



UNIVERSIDADE FEDERAL DO CEARÁ
INSTITUTO DE CIÊNCIAS DO MAR
GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS

EMILY AIMÉE ALVES CARNAÚBA

**MAPEAMENTO DO USO E OCUPAÇÃO DA TERRA UTILIZANDO OS
SATÉLITES LANDSAT 8, SENTINEL 2B E CBERS 4A EM ÁREA DE
AGRICULTURA NO MUNICÍPIO DE LIMOEIRO DO NORTE - CE**

FORTALEZA

2021

EMILY AIMÉE ALVES CARNAÚBA

**INTERCOMPARAÇÃO DE ACURÁCIAS ENTRE OS SATÉLITES LANDSAT 8,
SENTINEL 2B E CBERS 4A NO MAPEAMENTO DE USO E COBERTURA
DO SOLO NA REGIÃO DE LIMOEIRO DO NORTE-CE**

Monografia apresentada ao Curso de Graduação em Ciências Ambientais do Instituto de Ciências do Mar (LABOMAR) da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Ciências Ambientais.

Orientador: Prof. Dr. Antônio Geraldo Ferreira.

Coorientador: Prof. Dr. Adunias Teixeira.

FORTALEZA

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

C286i Camaúba, Emily Aimée Alves.

Intercomparação de acurácias entre os satélites Landsat 8, Sentinel 2B e CBERS 4A no mapeamento de uso e cobertura do solo na região de Limoeiro do Norte - CE / Emily Aimée Alves Camaúba. – 2021.

55 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Instituto de Ciências do Mar, Curso de Ciências Ambientais, Fortaleza, 2021.

Orientação: Prof. Dr. Antônio Geraldo Ferreira.

Coorientação: Prof. Dr. Adunias Teixeira .

1. Agricultura de precisão. 2. Classificação Supervisionada. 3. Modelos de Classificação.
I. Título.

CDD 333.7

EMILY AIMÉE ALVES CARNAÚBA

**MAPEAMENTO DO USO E OCUPAÇÃO DA TERRA UTILIZANDO OS
SATÉLITES LANDSAT 8, SENTINEL 2B E CBERS 4A EM ÁREA DE
AGRICULTURA NO MUNICÍPIO DE LIMOEIRO DO NORTE - CE**

Monografia apresentada ao Curso de Graduação em Ciências Ambientais do Instituto de Ciências do Mar (LABOMAR) da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Ciências Ambientais.

Aprovada em: ___/___/_____.

BANCA EXAMINADORA

Prof. Dr. Antônio Geraldo Ferreira (Orientador)
Universidade Federal do Ceará (UFC)

Dr. Eduardo Lacerda Barros
Programa Cientista-Chefe Meio Ambiente – Secretaria do Meio Ambiente do
Estado do Ceará(SEMA)

Dra. Karinne Reis Deusdará Leal
LABOMAR – EOLLAB (UFC)

A Deus.

Aos meus pais, Hélio e Sidnéia.

AGRADECIMENTOS

A Deus por ter me presenteado com essa oportunidade e por ter me dado a estrutura necessária para trilhar essa caminhada com êxito e conseguir chegar até o final.

À minha família, minha maior incentivadora, que sempre me proporcionou o necessário e muitas vezes até mais, para construir um caminho profissional excepcional. Que nunca me deixaram desistir, sempre otimistas quanto ao futuro. Deixo aqui registrado meu amor à minha mãe, meu pai e minha irmã.

À CAPES, pelo apoio financeiro com a manutenção da bolsa de auxílio.

Ao prof. Dr. Antônio Geraldo Ferreira, pela excelente orientação e parceria, apoiando e incentivando sempre. Admiro-o por toda sua inteligência, educação e humildade, um exemplo a ser seguido. :)

Ao prof. Dr. Adunias Teixeira, pela excelente orientação, pela paciência e humildade em dividir um pouco do conhecimento em sua área e pela hospitalidade em me receber em seu laboratório.

Ao Níveo Rocha, funcionário da Fundação Cearense de Meteorologia e Recursos Hídricos, pela grande ajuda, esclarecendo dúvidas e mostrando soluções.

Aos participantes da banca examinadora Prof. Dr. Eduardo Lacerda Barros e Dra. Karinne Reis Deusdará Leal pelo tempo, pelas valiosas colaborações e sugestões.

Ao corpo de funcionários do LABOMAR, desde a equipe da recepção e da limpeza que sempre alegravam as manhãs com um simples “bom dia”, à equipe do restaurante universitário que fez parte dos melhores momentos dos dias de graduação, as equipes dos laboratórios pelo acolhimento e ensinamentos, até o corpo docente pela construção de conhecimento profissional.

Aos colegas da turma, pelos ensinamentos de vivência em grupo e aos amigos que fiz na graduação, pelas experiências, aventuras, reflexões, mudanças de perspectiva e companheirismo.

Entrega teu caminho ao Senhor,
confia nele, e Ele tudo fará.

- Salmos 37:5

RESUMO

Com o avanço da tecnologia no século XXI, a área da agricultura teve que se adaptar as novas demandas e com isso buscou se modernizar. A exemplo disso, é o surgimento da agricultura de precisão, que juntamente com o sensoriamento remoto, busca otimizar a produção de maneira que não acarrete grandes impactos ao meio ambiente. Como forma de ter um melhor conhecimento sobre determinada área, a fim de se ter um controle sobre o que compõem determinada região, usa-se o método de classificação supervisionada e com a grande variedade de satélites, muitas vezes fica difícil para o usuário (seja acadêmico ou não) saber qual o satélite mais adequado para está aplicação. Com isso, o presente trabalho foi feito em uma área de agricultura, na região de sertão central do estado do Ceará, no município de Limoeiro do Norte. Onde se comparou três diferentes satélites: Landsat 8, Sentinel 2B e CBERS 4A e diferentes métodos de classificação supervisionada: Distância Mínima, Máxima Verossimilhança e Spectral Angle Mapper. Com a finalidade de encontrar o melhor método de classificação associado a imagens de satélite, foram medidas as acurácias de cada método de classificação, a fim de comprovar o quão confiáveis são esses métodos, a partir dos índices Kappa e Exatidão Global. O presente trabalho concluiu que o melhor método de classificação supervisionada foi o Mindist, apresentando uma acurácia considerável. Dentre os três satélites citados, o que apresentou melhores resultados foi o Sentinel 2B. Para estudos futuros, poderá ser feita uma análise temporal, utilizando o método de classificação supervisionada que mostrou melhor desempenho.

Palavras-chave: Agricultura de Precisão, Classificação Supervisionada, Modelos de Classificação.

ABSTRACT

With the advancement of technology in the 21st century, the area of agriculture had to adapt to new demands and thus sought to modernize. An example of this is the emergence of precision agriculture, which together with remote sensing, seeks to optimize production in a way that does not have a major impact on the environment. As a way to have a better knowledge about a certain area, in order to have a control over what makes up a given region, the supervised classification method is used and with the wide variety of satellites, it is often difficult for the user (be it academic or not) to know which satellite is most suitable for this application. With this, the present work was done in an agricultural area, in the central sertão region of the state of Ceará, in the municipality of Limoeiro do Norte. Where three different satellites were compared: Landsat 8, Sentinel 2B and CBERS 4A and different supervised classification methods: Minimum Distance, Maximum Likelihood and Spectral Angle Mapper. In order to find the best classification method associated with satellite images, the accuracy of each classification method was measured, in order to prove how reliable these methods are, based on the Kappa and Global Accuracy indices. The present work concluded that the best supervised classification method was the Mindist, presenting considerable accuracy. Among the three satellites mentioned, the one that showed the best results was the Sentinel 2B. For future studies, a temporal analysis can be made, using the supervised classification method that showed the best performance.

Keywords: Precision Agriculture, Supervised Classification, Classification Models.

LISTA DE FIGURAS

| | | |
|-----------|--|----|
| Figura 1 | – Mapa com localização da área de estudo | 19 |
| Figura 2 | – Imagem representativa do satélite Landsat 8..... | 21 |
| Figura 3 | – Imagem representativa do satélite Sentinel 2..... | 22 |
| Figura 4 | – Imagem representativa do satélite CBERS 4 A..... | 24 |
| Figura 5 | – Representação gráfica do método da Distância Mínima..... | 28 |
| Figura 6 | – Representação gráfica da distribuição de probabilidade de um determinado ponto (pixel) pertencer a uma classe..... | 29 |
| Figura 7 | – Representação visual da acurácia e precisão..... | 31 |
| Figura 8 | – Exemplo usado para melhor compreensão dos termos Acurácia do Produtor, do Usuário e Exatidão Global..... | 32 |
| Figura 9 | - Fluxograma metodológico..... | 34 |
| Figura 10 | – Representação da composição falsa cor RGB 431 nos satélites Sentinel 2B, Landsat 8 e CBERS 4 | 36 |
| Figura 11 | – Mapa de classificação de área usando o método Maxver, para o satélite Sentinel 2..... | 40 |
| Figura 12 | – Mapa de classificação de área usando o método Mindist, para o satélite Sentinel 2..... | 40 |
| Figura 13 | – Mapa de classificação de área usando o método SAM, para o satélite Sentinel 2..... | 40 |
| Figura 14 | – Mapa de classificação de área usando o método Maxver, para o satélite Landsat 8..... | 42 |
| Figura 15 | – Mapa de classificação de área usando o método Mindist, para o satélite Landsat 8..... | 42 |
| Figura 16 | | |

| | |
|--|----|
| – Mapa de classificação de área usando o método SAM, para o satélite Landsat 8..... | 42 |
| Figura 17 – Mapa de classificação de área usando o método Maxver, para o satélite CBERS 4A..... | 44 |
| Figura 18 – Mapa de classificação de área usando o método Mindist, para o satélite CBERS 4A..... | 44 |
| Figura 19 – Mapa de classificação de área usando o método SAM, para o satélite CBERS 4A..... | 44 |

LISTA DE TABELAS

| | | |
|-----------|---|----|
| Tabela 1 | – Características dos sensores acoplados ao satélite Landsat 8..... | 21 |
| Tabela 2 | – Características do sensor MSI acoplado ao satélite Sentinel 2..... | 23 |
| Tabela 3 | – Características dos sensores acoplados ao satélite CBERS 4 A... | 25 |
| Figura 4 | – Vantagens e Desvantagens para os sensores OLI, MSI, WPM..... | 26 |
| Tabela 5 | – Classificação dos valores Kappa, variando de 0 a 1..... | 33 |
| Tabela 6 | – Identificação das imagens adquiridas..... | 35 |
| Tabela 7 | – Divisão das classes de uso e ocupação do solo e suas respectivas características e quantidades de amostras utilizadas no treinamento..... | 37 |
| Tabela 8 | – Porcentagens de área classificada para cada classe, usando o satélite Sentinel 2..... | 40 |
| Tabela 9 | – Porcentagens de área classificada para cada classe, usando o satélite Landsat 8..... | 42 |
| Tabela 10 | – Porcentagens de área classificada para cada classe, usando o satélite CBERS 4 A..... | 44 |
| Tabela 11 | – Acurácias do Produtor e Usuário para o satélite Sentinel 2..... | 45 |
| Tabela 12 | – Acurácias do Produtor e Usuário para o satélite Landsat 8..... | 46 |
| Tabela 13 | – Acurácias do Produtor e Usuário para o satélite CBERS 4A..... | 47 |
| Tabela 14 | – Resultados dos valores do Índice Kappa e Exatidão Global em relação a cada método de classificação para os três tipos de satélites..... | 48 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|---------|---|
| FAO | – Organização das Nações Unidas para Alimentação e Agricultura. |
| IBGE | – Instituto Brasileiro de Geografia e Estatística. |
| CEASA | – Centrais de Abastecimento do Ceará. |
| AP | – Agricultura de Precisão. |
| EMBRAPA | – Empresa Brasileira de Pesquisa Agropecuária. |
| CBERS | – China-Brazil Earth Resources. |
| OLI | – Operational Terra Imager. |
| MSI | – Multi-Spectral Instrument. |
| WPM | – Câmera Multiespectral e Pancromática de Ampla Varredura. |
| MUX | – Câmera Multiespectral. |
| WFI | – Câmera de Campo Largo. |
| USGS | – Sistema Geológico dos Estados Unidos. |
| ESA | – Agencia Espacial Europeia. |
| INPE | – Instituto Nacional de Pesquisas Espaciais. |
| NDVI | – Índice de Vegetação por Diferença Normalizada. |
| SCP | – Semi-Automatic Classification Plugin. |
| NASA | – National Aeronautics and Space Administration. |
| TIRS | – Thermal Infrared Sensor. |
| NIR | – Near Infrared (Infravermelho Próximo). |
| SAM | – Spectral Angle Mapper |
| PA | – Acurácia do Produtor. |
| PU | – Acurácia do Usuário |

- Mindist – Distância Mínima.
- Maxver – Máxima Verossimilhança.

