computacionais elevados para a realização do processamento dos dados espaciais. A plataforma *Google Earth Engine* (GEE) possibilita essas análises em grandes escalas, utilizando-se de servidores da Google, além de fornecer uma interface interativa por meio de janelas e caixas de textos facilitando assim a confecção de algoritmos que otimizam o processamento computacional.

Vários métodos de classificação podem ser utilizados na plataforma para realização do mapeamento de uso e ocupação do solo, entre eles estão os classificadores supervisionados *Random Forest* (RF), *Support Vector Machine* (SVM) e *Classification and Regression Trees* (CART), onde cada um leva em consideração diferentes parâmetros e métodos para realizar a identificação e classificação previamente estabelecidas.

Desta forma, o objetivo do trabalho é avaliar a eficácia de cada um desses algoritmos de classificação em realizar o mapeamento do uso e ocupação na região do Vale do Ivaí -PR.

## 2 OBJETIVO GERAL

O objetivo geral desse estudo é a utilização da plataforma do *Google Earth Engine* para elaboração de um sistema automático de mapeamento da cobertura e interpretação do uso do solo.

### 2.1 OBJETIVOS ESPECÍFICOS

a) desenvolver algoritmo de classificação de imagens de satélite através da plataforma *Google Earth Engine*.

b) realizar o mapeamento do uso e ocupação do solo na região do Vale do Ivaí utilizando de diferentes algoritmos de classificação, como o *Random Forest* (RF), *Support Vector Machine* (SVM) e *Classification and Regression Trees* (CART) em imagens *Landsat 8*.

c) avaliar a eficiência dos classificadores por meio da análise de acurácia e definir qual ou quais tem o melhor desempenho na região de estudo.

### 3 REVISÃO DE LITERATURA

#### 3.1 SENSORIAMENTO REMOTO ORBITAL

O termo Sensoriamento Remoto (SR) surgiu no início dos anos 60, devido ao grande desenvolvimento na área espacial nos anos anteriores, ficou conhecida como a década da corrida espacial (MENESES; ALMEIDA, 2012).


O SR pode ser entendido como um conjunto de atividades computacionais que permitem a obtenção de informações da superfície terrestre através de imagens de satélites, sem a necessidade de contato direto com o alvo. Para isso, utiliza-se da aquisição e análise das interações eletromagnéticas da superfície “imageada”. (MORAES, 2002).

Sendo assim, a radiação eletromagnética (REM) ao interagir com a superfície terrestre pode sofrer absorção, reflexão e/ou transmissão de diferentes comprimentos de ondas dependendo dos elementos presentes na superfície, onde a proporção entre o fluxo de REM incidente e o fluxo que é refletido (Reflectância), é utilizado na identificação dos alvos em SR (GALO et al., 2002).

Dentre os equipamentos que apresentam capacidade de transformar a radiação eletromagnética em informações sobre o meio, podemos destacar os sensores imaginadores da série *Landsat* (USGS, 2020)..

#### 3.2 SISTEMA LANDSAT

Um dos sistemas orbitais mais utilizados é a série *Landsat*, que surgiu em meados da década de 60 através de um programa da *National Aeronautics and Space Administration* (NASA). Desde 23 de julho de 1972 o programa opera ininterruptamente fornecendo imagens orbitais gratuitas em seu acervo (Figura 1). Em 11 de fevereiro de 2013, a partir da base da Força Área de Vandenberg, Califórnia, lançou-se o *Landsat 8* conhecido como missão de continuidade de dados *Landsat*. Segundo o *United States Geological Survey* (USGS), 2020, esse satélite conta com dois novos sensores *Operational Land Imager* (OLI) - construído pela *Ball Aerospace & Technologies Corporation* e *Thermal Infrared Sensor* (TIRS) - construído pelo Centro de Voo Espacial Goddard da NASA.

FIGURA 1: LINHA DO TEMPO DA SÉRIE *LANDSAT*.

FONTE: USGS.

O sensor OLI do *Landsat 8* conta com uma resolução espacial de 30 metros, sendo as bandas 1,2,3,4,5,6,7 e 9 e a banda 8 pancromática com 15 metros. O sensor captura dados com precisão radiométrica aprimorada em uma faixa de 16 bits por pixel, permitindo uma melhor caracterização do estado e cobertura do solo. O sensor TIRS possui uma resolução espacial de 100 metros, sendo compostos por duas bandas, são elas, 10 e 11. Utilizado para coleta de dados de temperatura da superfície terrestre através de física quântica para a detecção do calor (USGS, 2020).

### 3.3 MAPEAMENTO DE USO E OCUPAÇÃO DO SOLO

Através de dados de SR é possível realizar o mapeamento do uso e ocupação do solo, que auxiliam tanto em pesquisas quanto em tomadas de decisões, inclusive políticas, no estudo e planejamento de estratégias para a área de estudo em questão (ALO; PONTIUS, 2008).

Um mapeamento de uso e ocupação do solo pode ser entendido como um processo técnico de análise e interpretação da superfície terrestre, por meio de



algoritmos de classificação ou por análise visual em imagens digitais aéreas ou orbitais (IBGE, 2013).

Na análise visual as informações são obtidas por técnicas de observação e desenvolvimentos lógicos, associando objetos por dedução, indução e analogia. Iniciamos com a localização do objeto, posteriormente com análises e informações complementares do mesmo, baseando-se em sua forma, tamanho, tonalidade, localização, textura e estrutura nos levando a fointerpretação (Panizza e Fonseca, 2011)

Por outro lado, na utilização de algoritmos de classificação supervisionada, o usuário precisa de informações prévias que permitem a identificação das classes de interesse, para o treinamento do classificador. Assim, o usuário deve identificar na imagem áreas representativas de cada classe (amostra). Já no método não-supervisionado o usuário não realiza o treinamento do classificador, as áreas escolhidas devem ser heterogêneas para assegurar todas as possíveis classes e suas variabilidades. As imagens a serem classificadas de treinamento são submetidas a um algoritmo de agrupamento ou “*clustering*” que determina numa feição espacial de dimensão igual ao número de bandas presentes, desta forma, assume-se que cada grupo ou “cluster” representa a distribuição de probabilidade de uma classe. (SPRING, 2020)

De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), 2013, o processo de classificação gera mapas temáticos que facilitam a identificação da distribuição espacial das classes mapeadas e na extração de dados de área dessas classes. Portanto, o levantamento de uso e ocupação fornecem dados que auxiliam em estudos de desmatamentos/reflorestamentos, acompanhamento de históricos agrícolas, degradação do solo, planejamentos de recuperações de encostas, entre outros.