SUMÁRIO

| | |
|---|----|
| 1 INTRODUÇÃO | 17 |
| 2 OBJETIVOS | 18 |
| 3 REFERENCIAL TEÓRICO | 18 |
| 3.1. Área de estudo..... | 18 |
| Figura 1 - Mapa com localização da área de estudo..... | 19 |
| 3.1 Agricultura de Precisão | 19 |
| 3.2 Sensor OLI/Landsat 8 | 20 |
| Figura 2 - Imagem representativa do satélite Landsat 8. | 21 |
| 3.3 Sensor MSI/Sentinel 2 | 22 |
| 3.4 WPM/ CBERS 4 A..... | 23 |
| Figura 4 - Imagem representativa do satélite CBERS 4 A. | 24 |
| Fonte: Autor, 2020. | 26 |
| 3.5 Classificação Supervisionada | 26 |
| 3.5.1 <i>Distância Mínima</i> | 27 |
| Figura 5 - Representação gráfica do método da Distância Mínima..... | 28 |
| 3.5.2 <i>Máxima Verossimilhança</i> | 28 |
| Figura 6 - Representação gráfica da distribuição de probabilidade de um determinado ponto (pixel) pertencer a uma classe..... | 29 |
| 3.5.3 <i>Spectral Angle Mapper</i> | 29 |
| 3.6 Acurácia | 30 |
| Figura 7 - Representação visual da acurácia e precisão..... | 31 |
| 3.6.1 <i>Coeficiente Kappa</i> | 32 |
| 4 MATERIAIS E MÉTODOS..... | 33 |
| 4.1. Aquisição de imagens | 34 |
| 4.3. Processamento Digital de Imagem | 35 |
| 4.4.1 <i>Classificação supervisionada</i> | 35 |
| Figura 10 - Representação da composição falsa cor RGB 431 nos satélites Sentinel 2B, Landsat 8 e CBERS 4 A..... | 36 |
| 4.4.1.1 <i>Métodos de Classificação</i> | 37 |
| 4.4.2 <i>Pós Processamento</i> | 37 |
| 4.4.3 <i>Acurácia</i> | 38 |
| 5 RESULTADOS E DISCUSSÃO..... | 39 |

| | |
|---|----|
| 5.1 Classificação Sentinel 2..... | 39 |
| Figura 11 – Mapa de classificação de área usando o método Maxver, para o satélite Sentinel 2. Figura 12 - Mapa de classificação de área usando o método Mindist, para o satélite Sentinel 2..... | 40 |
| Figura 13 - Mapa de classificação de área usando o método SAM, para o satélite Sentinel 2. Tabela 8 – Porcentagens de área classificada para cada classe, usando o satélite Sentinel 2 | 40 |
| 5.2 Classificação Landsat 8 | 41 |
| Figura 14 - Mapa de classificação de área usando o método Maxver, para o satélite Landsat 8. Figura 15 - Mapa de classificação de área usando o método Mindist, para o satélite Landsat 8..... | 42 |
| 5.3 Classificação CBERS 4A | 43 |
| Figura 17 - Mapa de classificação de área usando o método Maxver, para o satélite CBERS 4A. Figura 18 - Mapa de classificação de área usando o método Mindist, para o satélite CBERS 4A..... | 44 |
| 5.4 Acurácia | 45 |
| 5.4.1 Índice Kappa e Exatidão Global..... | 47 |
| 6 CONCLUSÃO..... | 48 |
| REFERÊNCIAS..... | 50 |

1 INTRODUÇÃO

Desde os primórdios, a principal fonte de alimentação do homem é por meio do cultivo da terra. A agricultura é a principal fonte de alimento em todo o mundo, além de prover fibras para a fabricação de roupas e matérias primas para a produção de energia.

Segundo a Organização das Nações Unidas para Alimentação e Agricultura - FAO (2018), o Brasil é o terceiro maior produtor agrícola do mundo, sendo essa a principal atividade econômica do país, cuja produção é principalmente destinada ao mercado externo. A nível estadual, o Ceará, como segundo maior produtor de melão do Brasil (IBGE, 2019), é um estado conhecido pela fruticultura, mas também possui produção de grãos, como milho, arroz e feijão. Segundo CEASA, 2016 o município de Limoeiro do Norte (área escolhida para estudo), retém a maior produção de milho do estado do Ceará, onde o plantio é feito em área irrigada, sendo possível atender a demanda da região durante todo o ano.

A agricultura é uma atividade vantajosa para a economia e para a sociedade, contudo, com o acelerado crescimento da população, a demanda por alimentos aumenta, exigindo muito mais do meio ambiente, que sofre com grandes impactos. Como forma de atender a essa demanda de forma sustentável, foi criada a agricultura de precisão (AP), definida como “um sistema de gerenciamento agrícola baseada na variação espacial e temporal da unidade produtiva e visa ao aumento de retorno econômico, à sustentabilidade e à minimização do efeito ao ambiente” (MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO, 2013).

De forma a auxiliar a AP, o sensoriamento remoto entra como ferramenta facilitadora, utilizando imagens de diversos satélites para mapeamentos de distúrbios e de estresses, avaliação de eventos climáticos desastrosos sobre produções agrícolas, mapeamento do desenvolvimento fenológico das culturas, etc (FORMAGGIO; SANCHES, 2017).

Tendo em vista a necessidade de conhecer e mapear áreas de cultivo, se usa imagens de satélites, por serem de fácil acesso e por terem uma maior cobertura espacial. Com a finalidade de conhecer e mapear uma área aplicasse os métodos de classificação supervisionada, usados para mapeamento e

avaliação de mudanças de uso e ocupação do solo (KAVZOGLU; VIEIRA, 1998). Porém, com os diversos tipos de modelos de classificação e de satélites, muitas vezes não se sabe qual modelo é mais acurado.

Dessa maneira, o presente trabalho teve como um dos objetivos comparar três modelos estatísticos de classificação supervisionada (Máxima Verossimilhança, Distância Mínima e Spectral Angle Mapper), aplicados à imagens de três diferentes satélites, sendo eles: Landsat 8, Sentinel 2B e CBERS 4 A. Como forma de validar os resultados apresentados nas classificações, fora calculado os valores de acurácia, com foco em saber qual modelo de classificação mais se aproxima da “realidade”, sendo possível escolher o método de classificação supervisionado mais preciso e o satélite mais adequado para áreas de agricultura.

2 OBJETIVOS

Analisar os métodos de classificação supervisionada, usando a acurácia como forma de validação de três diferentes tipos de satélites, sendo eles: Landsat 8, Sentinel 2A e CBERS 4A, a fim de definir qual deles melhor se aplica para mapeamento de área agrícola

Objetivos mais específicos:

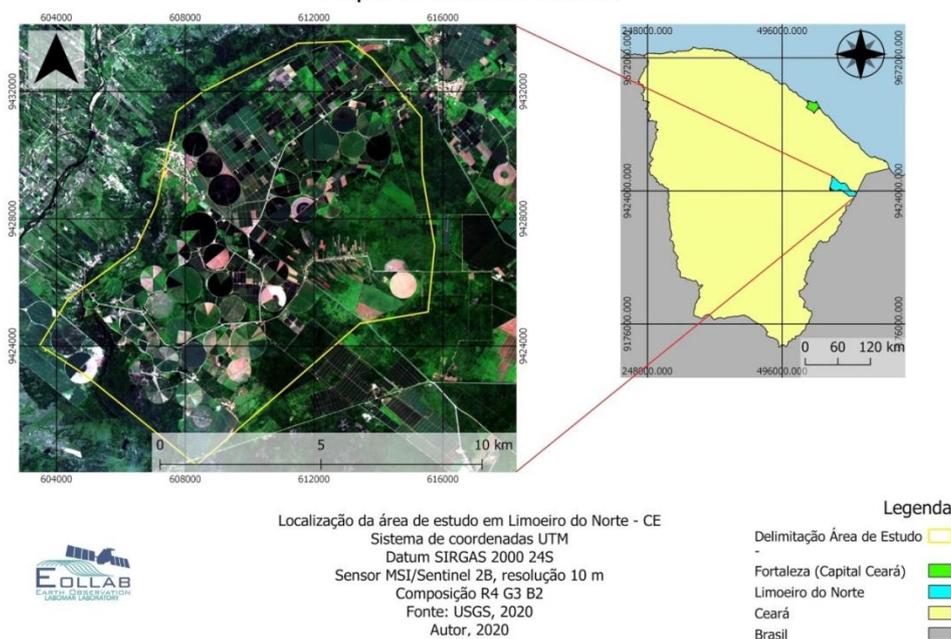
- Identificar as classes de uso e ocupação do solo na região
- Comparar bandas espectrais dos satélites a partir dos diferentes elementos que compõem a imagem.
- Comparar os valores de acurácia dos satélites.

3 REFERENCIAL TEÓRICO

3.1. Área de estudo

O presente trabalho tem como área de estudo um espaço de plantio comercial de milho, pertencente a empresa Agrocere®. Localizado na região do sertão central, no município de Limoeiro do Norte - CE, nas coordenadas - 5.196717° S e -38.000881° O. O datum utilizado foi o WGS 84.

Figura 1 - Mapa com localização da área de estudo.
Mapa da área de estudo



Fonte: Autor, 2020.

3.1 Agricultura de Precisão

Como forma de maximizar os lucros e aumentar a produção sem que seja necessário degradar mais áreas para o plantio, reduzindo os impactos ambientais, foi pensado em novas formas de tecnologias agrícolas, entre elas a Agricultura de Precisão associada ao Sensoriamento Remoto.

No ano de 2012 foi criado a Comissão Brasileira de Agricultura de Precisão, pelo Ministério da Agricultura, Pecuária e Abastecimento. A partir disso, foi definida a agricultura de precisão como “um sistema de gerenciamento agrícola baseado na variação espacial e temporal da unidade produtiva e visa ao aumento de retorno econômico, à sustentabilidade e à minimização do efeito ao ambiente” (BRASIL, 2012, p. 6).

O Sensoriamento Remoto pode ser feito por sensores proximais e sensores orbitais. Os sensores proximais são acoplados em veículos de aviação como aviões ou em veículos automotores como tratores, possuem alta resolução espacial, por estarem mais próximos da superfície. Também são de alta resolução temporal, não dependendo de tempo de revisita, já que esse tempo

fica a critério da operação do veículo em que o sensor está acoplado (FORMAGGIO e SANCHES, 2017).

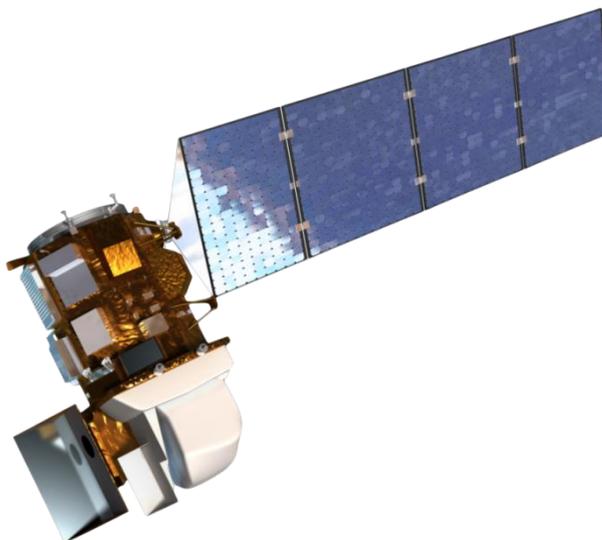
Os sensores orbitais são os sensores junto aos satélites, sendo muito utilizados quando é preciso imagens panorâmicas (FORMAGGIO e SANCHES, 2017) e em muitos casos, quando o agricultor não possui recursos suficientes para investir em sensores acoplados, podendo recorrer a satélites que disponibilizam o download gratuito de suas imagens, como exemplo os satélites usados neste trabalho. Esse tipo de sensor é baseado na interação da radiação eletromagnética com os alvos escolhidos (MOLIN, AMARAL e COLAÇO, 2015).

A AP pode ser aplicada para a obtenção de diagnósticos do cultivo, identificando fatores de baixo ou alto desempenho da lavoura, sendo possível o reconhecimento de pragas e espécies invasoras. A partir das aplicações, vem os principais benefícios da AP, como: redução na quantidade de insumos e gastos na produção, maior lucro e menor impacto no meio ambiente (MOLIN, AMARAL e COLAÇO, 2015).

3.2 Sensor OLI/Landsat 8

O satélite Landsat 8, lançado pela National Aeronautics and Space Administration (NASA) em 02 de novembro de 2013, possui dois instrumentos sensores: Thermal Infrared Sensor (TIRS) que mede a temperatura superficial da Terra por meio de duas bandas espectrais na faixa do infravermelho termal, com resolução espacial de 100 m (NASA, 2020) e o Operational Land Imager (OLI) com bandas espectrais nas faixas do visível, infravermelho próximo e infravermelho de onda curta, com resolução espacial de 30 m e 15 m (pancromática) (NASA, 2020).

Figura 2 - Imagem representativa do satélite Landsat 8.



Fonte: NASA, 2013.

Tabela 1 - Características dos sensores acoplado ao satélite Landsat 8.

| Landsat 8 | | | | |
|-------------|--------|---------------------------------------|------------------------|---------------------------|
| Sensor | Bandas | Resolução Espectral (μm) | Resolução Espacial (m) | Resolução Temporal (dias) |
| Sensor OLI | B1 | 0,43 - 0,45 | 30 | 16 |
| | B2 | 0,45 - 0,51 | | |
| | B3 | 0,53 - 0,59 | | |
| | B4 | 0,64 - 0,67 | | |
| | B5 | 0,85 - 0,88 | | |
| | B6 | 1,57 - 1,65 | | |
| | B7 | 2,11 - 2,29 | 15 | |
| | B8 | 0,50 - 0,68 | 30 | |
| | B9 | 1,36 - 1,38 | 100 | |
| Sensor TIRS | B10 | 10,6 - 11,19 | | |
| | B11 | 11,5 - 12,51 | | |

Fonte: Adaptado de NASA, 2020.

Dentre os sensores a bordo do Landsat 8 o sensor OLI foi escolhido para a execução do presente estudo, por conter as bandas do visível e infravermelho, essenciais para as análises feitas ao longo do trabalho.

3.3 Sensor MSI/Sentinel 2

Lançado em junho de 2015, pela European Space Agency (ESA), com o objetivo de observação da Terra a fim de obter dados sobre vegetação, recursos hídricos, área costeira e umidade do solo, o satélite Sentinel 2 é composto pelo instrumento sensor MultiSpectral Instrument (MSI) que possui 13 bandas espectrais, onde as bandas do visível e infravermelho possuem resolução espacial de 10 m, as variações das bandas red edge e bandas infravermelhas de onda curta contam com resolução espacial de 20 m e as bandas para correções atmosféricas como aerossóis, vapor de água e cirrus possuem resolução de 60 m (ESA, 2020).

Figura 3 - Imagem representativa do satélite Sentinel 2.



Fonte: ESA, 2008.

Tabela 2 - Características do sensor MSI acoplado ao satélite Sentinel 2.

| Sentinel 2 / MSI | | | |
|------------------|---------------------------------------|------------------------|---------------------------|
| Bandas | Resolução Espectral (μm) | Resolução Espacial (m) | Resolução Temporal (dias) |
| B1 | 0,44 | 60 | 10 |
| B2 | 0,49 | 10 | |
| B3 | 0,56 | | |
| B4 | 0,66 | | |
| B5 | 0,7 | | |
| B6 | 0,74 | | |
| B7 | 0,78 | | |
| B8 | 0,84 | | |
| B8A | 0,86 | 60 | |
| B9 | 0,94 | | |
| B10 | 1,37 | 20 | |
| B11 | 1,61 | | |
| B12 | 2,19 | | |

Fonte: Adaptado de ESA, 2020.

De acordo com ESA, 2020 o funcionamento do sensor MSI se dá a partir da captura da luz refletida até o sensor MSI, por meio de um telescópio composto de três espelhos, em seguida a luz capturada é dividida em dois conjuntos de planos focais: comprimentos de onda do visível e infravermelho termal e próximo e comprimentos de onda do red edge e infravermelho de onda curta.

3.4 WPM/ CBERS 4 A

O satélite CBERS 4A é fruto do programa CBERS (XXXXXXX), uma parceria entre os países Brasil e China. Foi lançado em 20 de Dezembro de 2019, pelo foguete chinês Longa Marcha 4B. O objetivo principal dessa missão é o monitoramento ambiental, como por exemplo: controle de queimadas na Amazônia, monitoramento de recursos hídricos, áreas agrícolas, uso e ocupação do solo, entre outras aplicações ambientais (INPE, 2018).

Figura 4 - Imagem representativa do satélite CBERS 4 A.



Fonte: INPE, 2020.

O CBERS 4A conta com três distintos sensores, a câmera Multiespectral (MUX) com três bandas no visível e uma no infravermelho, com resolução espacial de 16m, a câmera de Campo Largo (WFI) também possui três bandas no visível e uma no infravermelho, com resolução espacial de 55m. Já o terceiro sensor, a câmera Multiespectral e Pancromática de Ampla Varredura (WPM), considerado o grande diferencial do satélite CBERS 4 A, possui três bandas no visível e uma no infravermelho, ambas com resolução espacial de 8m, e uma banda pancromática com resolução de 2m (INPE, 2019). O sensor WPM por possui melhor resolução, possibilitando um melhor detalhamento, é o sensor da família CBERS 4 A escolhido para o presente estudo.

Tabela 3 - Características dos sensores a bordo do satélite CBERS 4A.

| CBERS 4A | | | | |
|----------|--------|---------------------------------------|------------------------|---------------------------|
| Sensor | Bandas | Resolução Espectral (μm) | Resolução Espacial (m) | Resolução Temporal (dias) |
| WPM | P | 0,45 - 0,90 | 2 | 31 |
| | B1 | 0,45 - 0,52 | 8 | |
| | B2 | 0,52 - 0,59 | | |
| | B3 | 0,63 - 0,69 | | |
| | B4 | 0,77 - 0,89 | | |
| MUX | B5 | 0,45 - 0,52 | 16,5 | |
| | B6 | 0,52 - 0,59 | | |
| | B7 | 0,63 - 0,69 | | |
| | B8 | 0,77 - 0,89 | | |
| WFI | B13 | 0,45 - 0,52 | 55 | 5 |
| | B14 | 0,52 - 0,59 | | |
| | B15 | 0,63 - 0,69 | | |
| | B16 | 0,77 - 0,89 | | |

Fonte: Adaptado de INPE, 2019.

Para melhorar a visualização e como forma de percepção das diferenças entre os sensores escolhidos para o presente estudo, a tabela 4 faz um comparativo entre eles.

Tabela 4 – Vantagens e Desvantagens para os sensores OLI, MSI, WPM.

| Sensor | Bandas | Resolução espectral (μm) | Resolução Espacial (m) | Resolução temporal (dias) | Vantagem | Desvantagem | |
|--------|--------|---------------------------------------|------------------------|---------------------------|---|--|----|
| OLI | B1 | 0,43 – 0,45 | 30 | 16 | Com uma resolução temporal de 16 dias, é possível um número maior de imagens. | Por conta da sua resolução espacial de 30 metros para as bandas do visível, não é possível um melhor detalhamento da imagem. | |
| | B2 | 0,45 – 0,51 | | | | | |
| | B3 | 0,53 – 0,59 | | | | | |
| | B4 | 0,64 – 0,67 | | | | | |
| | B5 | 0,85 – 0,88 | | | | | |
| | B6 | 1,57 – 1,65 | | | | | |
| | B7 | 2,11 – 2,29 | 15 | | | | |
| | B8 | 0,50 – 0,68 | 30 | | | | |
| | B9 | 1,36 – 1,38 | | | | | |
| MSI | B1 | 0,44 | 60 | 10 | Uma maior quantidade de imagens, a cada 10 dias, possibilitando um acompanhamento quase que diário. | Resolução espacial moderada para detalhamento, com 20 metros. | |
| | B2 | 0,49 | 10 | | | | |
| | B3 | 0,56 | | | | | |
| | B4 | 0,66 | | | | | |
| | B5 | 0,7 | | | | | |
| | B6 | 0,74 | | | | | |
| | B7 | 0,78 | | | | | 20 |
| | B8 | 0,84 | | | | | |
| | B8A | 0,86 | | | | | |
| | B9 | 0,94 | 60 | | | | |
| | B10 | 1,37 | | | | | |
| | B11 | 1,61 | | | | | |
| B12 | 2,19 | 20 | | | | | |
| WPM | P | 0,45 – 0,90 | 2 | 31 | Com resolução espacial de 8 metros, sendo ainda possível melhorar para 2 metros, colaborando para um maior grau de detalhe da imagem. | Resolução espacial muito longa, de 31 dias, dificultando um monitoramento. | |
| | B1 | 0,45 – 0,52 | 8 | | | | |
| | B2 | 0,52 – 0,59 | | | | | |
| | B3 | 0,63 - 0,69 | | | | | |
| | B4 | 0,77 – 0,89 | | | | | |

Fonte: Autor, 2020.

3.5 Classificação Supervisionada

De acordo com Meneses e Sano (2012), a classificação de imagens de satélites multiespectrais, consiste no ato de associar os pixels da imagem a uma determinada classe que possui um conjunto de critérios com base em seus valores de números digitais, em que o pixel que se encaixar nesses critérios, é associado a classe que mais se assemelha.