Por apresentar grande relevância, além de ser uma técnica relativamente simples e eficiente, o mapeamento de uso e ocupação é utilizado por muitos autores em suas pesquisas. Como Abrão et al. (2015) que avaliaram diferentes tipos de classificadores supervisionados e não-supervisionados, na região sudoeste do Estado de Mato Grosso do Sul (MS), no mapeamento de uso e ocupação do solo por meio de dados do *Landsat 8/OLI*. Segundo os autores o algoritmo *Bhattacharya* obteve os melhores índices de acurácia, sendo que as imagens classificadas por fusões de bandas pancromáticas apresentam melhores desempenhos.

Da Cunha e Martins (2017) estudaram a influência dos diferentes tipos de dados e métodos no mapeamento de uso e ocupação da terra no estado de Goiás, concluíram que no período de 2011 a 2014 houve uma expansão da agricultura sobre a pastagem, e também a expansão da pastagem sobre a vegetação densa, isso devido ser uma área de intensa ocupação agrícola.

### 3.4 GOOGLE EARTH ENGINE


Uma alternativa para a obtenção desses mapas de forma automatizada e sem necessidade de grande capacidade computacional, é o uso de plataformas de processamento em nuvem como o *Google Earth Engine* (GEE). O GEE é uma plataforma baseada em nuvem para análises de dados ambientais em larga escala, além de fornecer conjuntos de dados e imagens orbitais gratuitamente para seus usuários (GEE, 2020). A plataforma possui uma infraestrutura computacional do Google para otimização do processamento de dados geoespaciais (GORELICK et. al., 2017)

O GEE conta também com uma *Application Programming Interface* (API) para as linguagens de programação *JavaScript* e *Python*, além de um *Integrated Development Environment* (IDE) online que permite rápida visualização de análises espaciais, utilizando-se da API (GEE, 2020).

Esta plataforma permite que os usuários executem seus algoritmos por meio de imagens e vetores georreferenciados, facilitando as análises com dados de diferentes estruturas. Além de fornecer uma biblioteca de algoritmos pré-definidos para serem aplicados, otimizando assim, o tempo no desenvolvimento e redução de linhas de *scripts* (GEE, 2020).

O editor de códigos é um ambiente interativo para o desenvolvimento de algoritmos, o painel central fornece o espaço para a escrita do *script*, acima possui botões de salvamento, executar e limpar os dados trabalhados. O mapa na parte inferior da interface contém as camadas inseridas pelo o *script*, no lado esquerdo fornece um painel com exemplos de códigos, ao lado direito, possui um tipo de inspetor, um console e um gerenciador de tarefas como mostrado na figura 2 (GEE, 2020).

FIGURA 2: INTERFACE DA PLATAFORMA DO GOOGLE EARTH ENGINE.



FONTE: O AUTOR (2021)

Muitos autores utilizaram a plataforma para criação de algoritmos, entre eles, Becker et al. (2019) utilizaram-se de imagens do *Landsat 8* para conhecer a proporção de uso do solo no município de Cascavel – PR. Concluíram-se, portanto, que a plataforma GEE permite a realização de várias simulações e visualizações rápidas devido seu processamento em nuvem.

De Oliveira et al. (2019) utilizaram-se do uso da plataforma e de imagens do *Landsat 8* e *Sentinel-2* para o mapeamento de uso e cobertura do solo de Moçambique, chegaram à conclusão que o GEE possibilitou o processamento e análise de um grande volume de dados, o que poderia ser inviável em um para um software com Sistema de Informação Geográfica (SIG) para *desktop*.

Para a confecção dos mapas de uso e ocupação do solo por meio da plataforma GEE são necessários classificadores, sendo que a plataforma disponibiliza vários em sua base de dados, alguns deles são, *Random Forest*, *Support Vector Machine*, *Classification and Regression Trees*, *Decision Tree*, *Neural Networks* entre outros.


### 3.5 RANDOM FOREST (RF)

No GEE podemos encontrar diversos algoritmos de classificação, entre eles está o *Random Forest* (RF). Ele é um algoritmo que se utiliza de aprendizado de

máquina (*Machine Learning*) que por meio de uma operação de *bootstrap*, cria várias árvores com base em conjuntos de classes de um treinamento supervisionado preliminar (ADELABU et. al.,2013).

Assim, cada árvore aumenta de acordo com a amostragem realizada para o treinamento, cada nó é dividido em subconjuntos com variáveis de entrada para as tomadas de decisões, em seguida, votam-se na classificação correta (Figura 3) (PAVLOV, 2019).

FIGURA 3: REPRESENTAÇÃO DE TOMADA DE DECISÃO DO CLASSIFICADOR RF.



FONTE: O AUTOR (2021)

Dessa forma, quanto melhor for a classificação supervisionada melhor será a precisão do classificador, resultando no aumento dos subconjuntos das árvores. Depois que um grande número de árvores for gerado, elas votam na classe mais popular, gerando as ditas florestas aleatórias (*Random Forest*) (BREIMAN, 2001).

Souza et al. (2017) utilizaram-se da plataforma GEE e de imagens do *Landsat 5,7 e 8* e MODIS para a realização da classificação supervisionada de uso e cobertura da terra em áreas não florestais do sudeste paranaense, por meio do classificador *Random Forest*, concluiu-se que a plataforma é uma ferramenta eficaz, pois, obteve uma acurácia de 68% para o classificador.