A classificação de imagens digitais pode ser dividida em variados métodos: classificação paramétrica e não paramétrica, classificação espectral e espacial, classificação supervisionada ou não supervisionada e classificação por

pixel ou por regiões. O método mais comum e mais utilizado pelos softwares comerciais (como exemplo o Qgis) é o de classificação supervisionada e não supervisionada (MENESES; SANO, 2012) e para o presente trabalho, foi utilizado o método de classificação supervisionada.

O método de classificação supervisionada conta com a presença de um analista, que a partir do seu conhecimento prévio da área de estudo, seleciona as amostras de treinamento, onde cada amostra possui pixels semelhantes, a partir disso, cada pixel amostrado será comparado numericamente e classificado na classe que melhor se encaixa (LILLESAND; KIEFER; CHIPMAN, 2003). As amostras de treinamento são de extrema importância para poder treinar o algoritmo que irá fazer a classificação dos pixels nas classes escolhidas de acordo com o conhecimento prévio da localidade escolhida. Há diversos tipos de algoritmos de classificação supervisionada, como exemplo os que serão abordados neste trabalho: Distância Mínima, Máxima Verossimilhança e Spectral Angle Mapper.

Ressaltando que a classificação de imagens busca ao máximo condizer com a realidade, por isso, é de suma importância que seus resultados sejam avaliados e validados por métodos estatísticos que estimem sua acurácia (MENESES; SANO, 2012).

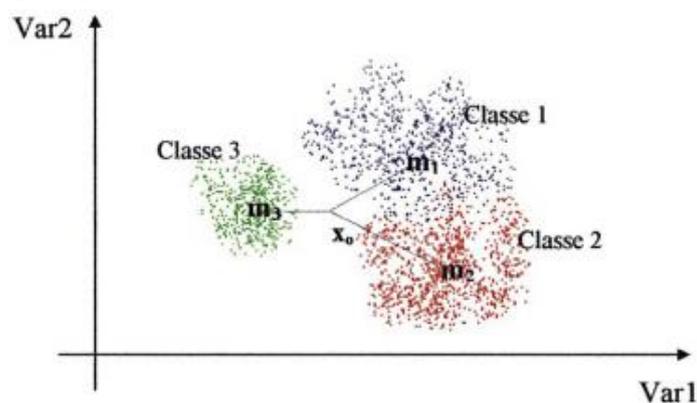
3.5.1 Distância Mínima

O método de Distância Mínima ou do inglês Minimum Distance, funciona a partir da distância Euclidiana, ou seja, a partir da distância de dois pontos, referentes ao valor espectral de um pixel coletado pelas amostras de treinamento em relação a média espectral de cada classe (MENESES; SANO, 2012). De acordo com Borges; Silva; Castro (2007) “Na classificação, cada pixel será incorporado a um agrupamento, através da análise da medida de similaridade de distância Euclidiana”. A equação 2 é referente ao cálculo da distância Euclidiana, onde x é referente ao valor do pixel treinado e m é a média de uma classe.

$$D(x, m) = (x^2 - m^2)^{\frac{1}{2}} \quad (2)$$

Para melhor compreensão a Figura 5 mostra a distância entre o pixel treinado e as médias das classes. A classe que tiver uma menor distância entre o valor de sua média e o valor do pixel candidato, essa será a classe há qual o pixel pertencerá.

Figura 5 - Representação gráfica do método da Distância Mínima.



Fonte: Müller, 1997.

3.5.2 Máxima Verossimilhança

De acordo com Lillesand, Kiefer, Chipman (2008) o método de Máxima Verossimilhança ou como também é chamado, Maxver, avalia a variação e a covariância da resposta espectral das classes escolhidas para a classificação dos pixels amostrados. Possui uma distribuição normal ou Gaussiana, onde as classes podem estar distribuídas de diversas maneiras (FOODY; MCCULLOCH; YATES, 1995).

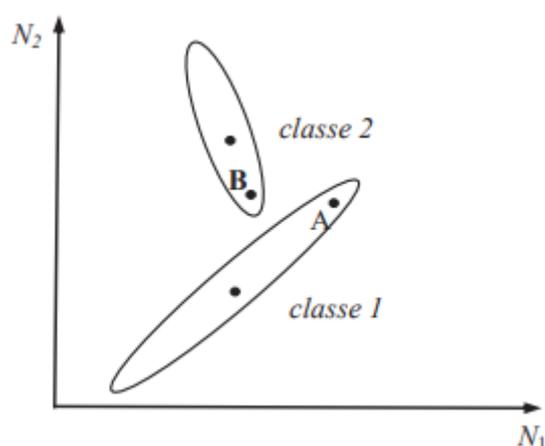
De maneira mais resumida, o método Maxver classifica o pixel de acordo com a maior probabilidade de pertencer a determinada classe, o cálculo dessa probabilidade é feito a partir da equação 3 proposta por Richard e Jia (2006), apresentada a seguir:

$$x \in w_i \text{ se } p(x/w_i)p(w_i) > p(x/w_j)p(w_j) \quad (3)$$

Como explica Meneses e Sano (2012), “onde, a probabilidade $p(x/w_i)$ dá a possibilidade de x pertencer à classe w_i e $p(w_i)$ é a probabilidade de a classe ocorrer na imagem, que de fato é conhecida das áreas de treinamento. Tantas quanto forem as classes de treinamento selecionadas, tantas serão $p(x/w_i)$.”

A figura 6 representa melhor a questão de um determinado ponto pertencer a uma classe levando em consideração a sua probabilidade.

Figura 6 - Representação gráfica da distribuição de probabilidade de um determinado ponto (pixel) pertencer a uma classe.



Fonte: Meneses e Sano, 2012.

Na figura 6 nota-se que o ponto A deveria estar inserido na classe 2, por conta da menor distância, porém o método Maxver leva em conta a relação da posição do ponto com o tipo de distribuição de cada classe e de acordo com a inclinação das elipses é possível notar que a classe 1 possui uma inclinação para a direita ou seja, distribuição positiva, já a classe 2 uma inclinação para esquerda, mostrando uma distribuição negativa (MENESES; SANO, 2012).

3.5.3 Spectral Angle Mapper

O método Spectral Angle Mapper também é conhecido pela sigla SAM. De acordo com Kruse et al. (1993) o método SAM verifica a semelhança entre as assinaturas espectrais dos pixels coletados pelas amostras de

treinamento e as assinaturas espectrais dos pixels da imagem a ser classificada.

Os resultados numéricos de SAM são dados em valores de ângulos, a partir da equação 4 proposta por Kruse et al. (1993).

$$\alpha = \cos^{-1} \frac{\sum xy}{\sqrt{\sum(x)^2 + \sum(y)^2}} \quad (4)$$

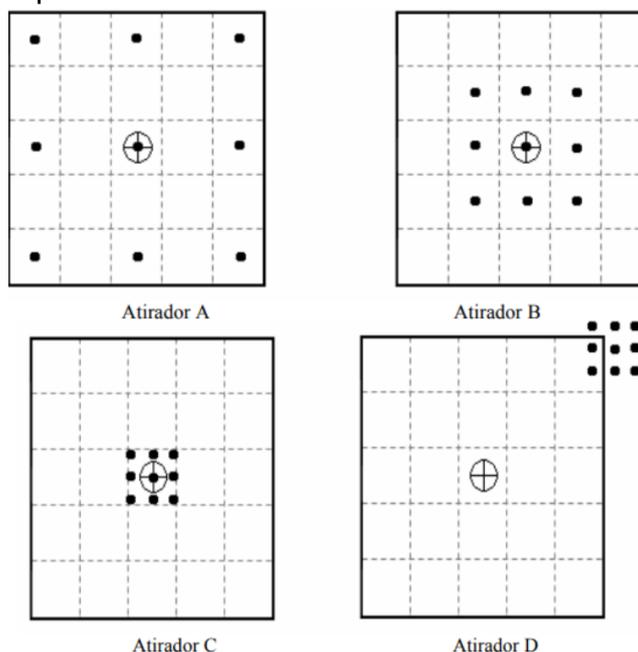
Onde α é o ângulo formado entre o espectro do pixel de amostragem e o espectro do pixel da imagem, x é o espectro do pixel da imagem e y é o espectro do pixel de amostragem. O resultado da equação pode ser interpretado a partir de que quanto menor for o ângulo para um pixel classificado, maior será sua semelhança com a amostra de referência (KRUSE et al., 1993).

3.6 Acurácia

De acordo com Mikhail e Ackermann (1976, p. 64, apud MÔNICO et al, 2009, p.469-483) acurácia é o valor de proximidade entre uma estimativa com o seu valor verdadeiro. Aplicada ao presente estudo, é o quão próximo a classificação realizada condiz com a “realidade”. Usando como forma de comparação as amostras de treinamento usadas para classificação e as amostras de exatidão que são condizentes com a realidade.

Proposto por Monico et al (2009) a Figura 6 mostra melhor o conceito de acurácia juntamente com o de precisão.

Figura 7 - Representação visual da acurácia e precisão.



Fonte: Adaptado de Monico et al (2012).

Na figura 7, os atiradores B e C possuem uma maior acurácia, já que se aproximam mais do alvo, que indica o valor verdadeiro, os atiradores C e B possuem uma maior precisão, pois possuem uma dispersão de tiros menor. Observando o atirador C, é notável que tanto sua precisão como a acurácia são altas.

A análise da acurácia pode ser feita de três maneiras: de uma forma mais geral, 1) a exatidão ou acurácia global e de forma mais individual, as 2) acurácias do produtor e do 3) usuário. O coeficiente Kappa também é um indicador usado para medir e analisar a acurácia.

A exatidão global é uma das medidas mais simples, sendo calculada a partir da fração do total de pixels classificados corretamente pelo total de pixels da matriz de erro. A exatidão global indica a probabilidade de um pixel estar corretamente classificado (CONGALTON, 1991).

As acurácias do produtor e do usuário são mais direcionadas às categorias de classificação, diferente da exatidão global que analisa as classes de forma mais geral, sendo os resultados gerados a partir dos valores da matriz de erro. A acurácia do produtor é calculada pela divisão entre os valores na diagonal da matriz de erro pelo total das classes dispostas em coluna

(MASTELLA; VIEIRA, 2018). O resultado da acurácia do produtor mostra o quão bem uma determinada amostra foi classificada (CONGALTON, 1991).

A acurácia do usuário pode ser calculada a partir da razão entre os valores da diagonal da matriz de erro pelo total de classes dispostas em linhas (MASTELLA; VIEIRA, 2018). A partir da figura 8 é possível compreender melhor o que foi explicado anteriormente.

Figura 8 - Exemplo usado para melhor compreensão dos termos Acurácia do Produtor, do Usuário e Exatidão Global.

| | | Dados de Referência | | | |
|------------------------------|-----------------|-----------------------------|-----------------|-----------------|----------------|
| | | A | B | C | Total (linhas) |
| Dados Classificados | A | 10 | 20 | 30 | 60 |
| | B | 40 | 50 | 60 | 150 |
| | C | 70 | 80 | 90 | 240 |
| Total (colunas) | | 120 | 150 | 180 | 450 |
| Acurácia "Dados do Produtor" | | Acurácia "Dados do Usuário" | | Exatidão Global | |
| A | 10/120*100=8,3% | A | 10/60*100= 16% | 10+50+90/450 | |
| B | 50/150*100=3,3% | B | 50/150*100=3,3% | 150/450*100=33% | |
| C | 90/180*100=5% | C | 90/240*100=3,8% | | |

Fonte: Mastella e Vieira, 2018.

3.6.1 Coeficiente Kappa

Método estatístico proposto por Cohen (1960), onde mede a qualidade da classificação, o quão ela concorda com as amostras de exatidão. O coeficiente é calculado a partir da equação 5.

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (5)$$

Em que r é o número de linhas na matriz de erro, x_{ii} é o número de observações na linha i e na coluna l, para x_{i+} e x_{+i} são os valores totais das linhas i e colunas i, e N é o número total de classes (BISHOP et al., 1975, apud CONGALTON, 1991).

Os valores do índice Kappa, variam de 0 a 1, quanto mais próximo o valor for de 1 mais acurado ele é e quanto mais próximo for de 0 menos acurado ele é (CONGALTON, 2004). Landis e Koch (1977) organizaram os possíveis resultados de Kappa em intervalos, valores maiores que 0,80 significam uma alta acurácia, para valores entre 0,40 e 0,80 representa uma acurácia moderada e abaixo de 0,40 indica uma baixa acurácia.

Tabela 5 - Classificação dos valores Kappa, variando de 0 a 1.

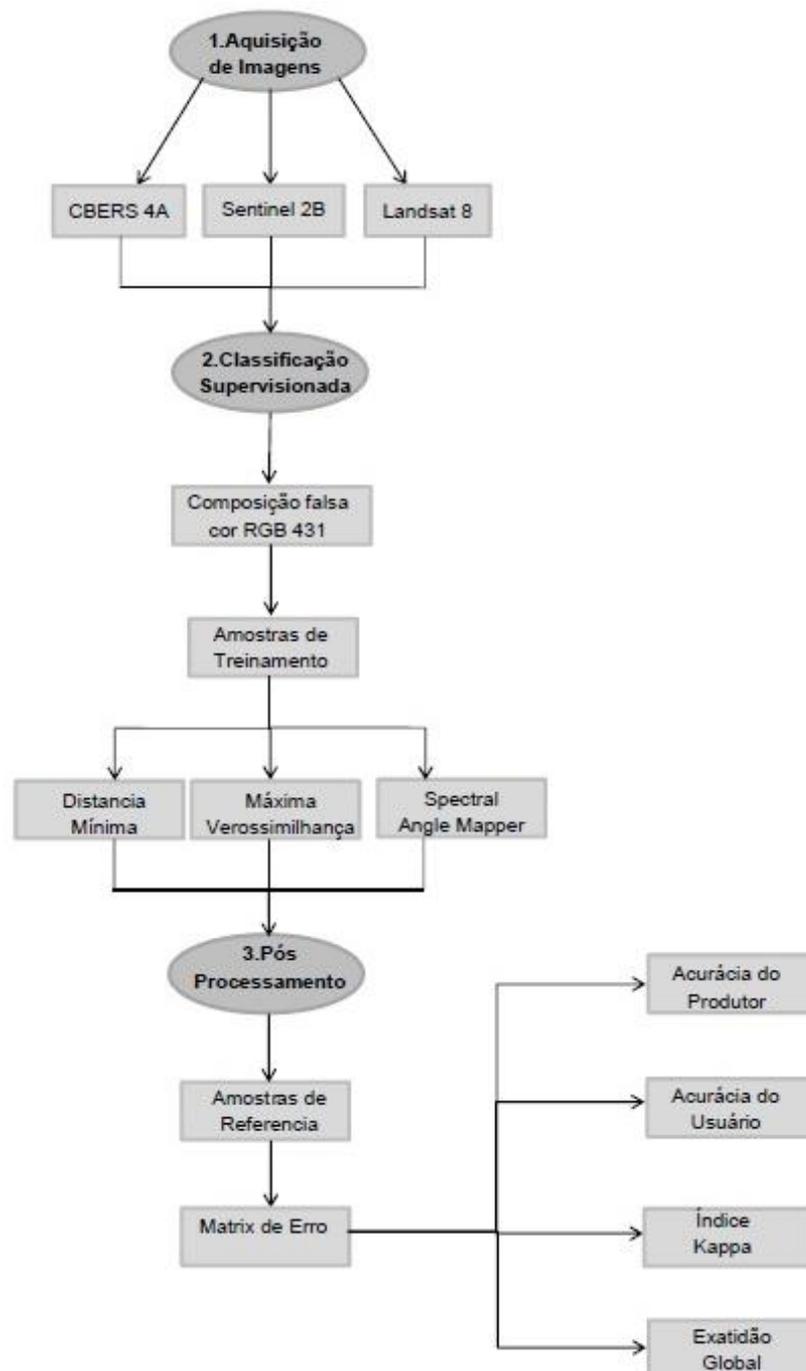
| Valores Kappa | Classificação |
|---------------|---------------|
| < 0 | Péssimo |
| 0 - 0,2 | Ruim |
| 0,2 - 0,4 | Considerável |
| 0,4 - 0,6 | Razoavel |
| 0,6 - 0,8 | Bom |
| 0,8 - 1 | Excelente |

Fonte: Autor, adaptado de Landis e Koch (1977).

4 MATERIAIS E MÉTODOS

D acordo com a Figura 9, é possível entender de forma direta a aplicação da metodologia, que foi dividida em três partes: 1.Aquisição de Imagens, 2.Classificação Supervisionada e 3.Pós Processamento.

Figura 9 – Fluxograma metodológico.



Fonte: Autor, 2020.

4.1. Aquisição de imagens

A tabela 6, mostra em que plataforma as imagens foram adquiridas, as datas de cada cena e as localizações de acordo com suas órbitas.

Tabela 6 – Identificação das imagens adquiridas

| Obtenção de Imagens | | | |
|---------------------|------------|------------|--------|
| Satélite | Plataforma | Data | Orbita |
| Landsat 8 | USGS | 11/08/2020 | 216/64 |
| Sentinel 2B | Copernicus | 14/08/2020 | 214/95 |
| CBERS 4A | INPE | 28/08/2020 | 197/19 |

Fonte: Autor, 2020.

As imagens utilizadas possuem datas próximas, para não haver modificações nas formas de uso e ocupação do solo, o que conseqüentemente causaria diferença nas classificações das imagens, já que o ambiente estaria diferente nos três períodos escolhidos.

4.2. Pré-processamento

Por conta da presença da atmosfera, imagens de satélite sofrem com fenômenos de espalhamento, absorção e refração eletromagnética, o que causa uma redução na detecção de pequenos objetos presentes em uma imagem, por conta da diminuição de contraste (NOVO, 2008).

Para o presente trabalho, foram obtidas imagens já corrigidas atmosféricamente, não sendo necessária a aplicação de métodos de correção digital de imagens.

4.3. Processamento Digital de Imagem

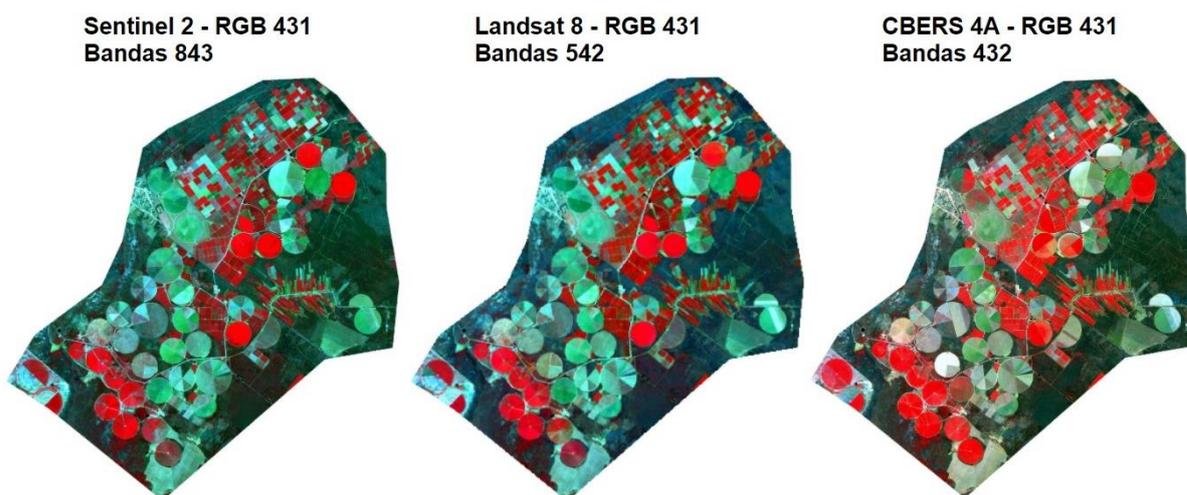
4.4.1 Classificação supervisionada

2) A classificação foi feita a partir do Semi-Automatic Classification Plugin (SCP), que consiste na classificação pixel a pixel de forma supervisionada (QGIS BRASIL, 2015), onde são feitas coletas de amostras na imagem para compor as categorias de interesse, como exemplo a classe de água, de área urbana, de vegetação, etc. Após a coleta de amostras, o plugin gera uma imagem classificada. Quanto mais amostras forem coletadas, maior o grau de detalhamento da imagem.

Para a classificação das três imagens dos diferentes satélites, foi gerada a composição falsa cor RGB nas bandas 4 (infravermelho próximo), 3 (vermelho), 1 (azul) de cada satélite.

A composição escolhida oferece uma melhor visualização da área, sendo possível distinguir áreas de plantação em florescimento, por conta de que, a vegetação em vigor vegetativo absorve no comprimento de onda do vermelho visível (banda 4 do satélite/MSI; OLI e banda 3 do WPM) e refletem no comprimento do infravermelho (correspondente as bandas: 8 no Sentinel 2B, 5 no satélite Landsat 8 e 4 no satélite CBERS 4 A), aparecendo em tons de vermelho na imagem (FORMAGGIO et al., 2017). Já as zonas de solo exposto e vegetação em senescência, ou seja, plantação que já está em tempo de colheita, possuem uma alta refletância nas faixas do vermelho visível, apresentando uma coloração variando do esverdeado para o azulado (FORMAGGIO et al., 2017), contudo, é possível distinguir uma área de solo exposto de uma área de vegetação senescente, já que a coloração de solo exposto é representada por um azul mais vibrante e no sensor WPM por um verde com textura lisa.

Figura 10 - Representação da composição falsa cor RGB 431 nos satélites Sentinel 2B, Landsat 8 e CBERS 4 A.



Fonte: Autor, 2020.

Para o processo de classificação supervisionada é necessário a coleta de amostras de treinamento, que de acordo com Venturieri, 2007 serão usadas para treinar o algoritmo de classificação para a diferenciação das classes

estabelecidas. De acordo com a figura 10, foram divididas quatro classes, sendo elas: vegetação densa (verde escuro rugoso), solo exposto (tons de ciano), plantação em florescimento (tons de vermelho), plantação em senescência (tons de verde). De acordo com a Tabela 6 é possível observar as características e a quantidade de amostras de treinamento coletadas para cada classe.