### 3.6 SUPPORT VECTOR MACHINE (SVM)

Outro algoritmo encontrado é o *Support Vector Machine* (SVM) que também consiste em uma técnica de *Machine Learning*. As aplicações desse método são

comparadas e muitas das vezes superiores a outros algoritmos de aprendizado, como a Rede Neural Artificial (RNA's) (LORENA e CARVALHO, 2007).

Para separar diferentes classes o SVM constrói um hiperplano no espaço multidimensional. O hiperplano ideal é obtido de maneira iterativa, buscando sempre a minimização do erro. A ideia central do SVM é encontrar um hiperplano marginal máximo (MMH), que faça uma melhor divisão do conjunto de dados em classes (Figura 4) (PAL e FOODY, 2010).

FIGURA 4: REPRESENTAÇÃO DA TOMADA DE DECISÃO DO CLASSIFICADOR SVM.



FONTE: O AUTOR (2021)

Rosa et al. (2017) realizaram comparações entre o algoritmo SVM e outros em software comercial e na plataforma GEE, utilizando-se de imagens do *Landsat 8* no município de São Paulo. Dentre os algoritmos estudados o SVM obteve os melhores resultados, e a plataforma do GEE alcançou precisão comparável e/ou superior a plataforma comercial.

### 3.7 CLASSIFICATION AND REGRESSION TREES (CART)

Por fim, o algoritmo *Classification and Regression Trees* (CART), que segue a mesma abordagem de outros classificadores que se utilizam de árvores preditivas (*Random Forest* e *Decision Tree*), foi introduzido pela primeira vez por Breiman et al. (1984).

Ele pode lidar com tarefas de classificação onde a variável de destino é uma "classe" e também regressão, onde a variável de destino é contínua e a árvore é usada para prever seu valor. O algoritmo aumenta em grande quantidade os ramos das árvores e as cortam (poda) em um tamanho onde tenha menor estimativa de erro (LOH, 2014). Onde esses erros podem ser estimados pelos métodos de Mínimos Quadrados ou Desvio Absoluto.

Já Pinheiro et al. (2019) utilizaram-se de imagens Planet na plataforma GEE para validar imóveis rurais na região do Mato Grosso do Sul – MS, através de alguns métodos de classificação supervisionada. Concluíram que os classificadores CART e RF tiveram os maiores valores de acurácia.


## **4 MATERIAIS E MÉTODOS**

### **4.1 ÁREA DE ESTUDO**

A área de estudo compreende o Vale do Ivaí-PR, na região sul do Brasil, norte do Paraná, com uma área de 7.385,05 km<sup>2</sup> correspondendo a 3,7% do território estadual (IPARDES, 2007). Mais de 90% do território encontra-se entre 300 m e 700 m de altitude, já a declividade de 0 a 10 % se encontra em 43,9% do território, 10 a 20% em 35,7% e as declividade mais acentuadas em 1,6% da área principalmente ao leste do vale (IPARDES, 2007).

O Vale do Ivaí é constituído por 26 municípios, configurando assim a Associação dos Municípios do Vale do Ivaí (AMUVI) no ano de 2018, sendo eles: Apucarana, Arapuã, Ariranha do Ivaí, Bom Sucesso, Borrazópolis, Califórnia, Cambira, Cruzmaltina, Faxinal, Godoy Moreira, Grandes Rios, Ivaiporã, Jandaia do Sul, Jardim Alegre, Kaloré, Lidianópolis, Lunardelli, Marilândia do Sul, Marumbi, Mauá da Serra, Novo Itacolomi, Rio Bom, Rio Branco do Ivaí, Rosário do Ivaí, São João do Ivaí e São Pedro do Ivaí (Figura 5).

FIGURA 5: MAPA DE LOCALIZAÇÃO DO VALE DO IVAÍ.



FONTE: O AUTOR (2021)


## 4.2 PLATAFORMA DO GOOGLE EARTH ENGINE

Para o desenvolvimento do trabalho foi utilizado o editor de códigos do GEE (code.earthengine.google.com) que é um Ambiente Integrado de Desenvolvimento (IDE) online tendo como base em sua programação API a linguagem Java script criado para facilitar o desenvolvimento de softwares. Nesse IDE temos a interface do usuário onde todo processo de criação do algoritmo é desenvolvido, desde chamadas de arquivos auxiliares até a exportação de resultados.

## 4.3 CRIAÇÃO DO ALGORITMO

Dessa forma, o algoritmo desenvolvido nesse trabalho pode ser dividido em algumas etapas principais, facilitando assim a sua construção e compreensão (Figura 6). Onde cada etapa é descrita como segue.

FIGURA 6: FLUXOGRAMA DO DESENVOLVIMENTO DO ALGORITMO.



FONTE: O AUTOR (2021)

#### 4.4 SELEÇÃO DE IMAGENS

Inicialmente as imagens utilizadas são retiradas do catálogo de dados do *Google Earth Engine*, fornecidos pela *United States Geological Survey* (USGS) e neste estudo foi utilizado um conjunto de imagens do *Landsat 8* 'LANDSAT/LC08/C01/T1\_SR'. Esse pacote já está corrigido atmosféricamente pelo *Surface Reflectance Code* (LASRC), evitando assim algumas variáveis que podem interferir na aquisição dos dados, como, nuvem, sombra e neve (USGS,2019). Para acesso a essa coleção é preciso realizar a chamada através de um script na interface do usuário (Figura 7). A série *Landsat* além de gratuita possui também o maior acervo de imagens de satélite devido a sua linha temporal ter iniciados por volta dos anos 60, com isso pode se realizar análises mais extensas podendo assim aprofundar em estudos com séries históricas.