Tabela 7 - Divisão das classes de uso e ocupação do solo e suas respectivas características e quantidades de amostras utilizadas no treinamento.

| Classes | Características | Quantidade de amostras |
|-----------------------------------|---|------------------------|
| Vegetação Densa | Nesta classe foi incluído as áreas com vegetação nativa, não adteradas pelo homem | 4 |
| Solo Exposto | Nesta classe foi adicionado as áreas degradadas antropicamente, com ocupação urbana e áreas onde as culturas plantadas já foram colhidas | 9 |
| Plantação em Florescimento | Nesta classe incluiu-se áreas de plantação em fase de maturação, onde a cultura ainda esta crescendo e se preparando para após atingirem a maturação serem colhidas | 14 |
| Plantação em Senescência | Nesta classe foram inseridas as áreas em que a cultura já estava pronta para a colheita | 14 |

Fonte: Autor

4.4.1.1 Métodos de Classificação

Após a definição e delimitação de cada amostra de treinamento, foi feita a classificação supervisionada, usando a ferramenta Semi-Automatic Classification Plugin, que gera de forma automática a classificação de cada imagem a partir de três algoritmos: Distância Mínima, Máxima Verossimilhança e Ângulo Espectral.

4.4.2 Pós Processamento

Após o processamento das imagens, com as imagens classificadas, é feito a validação da classificação, onde são coletadas as amostras de referência, podendo ser obtidas a partir de trabalhos de campo ou de imagens mais detalhadas, com melhor resolução (CHUVIECO, 1990). Para o presente trabalho, foi utilizada como verdade de campo uma imagem do Google Earth.

O pós-processamento foi feito por meio do plugin SCP do software QGIS 3.10.9. Posteriormente a coleta das amostras de referência, foi gerada a matriz de confusão ou matriz de erro, que consiste no número total de pixels contidos na imagem classificada automaticamente em comparação com as amostras de referência (CONGALTON, 2001). A matriz de erro gerada pelo Qgis, traz também os valores dos coeficientes estatísticos: Índice Kappa e Exatidão Global, a partir destes pode-se medir a acurácia dos métodos de classificação aplicados a imagem dos satélites.

O índice ou coeficiente Kappa, proposto por Cohen em 1960, é um método estatístico que compara dois conjuntos de dados, com a finalidade de avaliar o nível de concordância entre eles (LANDIS; KOCH,1977). O cálculo estatístico é feito a partir da equação 7:

$$K = \frac{Po - Pe}{1 - Pe} \quad (7)$$

Onde Po é o valor de aceitação relativa, Pe é o valor esperado de aceitação. Os valores de K variam de 0 a 1, sendo o valor mais próximo de 1 o de maior aceitação. De acordo com a tabela proposta por Landis e Koch (1977), os valores são classificados de péssimo a excelente, como apresentado na tabela 4.

Em relação ao índice de Exatidão Global, a acurácia é obtida a partir da razão da soma das amostras classificadas com o número total de classes (FIGUEIREDO; VIEIRA, 2007), como mostra a equação 8 abaixo:

$$G = \frac{\sum_{i=1}^n x_{ii}}{n} \quad (8)$$

4.4.3 Acurácia

A acurácia pode ser analisada a partir dos produtos gerados no pós - processamento, através do plugin SCP, que gera a acurácia do produtor e do usuário.

A acurácia do produtor é definida como uma medição do erro de omissão, que apresenta a probabilidade da amostra de referência ser classificada de forma correta (CONGALTON, 2001). É calculado pela equação

9, onde x_{ii} é o número de amostras classificadas corretamente e $x + 1$ é o total de amostras em uma determinada classe (Lillesand; Kiefer, 1994).

$$ap = \frac{x_{ii}}{x+i} \quad (9)$$

Para a acurácia do usuário, é medido o erro de comissão, que é referente a probabilidade de uma amostra de referência estar classificada no lugar correto (CONGALTON, 2001). Os valores são dados por meio da equação 10, onde X_{ii} é o número de amostras classificadas corretamente e X_{i+} é o total de amostras em uma determinada classe (Lillesand; Kiefer, 1994).

$$au = \frac{x_{ii}}{x_{i+}} \quad (10)$$

5 RESULTADOS E DISCUSSÃO

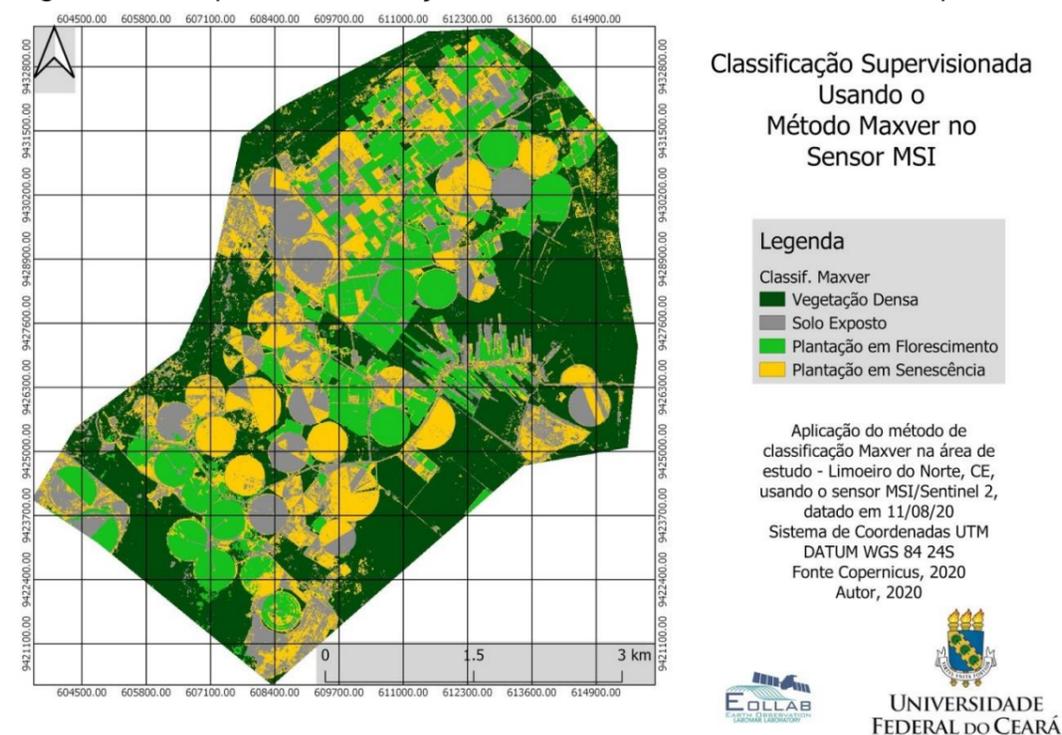
Após o processo de classificação das imagens usando o plugin SCP do software Qgis, foram geradas imagens condizentes com o método de classificação escolhido.

5.1 Classificação Sentinel 2B

Para as imagens do satélite Sentinel 2B, do dia 11 de Agosto de 2020, foram gerados mapas para cada modelo de classificação usado.

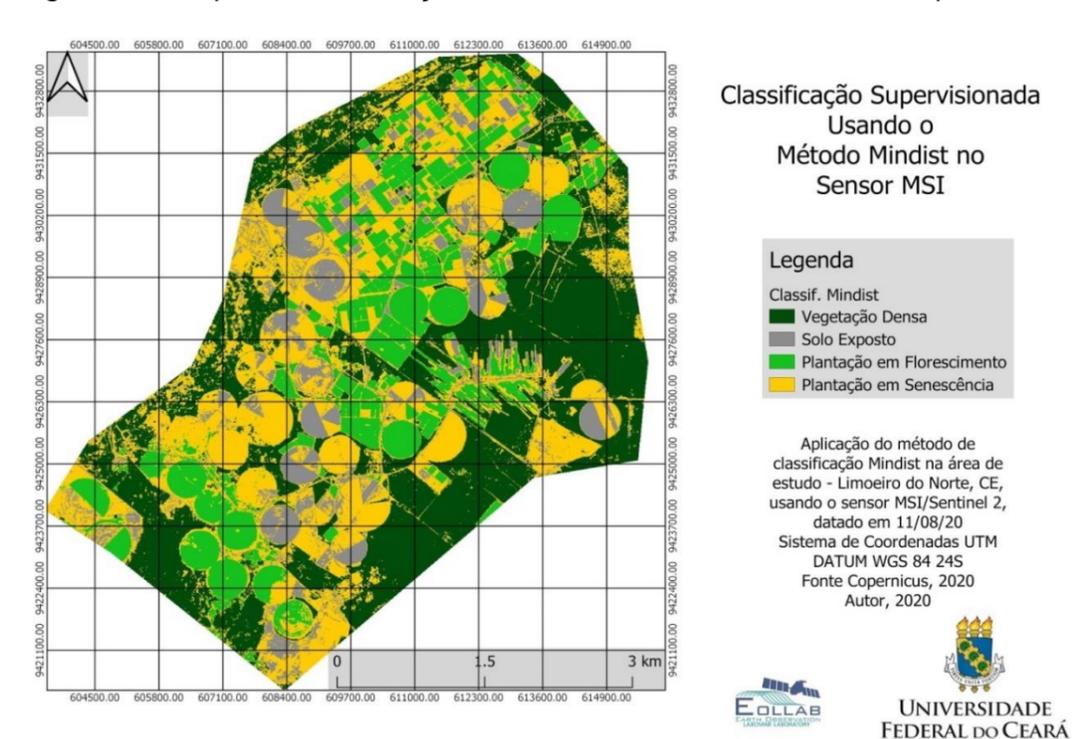
As figuras 11, 12, e 13, mostram os resultados do mapeamento feito a partir dos modelos de classificação; Maxver, Mindist e SAM. A tabela 8 mostra os percentuais de cada classe classificada.

Figura 11 – Mapa de classificação de área usando o método Maxver, para o satélite Sentinel 2.



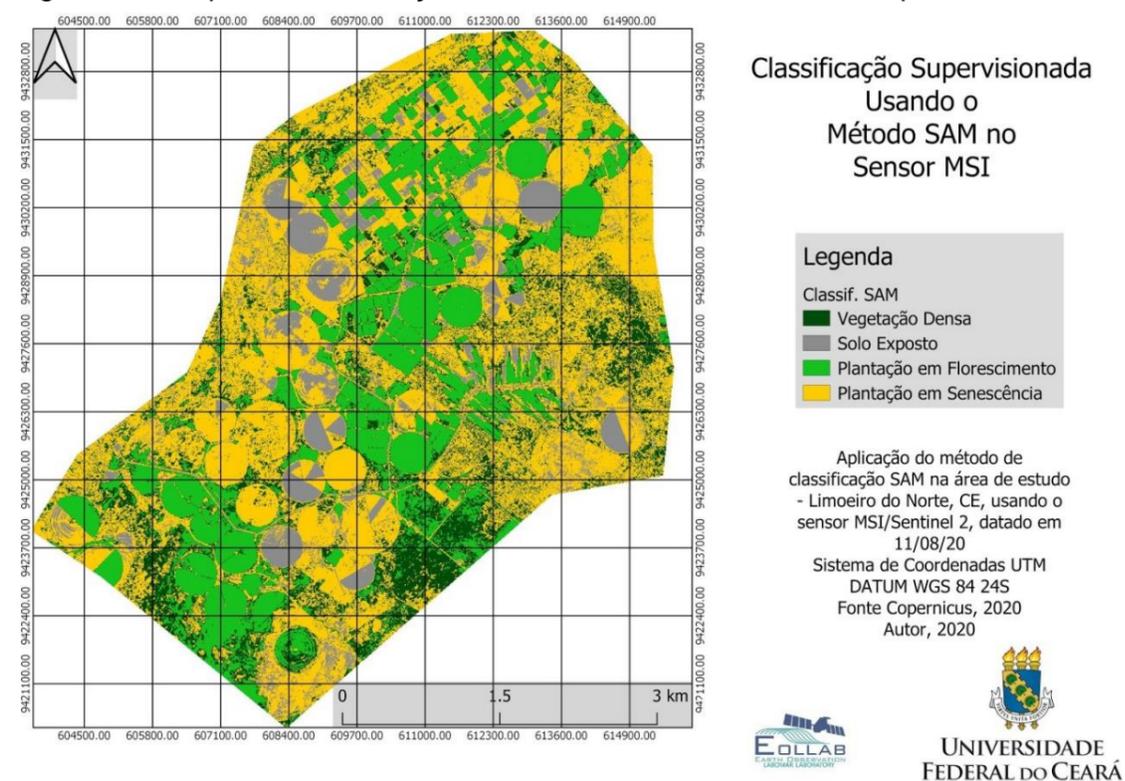
Fonte: Autor, 2020

Figura 12 - Mapa de classificação de área usando o método Mindist, para o satélite Sentinel 2.