FIGURA 7: SCRIPT DE SELEÇÃO DE IMAGENS.

```

4 //Importando uma coleção de imagens do banco de dados
5 var imagens1 = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
6   .filterDate('2018-12-01', '2019-05-30') // Período de Interesse
7   .filter(ee.Filter.lt('CLOUD_COVER',1)) // % Máx de Nuvens
8   .filterBounds(ee.Geometry.Polygon([
9     [[[-52.08424209373351, -23.295408026278366],
10      [-52.36439346092101, -24.32564008588756],
11      [-51.12843154685851, -24.590651902597862],
12      [-50.90870498435851, -23.49706868105338]]]]));
13
14 print('Imagens: ', imagens1);

```

FONTE: O AUTOR (2021)

O período de interesse trabalhado foi do dia 01 de dezembro de 2018 a 30 de maio de 2019, foram somente imagens sem nuvens para a análise.



#### 4.5 CRIAÇÃO DO MOSAICO E DERMACAÇÃO DA ÁREA DE ESTUDO

Cada imagem do *Landsat 8* possui dimensões de 185 km x 180 km (USGS,2019). Para abranger toda área de estudo necessita-se de duas imagens distintas. Assim, utilizamos um *script* para realização da criação do mosaico das imagens (Figura 8).

FIGURA 8: *SCRIPT* DO ALGORITMO DE CRIAÇÃO DE MOSAICO.

```
31 //mosaico
32 var mosaico = imagens1.mosaic();
```

FONTE: O AUTOR (2021)

Em seguida, é necessário limitar o processo de classificação somente na área de estudo. Para isso, inserimos um arquivo vetorial do Vale do Ivaí em formato *shapefile* (.shp) onde fazemos a chamada do mesmo na interface do usuário (Figura 9).

FIGURA 9: *SCRIPT* DO ALGORITMO PARA DEMARCAÇÃO DA ÁREA DE ESTUDO.

```
34 /// Inserindo Contorno do Vale by Assets\\
35 var vale = ee.FeatureCollection('users/carlaohws/Contorno_Vale');
36 Map.centerObject(vale, 9);
```

FONTE: O AUTOR (2021)

Para então, recortarmos o mosaico criado anteriormente, utilizando a função '*clip*' através do script na figura 10.

FIGURA 10: *SCRIPT* DO ALGORITMO PARA RECORTE DA ÁREA DE ESTUDO.

```
47 ///CLIP RASTER\\
48 var ROI = mosaico.clip(vale); // Recotar em função do Buffer
```


FONTE: O AUTOR (2021)

#### 4.6 AMOSTRAGEM OU TREINAMENTO

Para treinar os classificadores e posteriormente realizar a validação dos resultados, foram realizadas diversas amostragens de classes de uso e cobertura do solo. São elas: (Reflorestamento, Mata Nativa, Corpos d'água, Solo Exposto, Pastagem, Milho, Cana-de-açúcar e Soja). A classe solo exposto abrangem solo em estado de transição de culturas, em estados de descanso (sem cobertura vegetal), solo totalmente limpos e solos arenosos.

Essas amostras foram coletadas por interpretação visual nas imagens, tomando como base referências de campo realizadas previamente. As composições RGB das bandas do *Landsat 8* auxiliaram na identificação das amostras para cada classe de interesse, onde que por meio de cada composição facilita na identificação de cada cultura, como por exemplo, a classe soja que se destaca na composição RGB – 564 (Figura 11).


FIGURA 11: AMOSTRAS DA CLASSE SOJA UTILIZANDO AS BANDAS RGB - 456.



FONTE: O AUTOR (2021)

A mostras foram colhidas aleatoriamente dentro dos talhões que foram identificados de acordo com cada, considerando somente amostras de “pixels puros” onde foi selecionado somente no centro da amostra. Para cada classe foram coletadas aproximadamente 100 áreas (pequenos polígonos) de amostragem, escolhidas aleatoriamente dentro da área de estudo (Figura 12).

FIGURA 12: AMOSTRAGEM REALIZADA PARA ENSINAMENTO DOS CLASSIFICADORES.



FONTE: O AUTOR (2021)

## 4.7 CLASSIFICAÇÃO

Com base em todas as amostras coletadas foram utilizados dois polígonos amostrais diferentes, uma para treinamento e outra para testes. (Figura 12).

FIGURA 13: SCRIPT DE SEPARAÇÃO DE AMOSTRAGEM PARA TREINAMENTO E TESTE.

```

76 // Unindo as amostras treino
77 var amostras = Reflorestamento.merge(MataNativa).merge(Hidro).merge(SoloExposto).merge(Pastagem)
78 .merge(Milho).merge(Cana).merge(Soja);
79 print('Treino', amostras.size());
80
81 // Unindo as amostras teste(tst)
82 var amostras_tst = Reflorestamento_tst.merge(MataNativa_tst).merge(Hidro_tst).merge(SoloExposto_tst)
83 .merge(Pastagem_tst).merge(Milho_tst).merge(Cana_tst).merge(Soja_tst);
84 print('Teste', amostras_tst.size());

```

FONTE: O AUTOR (2021)

Foram utilizados alguns classificadores para criação do mapa de uso e ocupação do solo. Sendo eles o *Random Forest*, *Support Vector Machine* e o *Classification and Regression Trees*. As implementações desses classificadores são apresentadas nas Figuras 13, 14 e 15 a seguir.

FIGURA 14: *SCRIPT DO ALGORITMO PARA CHAMADA DO CLASSIFICADOR RANDOM FOREST.*

```

153 // Chamando e treinando o classificador "Random Forest"
154 var classificador = ee.Classifier.smileRandomForest({numberOfTrees:100,
155 variablesPerSplit:null, minLeafPopulation:1, bagFraction:0.5, maxNodes: null, seed:0}).train({
156   features: amostras,
157   classProperty: 'classe',
158   inputProperties: bandas
159 });

```

FONTE: O AUTOR (2021)

FIGURA 15: *SCRIPT DO ALGORITMO PARA CHAMADA DO CLASSIFICADOR SUPPORT VECTOR MACHINE.*

```

168 // Chamando e treinando o classificador "Support Vector Machine"
169 var classificador = ee.Classifier.libsvm({decisionProcedure:'Voting', svmType:'C_SVC',
170 kernelType:'POLY', shrinking:true, degree:2, gamma:null, coef0:2, cost:50
171 }).train({
172   features: amostras,
173   classProperty: 'classe',
174   inputProperties: bandas
175 });

```

FONTE: O AUTOR (2021)

FIGURA 16: *SCRIPT DO ALGORITMO PARA CHAMADA DO CLASSIFICADOR CART.*

```

161 // Chamando e treinando o classificador "Classification and Regression Tree"
162 var classificador = ee.Classifier.smileCart({maxNodes: null, minLeafPopulation:5}).train({
163   features: amostras,
164   classProperty: 'classe',
165   inputProperties: bandas
166 });

```

FONTE: O AUTOR (2021)

## 4.8 MÉTRICA DE ACURÁCIA

Para realizar a análise de acurácia das classificações será utilizado o método da matriz de confusão/erro consiste em uma tabela que mostra frequência de classificação para cada classe (CONGALTON, 1991). Para isso, duas amostragens foram realizadas, uma para treinamento do algoritmo e outra para testes. Posteriormente, será calculada a Exatidão Global (EG), que significa o total de acertos em relação ao total de amostras da imagem classificada, para o qual, segundo (Foody, 2002), o valor mínimo aceito que indica o sucesso da classificação é de 85%.

O índice *Kappa* sugerido por Landis e Koch (1977) afirmam que valores acima de 0,8 indicam que a classificação é muito boa, aproximando-se da realidade terrestre. Essas métricas podem ser chamadas para o algoritmo através do *script* apresentado na Figura 16.



FIGURA 20: *SCRIPT* DO CÁLCULO DA ÁREA DE PIXELS EM KM<sup>2</sup>.

```

294 //Calcular a área de pixels em quilômetro quadrado
295 var area_class0 = class0.multiply(ee.Image.pixelArea()).divide(1000*1000);
296 var area_class1 = class1.multiply(ee.Image.pixelArea()).divide(1000*1000);
297 var area_class2 = class2.multiply(ee.Image.pixelArea()).divide(1000*1000);
298 var area_class3 = class3.multiply(ee.Image.pixelArea()).divide(1000*1000);
299 var area_class4 = class4.multiply(ee.Image.pixelArea()).divide(1000*1000);
300 var area_class5 = class5.multiply(ee.Image.pixelArea()).divide(1000*1000);
301 var area_class6 = class6.multiply(ee.Image.pixelArea()).divide(1000*1000);
302 var area_class7 = class7.multiply(ee.Image.pixelArea()).divide(1000*1000);

```

FONTE: O AUTOR (2021)

FIGURA 21: *SCRIPT* DE REDUÇÃO DE PIXELS DE UMA MESMA CLASSE EM UMA ÚNICA.

```

304 //Reduzindo as estatísticas da sua área de estudo
305 var area0 = area_class0.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});
306 var area1 = area_class1.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});
307 var area2 = area_class2.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});
308 var area3 = area_class3.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});
309 var area4 = area_class4.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});
310 var area5 = area_class5.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});
311 var area6 = area_class6.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});
312 var area7 = area_class7.reduceRegion({reducer:ee.Reducer.sum(),geometry:vale,scale:30,maxPixels:1e9});


```

FONTE: O AUTOR (2021)

#### 4.10 CONFECÇÃO DOS MAPAS

O *software* QGIS auxiliou na confecção de mapas temáticos para facilitar a identificação e compreensão das classes dispostas. Para uma melhor visualização segue abaixo a fluxograma das etapas realizadas no programa (Figura 21).

FIGURA 22: FLUXOGRAMA CONFECÇÃO DOS MAPAS.




FONTE: O AUTOR (2021)



## 5 RESULTADOS E DISCUSSÃO

A Figura 23 apresenta os mapas classificados através da classificação supervisionada onde os algoritmos dos classificadores *Random Forest* (RF), *Support Vector Machine* (SVM) e *Classification and Regression Tree* (CART).

FIGURA 23: RESULTADO DA CLASSIFICAÇÃO E ÁREA GERADA UTILIZANDO OS ALGORITMOS *RANDOM FOREST* (RF), *SUPPORT VECTOR MACHINE* (SVM) E *CLASSIFICATION AND REGRESSION TREE* (CART).



FONTE: O AUTOR (2021)


Ao analisar a figura 24 o classificador CART apresenta uma concentração do plantio de Cana-de-açúcar na região Oeste do mapa, onde estão localizados os municípios que possuem maior área plantada segundo dados do IBGE/SIDRA (2017) como mostrados na tabela 1.

TABELA 1: ÁREAS DE CANA DE AÇÚCAR (CA) PLANTADAS NO ANO DE 2017.

| Município        | CA (ha) | Município         | CA (ha) | Município          | Área (ha) |
|------------------|---------|-------------------|---------|--------------------|-----------|
| Apucarana        | 29      | Godoy Moreira     | -       | Marumbi            | 3032      |
| Arapuã           | 450     | Grandes Rios      | -       | Mauá da Serra      | -         |
| Ariranha do Ivaí | -       | Ivaiporã          | -       | Novo Itacolomi     | -         |
| Bom Sucesso      | -       | Jandaia do Sul    | 2015    | Rio Bom            | -         |
| Borrazópolis     | -       | Jardim Alegre     | -       | Rio Branco do Ivaí | -         |
| Califórnia       | -       | Kaloré            | 695     | Rosário do Ivaí    | -         |
| Cambira          | 614     | Lidianópolis      | -       | São João do Ivaí   | 1516      |
| Cruzmaltina      | 50      | Lunardelli        | 190     | São Pedro do Ivaí  | 7431      |
| Faxinal          | 50      | Marilândia do Sul | -       |                    |           |

FONTE: IBGE/SIDRA.

FIGURA 24: MAPA DE USO E OCUPAÇÃO DO SOLO (CART).



FONTE: O AUTOR (2021)

Neves et al. (2019) utilizaram-se da plataforma GEE e de imagens do *Landsat 5* e *8* para relacionar mudanças de uso e cobertura do solo afetado pelas inundações ocorridas no Rio de Janeiro – RJ, através do algoritmo de classificação CART, apresentando dados satisfatórios de locais susceptíveis a inundações.