Fonte: Autor, 2020.

Figura 13 - Mapa de classificação de área usando o método SAM, para o satélite Sentinel 2.



Fonte: Autor, 2020

Tabela 8 – Porcentagens de área classificada para cada classe, usando o satélite Sentinel 2

| Classe | Distancia Mínima | Máxima Verossimilhança | Spectral Angle Mapper |
|----------------------------|------------------|------------------------|-----------------------|
| Vegetação Densa | 46,08 | 42,34 | 56,33 |
| Solo Exposto | 9,65 | 14,03 | 10,29 |
| Plantação em Florescimento | 18,49 | 19,7 | 17,7 |
| Plantação em Senescência | 25,75 | 23,92 | 15,67 |

Fonte: Autor, 2020

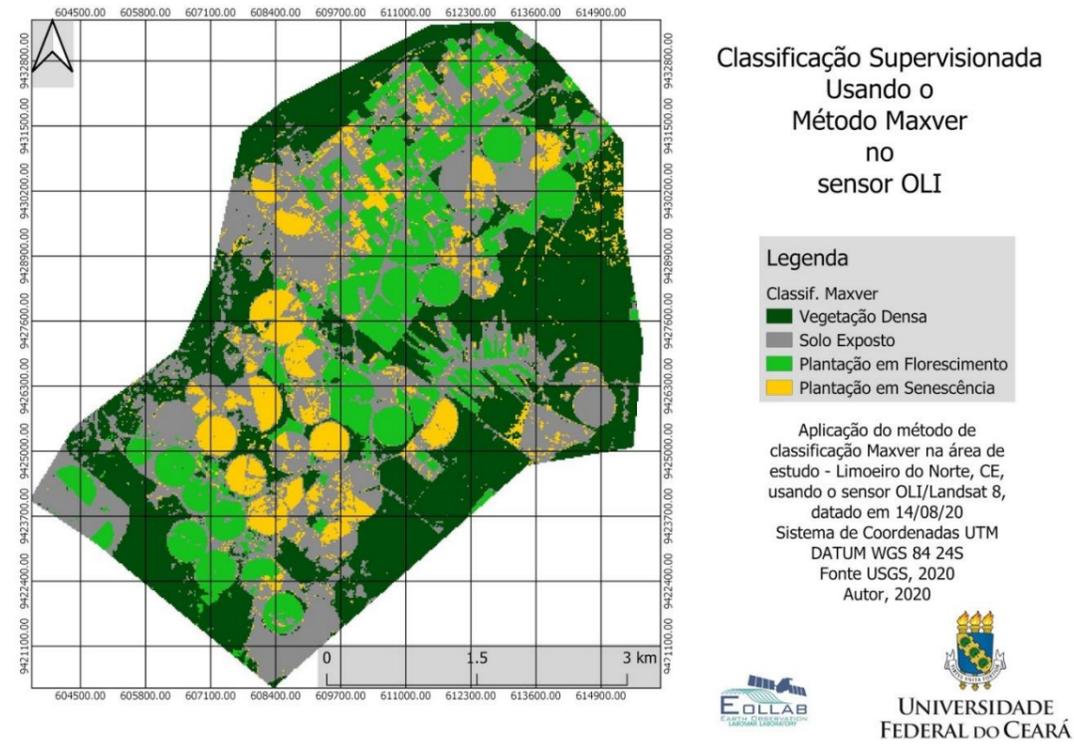
Analisando os mapas gerados com a imagem raster da área de estudo e os dados da tabela 6, é possível notar que o método SAM foi o que teve um pior desempenho, confundindo os pixels da classe de vegetação densa com plantação em senescência e os pixels de solo exposto foram confundidos com plantação em florescimento. O método Maxver foi o que melhor se saiu, mostrando uma maior área classificada como vegetação densa, a classe de solo exposto e de plantação em senescência foi confundida em algumas áreas, mas já era de se esperar, por conta da semelhança de tons e refletância. No caso do método Mindist, a classificação ficou de acordo com a imagem raster em composição RGB, assim como o Maxver, contudo houve confusão nas áreas de solo exposto, sendo essas áreas classificadas como plantação em senescência.

5.2 Classificação Landsat 8

Para as imagens do satélite Landsat 8, do dia 14 de agosto de 2020, foram gerados mapas para cada modelo de classificação usado.

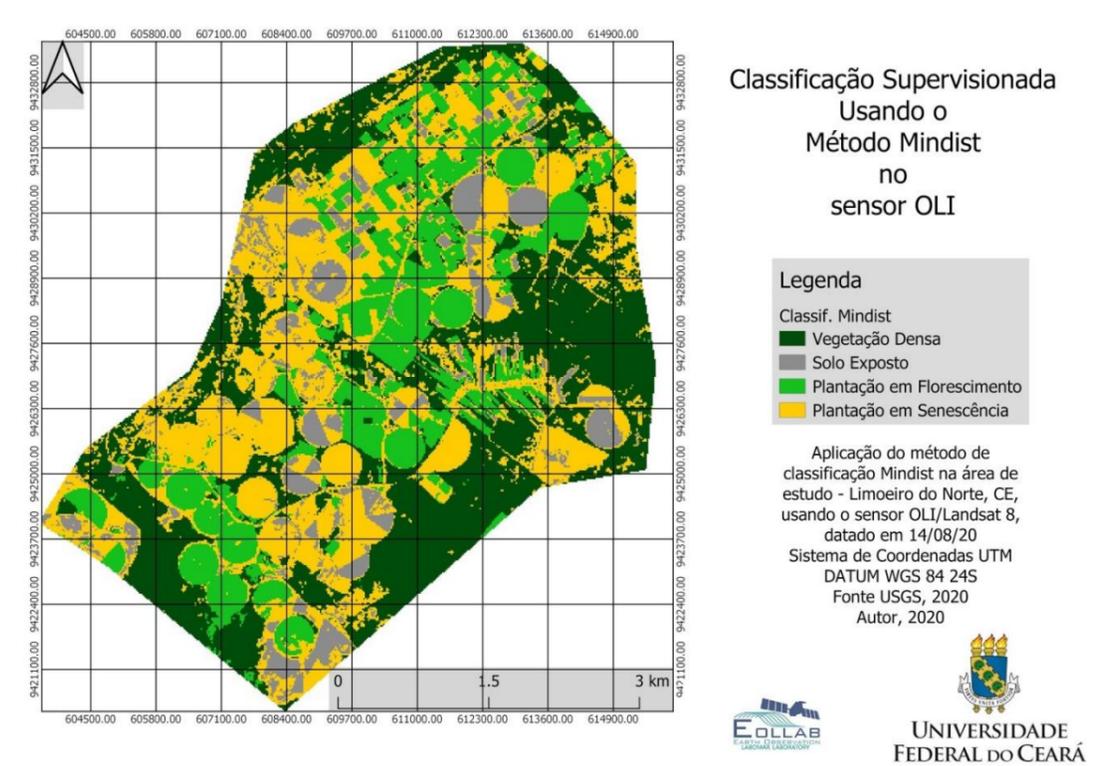
Nas figuras 14, 15, e 16, pode-se observar os resultados do mapeamento feito a partir dos modelos de classificação; Maxver, Mindist e SAM. A tabela 9 mostra os percentuais de cada classe classificada.

Figura 14 - Mapa de classificação de área usando o método Maxver, para o satélite Landsat 8.



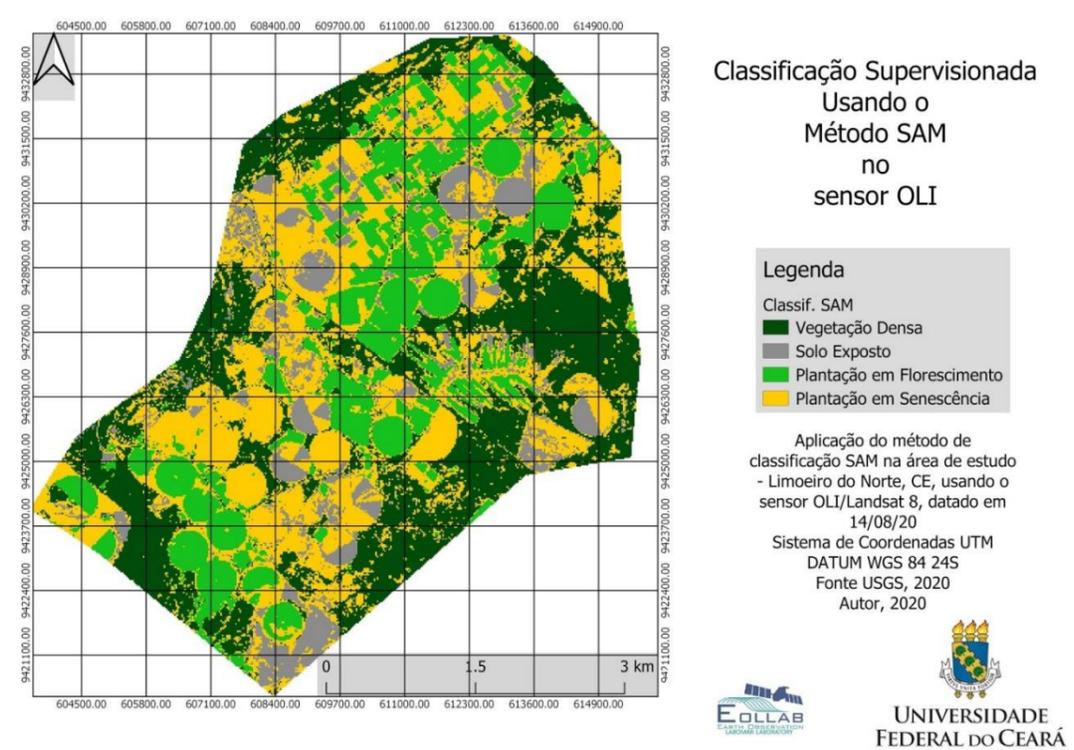
Fonte: Autor, 2020.

Figura 15 - Mapa de classificação de área usando o método Mindist, para o satélite Landsat 8.



Fonte: Autor, 2020.

Figura 16 - Mapa de classificação de área usando o método SAM, para o satélite Landsat 8.



Fonte: Autor, 2020

Tabela 9 - Porcentagens de área classificada para cada classe, usando o satélite Landsat 8.

| Classe | Distancia Mínima | Máxima Verossimilhança | Spectral Angle Mapper |
|----------------------------|------------------|------------------------|-----------------------|
| Vegetação Densa | 55,13 | 45,78 | 59,21 |
| Solo Exposto | 11,68 | 28,66 | 9,92 |
| Plantação em Florescimento | 3,58 | 1,73 | 6,22 |
| Plantação em Senescência | 29,59 | 23,81 | 24,63 |

Fonte: Autor, 2020.