Os três classificadores apresentaram grandes quantidades da Classe Pastagem na região Sul do mapa e praticamente a mesma área, essa região é composta basicamente por terrenos irregulares o que dificulta a




produção/mecanização agrícola, restando somente a opção de criação extensiva de animais.

Já a classe de Corpos Hídricos nos três classificadores tem praticamente a mesma área classificada, isso se dá devido a classe ser bem definida em relação as outras classes de interesse, devido as características da reflectância da água os classificadores têm mais facilidade em diferenciar essa classe das demais.

Para a classe Milho os algoritmos RF e SVM tiveram a quantidade de áreas parecidas na classificação, pode-se observar uma zona de concentração dessa classe ao oeste do mapa logo abaixo da classe Cana-de-Açúcar (Figura 25).

FIGURA 25: MAPA DE USO E OCUPAÇÃO DO SOLO (RF).



FONTE: O AUTOR (2021)

Se confrontados com os dados do IBGE/SIDRA (2017), o município que teve maior área plantada é São João do Ivaí (15680 ha) onde se tem maior ocorrência da classe Milho. No município de Apucarana ao norte do mapa há uma incidência da classe soja totalizando uma área de 18200 ha plantada como mostrados na tabela 2.

TABELA 2: ÁREAS DE MILHO (M) E SOJA (S) PLANTADAS NO ANO DE 2017.

| Município       | M (ha) | S (ha) | Município         | M (ha) | S (ha) | Município          | M (ha) | S (ha) |
|-----------------|--------|--------|-------------------|--------|--------|--------------------|--------|--------|
| Apucarana       | 7600   | 18200  | Godoy Moreira     | 2200   | 4000   | Marumbi            | 480    | 3000   |
| Arapuã          | 1200   | 12000  | Grandes Rios      | 1100   | 4000   | Mauá da Serra      | 500    | 3900   |
| Airanhã do Ivaí | 1500   | 13500  | Ivaiporã          | 2190   | 19000  | Novo Itacolomi     | 2420   | 3900   |
| Bom Sucesso     | 2760   | 3850   | Jandaia do Sul    | 1750   | 4200   | Rio Bom            | 2750   | 5900   |
| Borrazópolis    | 4770   | 13700  | Jardim Alegre     | 2380   | 10100  | Rio Branco do Ivaí | 2500   | 6500   |
| Califórnia      | 1200   | 9100   | Kaloré            | 7030   | 10800  | Rosário do Ivaí    | 460    | 2500   |
| Cambira         | 2950   | 6950   | Lidianópolis      | 1920   | 5900   | São João do Ivaí   | 15680  | 19500  |
| Cruzmaltina     | 2100   | 10400  | Lunardelli        | 2130   | 5000   | São Pedro do Ivaí  | 5250   | 9000   |
| Faxinal         | 2300   | 15000  | Marilândia do Sul | 3700   | 21400  |                    |        |        |

FONTE: IBGE/SIDRA.

Vieira et al. (2017) através da plataforma GEE realizaram o mapeamento automático da agricultura nas fronteiras agrícolas do MATOPIBA (Maranhão, Tocantins, Piauí e Bahia). Por meio do algoritmo *Random Forest* para a classificação supervisionada em imagens do MODIS, detectaram o rápido avanço das lavouras entre 2002 e 2015 na região.

Na tabela 3 apresenta os resultados das métricas de acurácia das classificações realizadas sendo elas, Índice *Kappa*, Acurácia Global, Acurácia do Produtor (AP) e Acurácia do Usuário (AU). Os três métodos utilizados apresentaram índices de kappa e exatidão global acima de 85% o que se aproxima da realidade terrestre.

TABELA 3: MÉTRICAS DE ACURÁCIA PARA OS CLASSIFICADORES.

| Classificadores Otimizados                | Índice Kappa | Exatidão Global (%) | AP (%) | AU (%) |
|-------------------------------------------|--------------|---------------------|--------|--------|
| <i>Random Forest</i>                      | 0.96         | 96                  | 97     | 97     |
| <i>Support Vector Machine</i>             | 0.98         | 98                  | 98     | 98     |
| <i>Classification and Regression Tree</i> | 0.94         | 95                  | 96     | 95     |

FONTE: O AUTOR (2021)

Segundo Landis e Koch (1977) valores do coeficiente *Kappa* acima 0.8 indica que a classificação realizada é Muito Boa, aproximando-se da realidade terrestre, assim, observando-se os dados da Tabela 3 os três classificadores apresentaram valores de 0.96, 0.98 e 0.95 para os classificadores RF, SVM e CART, respectivamente, podendo assim ser considerados satisfatórios.

Pode-se, portanto, afirmar que as classificações realizadas pelos os algoritmos foram ótimas, aproximando-se muito da realidade terrestre devido aos valores do índice *kappa* está bem acima do valor considerado Muito Boa (0.8).

A Exatidão Global (EG) nos da informação do desempenho da classificação global do mapa em questão onde os valores superiores foram obtidos com os classificadores Otimizados. A Acurácia do Produtor (AP) indica a probabilidade de o pixel ter sido corretamente classificado no mapa. Já a Acurácia do Usuário (AU) indica com que frequência a classe no mapa estará realmente presente no solo ou em sua referência.

Analizando a classe Mata Nativa classificado pelo algoritmo CART, onde AP e AU foram de 96% e 95% respectivamente, ou seja, 96% dos pixels classificados como Mata Nativa foram corretamente classificados de acordo com o classificador, porém somente 95% dos pixels classificados tem a probabilidade de realmente serem essa classe em solo.

A tabela 4 apresenta os resultados obtidos de Erros de Omissão (EO) e Erros de Comissão (EC) para os classificadores estudados. Os EO são pixels que deixaram de ser classificados como a classe que realmente a pertence. Já EC são pixels que foram colocados em classes que não as pertencem.

TABELA 4: ERROS DE OMISSÃO E COMISSÃO OBTIDOS PELOS CLASSIFICADORES.


| Classificadores | RF     |        | SVM    |        | CART   |        |
|-----------------|--------|--------|--------|--------|--------|--------|
| Classes         | EO (%) | EC (%) | EO (%) | EC (%) | EO (%) | EC (%) |
| Reflorestamento | 0,3    | 0,1    | 0,2    | 1,2    | 0,3    | 1,1    |
| Mata Nativa     | 0,1    | 16,9   | 0,4    | 4,0    | 0,6    | 17,0   |
| Corpos Hídricos | 0,0    | 0,0    | 0,0    | 0,0    | 0,0    | 0,0    |
| Solo Exposto    | 0,0    | 1,4    | 0,1    | 0,2    | 4,6    | 2,5    |
| Pastagem        | 0,9    | 0,6    | 0,2    | 0,3    | 1,4    | 6,9    |
| Milho           | 18,1   | 0,0    | 6,9    | 0,9    | 18,9   | 1,9    |
| Cana-de-Açúcar  | 0,8    | 0,4    | 1,0    | 0,3    | 3,9    | 0,9    |
| Soja            | 0,5    | 3,1    | 0,3    | 3,5    | 2,3    | 3,4    |

FONTE: O AUTOR (2021)

O classificador RF obteve maior porcentagem de EO na classe Milho e EC na classe Mata Nativa, o CART obteve maior EO na classe Milho e EC na classe Mata Nativa, pode afirmar que essas duas classes são as mais fáceis do classificador confundir, devido ao valor reflectância dessas duas classes serem próximos, ou seja, deixa de classificar milho como sendo milho e em relação a classe Mata Nativa a classificá-la como sendo outra classe.

O SVM foi o que teve melhor desempenho de classificação, analisando a tabela 4 foi o classificador que obteve as menores porcentagens de EO e EC, ou seja, foi o que menos deixou de classificar pixels a classe que realmente a pertence, e o que menos colocou pixels em classes que não as pertencem, o que corrobora com o índice Kappa obtido pelo mesmo de 0.98, ou seja, quanto mais próximo de 1 melhor se aproxima da realidade terrestre, sendo o melhor entre os classificadores (Figura 26).

FIGURA 26: MAPA DE USO E OCUPAÇÃO DO SOLO (SVM).



FONTE: O AUTOR (2021)

Moreira et al. (2014) realizaram classificação temporal de uso e ocupação do solo na bacia do Rio Vieira através do *software* ENVI 5.0, utilizando-se de imagens do *Landsat 5* e do algoritmo de classificação *Support Vector Machine*, o estudo apresentou dados satisfatórios de Índice *Kappa* de 0.90 para imagens de 2010 e uma Exatidão Global de 93%.

## 6 CONCLUSÕES

A plataforma do *Google Earth Engine* demonstrou ser de fácil manuseio e de interface totalmente amigável para criação dos algoritmos, além de um tempo de resposta relativamente rápido de acordo com o estudo apresentado. O banco de dados em nuvem das imagens de satélite otimiza e muito o tempo de processamento, além de não ser necessário o *download* para poder utilizá-las.

Diante dos três métodos de classificações supervisionadas estudados *Random Forest* (RF), *Support Vector Machine* (SVM) e *Classification and Regression Tree* (CART), o classificador de melhor desempenho foi SVM que apresentou Índice Kappa 0.98, seguido pelo RF com 0.96 e por fim o CART com 0.94. Sendo que ainda o menor erro de EC e EO é do SVM seguido pelo RF e CART.

Os estudos de diversos tipos de classificadores nos mostram que há variações principalmente em áreas classificadas quando se fala de mapeamento de uso e ocupação do solo, tanto visualmente quanto quantitativamente na elaboração dos mapas. Assim os estudos de suas métricas de acurácia e exatidões torna-se necessários para tomadas de decisões referentes a Uso e Ocupação do Solo, e também para escolha do melhor classificador de acordo com as classes a serem estudadas.

Portanto a plataforma GEE demonstrou-se ser uma ferramenta eficaz tanto na classificação quanto na geração dos mapas, onde que por meio de algumas linhas de códigos pode realizar o mapeamento de grandes áreas com uma confiabilidade boa.

## REFERÊNCIAS BIBLIOGRÁFICAS

ABRÃO, C. M. R.; CUNHA, E. R. DA; GREGÓRIO, E. C.; BACANI, V. M. **Avaliação de classificadores supervisionados e não supervisionados para mapeamento de uso e cobertura da terra a partir de dados Landsat-8/OLI**. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE, n. 1, p. 5439–5446, 2015.

ADELABU, S.; MUTANGA, O.; ADAM, E.; CHO, M. A. Exploiting machine learning algorithms for tree species classification in a semiarid woodland using RapidEye image. **Journal of Applied Remote Sensing**, v. 7, n. 1, p. 073480, 2013.

ALO, C. A.; PONTIUS, R. G. Identifying Systematic Land-Cover Transitions Using Remote Sensing and GIS: The Fate of Forests inside and outside Protected Areas of Southwestern Ghana. **Environment and Planning B: Planning and Design**, v. 35, n. 2, p. 280–295, 2008.

BECKER, W. R.; CARVALHO, L. E. DE; JOHANN, J. A.; et al. **Google Earth Engine Como Instrumento De Classificação Uso E Cobertura Do Solo No Município De Cascavel, Paraná, BRASIL** | Galoá Proceedings. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, n. April, p. 1–4, 2019. Disponível em: <<https://proceedings.science/sbsr-2019/papers/google-earth-engine-como-instrumento-de-classificacao-uso-e-cobertura-do-solo-no-municipio-de-cascavel--parana--brasil>>.

BREIMAN, L. E. O. Random Forests. **Machine Learning**, v. 45, p. 5–32, 2001.

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. **Classification And Regression Trees**. 1o ed. Routledge, 1984.

CONGALTON, R. G. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. **Remote Sensing of Environment**, v. 37, p. 35–46, 1991.

DA CUNHA, R. B.; MARTINS, C. A. A. INFLUÊNCIA DOS DADOS E MÉTODOS NO MAPEAMENTO DO USO E DA COBERTURA DA TERRA. **RA'E GA - O Espaço Geografico em Análise**, v. 39, p. 43–56, 2017.

DE OLIVEIRA, W. N.; MIZIARA, F.; FERREIRA, N. C. **Mapeamento do Uso e Cobertura do Solo de Moçambique Utilizando a Plataforma Google Earth Engine**. Anuario do Instituto de Geociencias, v. 42, p. 336–345, 2019. Disponível em: <[https://www.scopus.com/inward/record.uri?eid=2-s2.0-85068560879&doi=10.11137%2F2019\\_1\\_336\\_345&partnerID=40&md5=e3bb787b3a13c538735b22a1667e72a9](https://www.scopus.com/inward/record.uri?eid=2-s2.0-85068560879&doi=10.11137%2F2019_1_336_345&partnerID=40&md5=e3bb787b3a13c538735b22a1667e72a9)>.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, n. 1, p. 185–201, 2002.

GALO, M. L. B. T.; VELINI, E. D.; TRINDADE, M. L. B.; SANTOS, S. C. A. Uso do sensoriamento remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do complexo Tietê. **Planta Daninha**, v. 20, n. spe, p. 7–20, 2002.

GEE – Google Earth Engine Developers. **Sobre o Google Earth Engine**. Disponível em: <<https://developers.google.com/earth-engine>>. Acesso em: 07 de fev. 2020.

GORELICK, N.; HANCHER, M.; DIXON, M.; et al. Remote Sensing of Environment Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017. The Author(s). Disponível em: <<https://doi.org/10.1016/j.rse.2017.06.031>>.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual Técnico de Uso da Terra**. 2013.

IBGE/SIDRA – Produção Agrícola Municipal (PAM). **Áreas plantadas, colhidas, quantidade produzidas, rendimento médio e valor de produção das lavouras**. Disponível em: <<https://sidra.ibge.gov.br/pesquisa/pam/tabelas>>. Acesso em: 09 de ago. 2020.

IPARDES. **Diagnóstico socioeconômico do Território Vale do Ivaí: 1a fase: caracterização global**. Curitiba, 2007.

LANDIS, J.R.; KOCH, G.G. 1977. The measurement of observer agreement for categorical data. **Biometrics**, 33:159-174.

LOH, W. Y. Fifty years of classification and regression trees. **International Statistical Review**, v. 82, n. 3, p. 329–348, 2014.

LORENA, A. C.; CARVALHO, A. C. P. L. F. DE. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada - RITA**, Volume XIV, ED. 2, 2007.

MENESES, P. R.; ALMEIDA, T. DE. **Introdução Ao Processamento De Imagens De Sensoriamento Remoto**. UnB/CNPq, 2012.

MORAES, E. C. DE. **Capítulo 1 - Fundamentos de Sensoriamento Remoto**. Instituto Nacional de Pesquisas Espaciais. Ministério da Ciência e Tecnologia, v. Capítulo 1, p. 3–12, 2002.

MOREIRA, A. A.; HIAGO, F.; FERNANDES, SOUZA; M. Aplicação do algoritmo support vector machine na análise espaço-temporal do uso e ocupação do solo na bacia do rio vieira. **Caminhos de Geografia**, Vol. 15, p. 152–163, 2014.

NEVES, L. V.; BESER DE DEUS, L. A.; OSCAR JÚNIOR, A. C. DA S.; FERNANDES, M. D. C. Mudanças de Uso e Cobertura da Terra e Áreas Suscetíveis à Inundação – Estudo de Caso do Município de Duque de Caxias/RJ. **Revista do Departamento de Geografia**, v. 37, p. 30–43, 2019.

PANIZZA, A. D. C.; FONSECA, F. P. Técnicas De Interpretação Visual De Imagens. GEOUSP: **Espaço e Tempo** (Online), n. 30, p. 30, 2011.

PAVLOV, Y. L. Random Forests. **Random Forests**, p. 1–122, 2019.

PINHEIRO, É. C. C.; RAMOS, A. P. M.; MARCATO JUNIOR, J. Remote sensing applied to the environmental regularization of rural properties in mato grosso do sul. **Anuário do Instituto de Geociências**, v. 42, n. 3, p. 145–153, 2019.

ROSA, M. R.; CRUZ, B. B.; MACHADO, C. A. S.; et al. **Comparação de algoritmos: Software comercial X Google Earth Engine**. Anais do XXVII Congresso Brasileiro de Cartografia v. 202, p. 166–176, 2017.

SOUZA, L. F.; P. DE; ADAMI, M.; et al. **Classificação De Uso E Cobertura Da Terra Em Áreas De Não Floresta Do Sudeste Paraense Através Da Plataforma Google Earth Engine (Gee)**. in: Anais Do XIX Simpósio Brasileiro De Sensoriamento Remoto, 2019, Santos. Anais eletrônicos, São José dos Campos, INPE, 2019. Disponível em: <<https://proceedings.science/sbsr-2019/papers/classificacao-de-uso-e-cobertura-da-terra-em-areas-de-nao-floresta-do-sudeste-paraense-atraves-da-plataforma-google-eart>>.

SPRING – SISTEMA DE PROCESSAMENTO DE INFORMAÇÕES GEOREFERENCIADAS. **Classificação de Imagens**. Disponível em: < <http://www.dpi.inpe.br/spring/portugues/tutorial/classific.html> >. Acesso em: 05 de abr. 2020.

USGS - UNITED STATES GEOLOGICAL SURVEY. **Landsat Missions**. Disponível em: <<https://landsat.usgs.gov/>>. Acesso em: 13 de mar. 2019.

VIEIRA, V. DE C. B.; MOREIRA, M. A.; DANTAS, F. R.; et al. **Mapeamento automático da expansão da agricultura anual no MATOPIBA entre 2002 e 2015 utilizando a plataforma Google Earth Engine**. Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto -SBSR, n. 1999, p. 4227–4234, 2017.