Analisando os mapas gerados com a imagem raster da área de estudo e os dados da tabela 8, é possível notar que a classe de maior predominância no método SAM, é a de vegetação densa, contudo, houve confusão entre a classe de solo exposto e a classe de plantação em senescência, por conta da semelhança de refletâncias e tonalidades, como ocorreu com as classificações do satélite Sentinel no tópico 5.1.

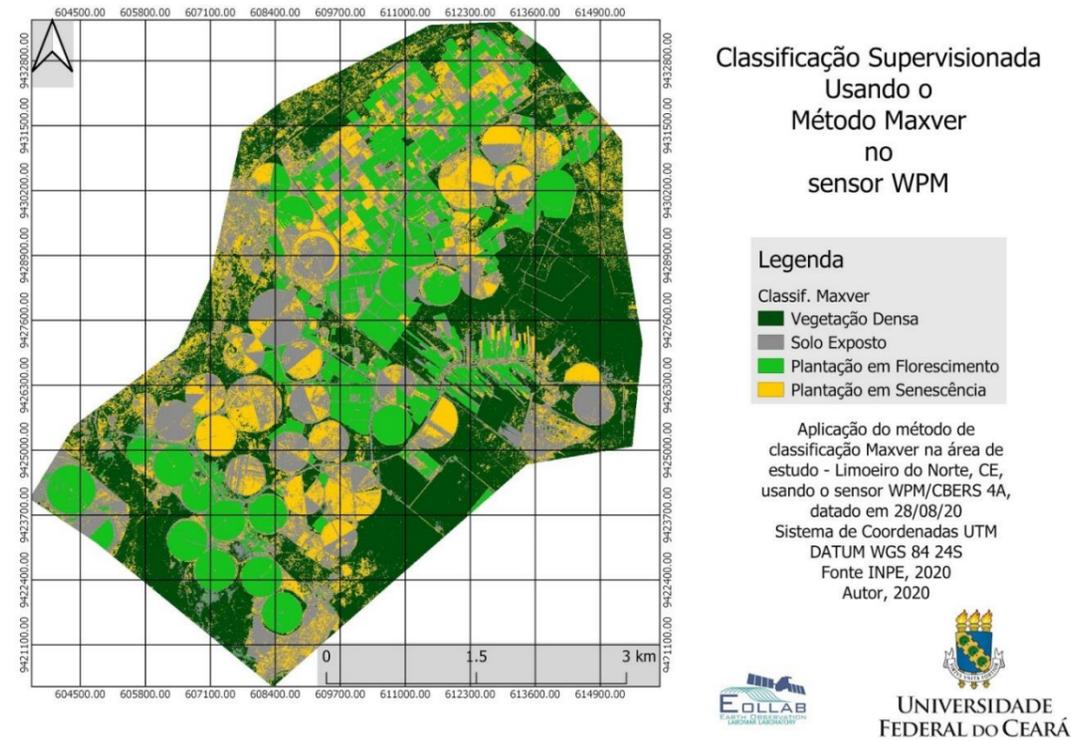
Os métodos Maxver e Mindist, são ótimos classificadores, contudo, na imagem Landsat 8, o Maxver se sobressaiu na classe de solo exposto, onde muitas vezes confundiu áreas de plantação em senescência com solo exposto, já no método Mindist ocorreu o inverso, sobressaiu-se na classe de plantação senescente, havendo confusão entre áreas de solo exposto e plantação senescente.

5.3 Classificação CBERS 4A

Para as imagens do satélite CBERS 4A, do dia 28 de agosto de 2020, foram gerados mapas para cada modelo de classificação usado.

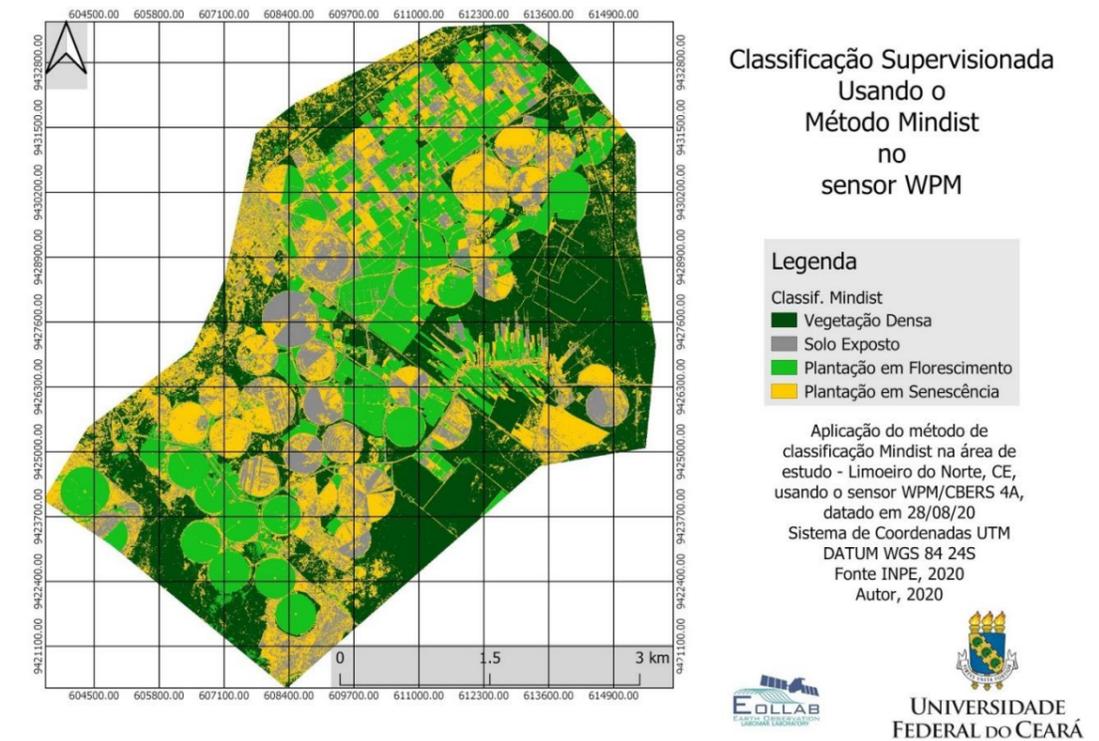
As figuras 17, 18, e 19, mostram os resultados do mapeamento feito a partir dos modelos de classificação; Maxver, Mindist e SAM. A tabela 10 mostra os percentuais de cada classe classificada.

Figura 17 - Mapa de classificação de área usando o método Maxver, para o satélite CBERS 4A.



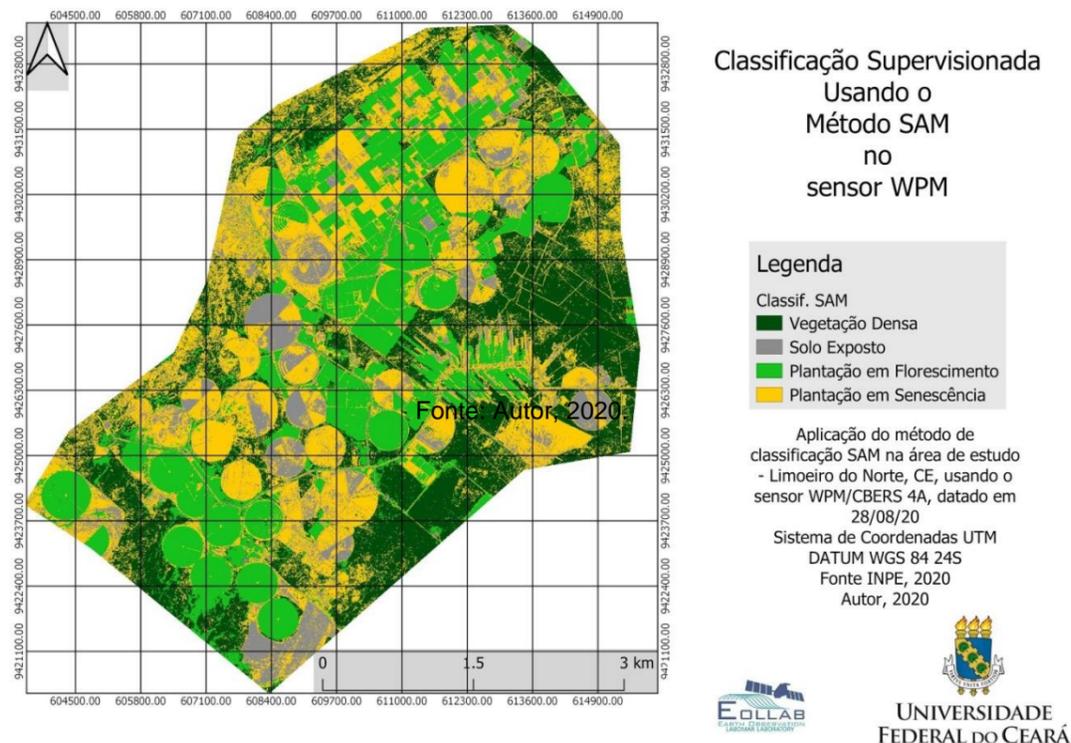
Fonte: Autor, 2020.

Figura 18 - Mapa de classificação de área usando o método Mindist, para o satélite CBERS 4A.



Fonte: Autor, 2020.

Figura 19 - Mapa de classificação de área usando o método SAM, para o satélite CBERS 4A.



Fonte: Autor, 2020.

Tabela 10 - Porcentagens de área classificada para cada classe, usando o satélite CBERS 4A.

| Classe | Distancia Mínima | Máxima Verossimilhança | Spectral Angle Mapper |
|----------------------------|------------------|------------------------|-----------------------|
| Vegetação Densa | 28 | 27,81 | 32,35 |
| Solo Exposto | 6,55 | 16,86 | 5,15 |
| Plantação em Florescimento | 9,45 | 4,24 | 12,71 |
| Plantação em Senescência | 56,01 | 51,06 | 49,77 |

Analisando os mapas gerados com a imagem raster da área de estudo e os dados da tabela 9, é possível notar um maior detalhamento das imagens classificadas, por conta da resolução espacial de 8 m. O método de classificação SAM mostrou a classe de plantação em senescência em predominância, assim como os outros métodos, Maxver e Mindist. Os três modelos mostraram uma confusão entre a classe de plantação em senescência e a classe do solo exposto, principalmente em regiões mais próximas a vegetação densa, porque nessas áreas há vegetação antropizada, e essa característica foi enquadrada na classe de solo exposto, contudo, a que foi mais similar a imagem raster em composição RGB foi o método Maxver.

5.4 Acurácia

Após as classificações, foi feita a medição das acurácias por meio de modelos estatísticos, gerando as acurácias do produtor e usuário, Índice Kappa e a Exatidão Global, para saber o quão cada método foi bem classificado, afirmando a sua aproximação com o meio real.

Na Tabela 10, podem ser visualizados os resultados obtidos para as acurácias do produtor e do usuário para o satélite Sentinel 2.

Tabela 11 - Acurácias do Produtor e Usuário para o satélite Sentinel 2.

| Sentinel 2 B | | | | | | |
|--------------|--------|-------|---------|-------|-------|-------|
| Classes | Maxver | | Mindist | | SAM | |
| | PA | PU | PA | PU | PA | PU |
| 1 | 66,81 | 99,94 | 95,1 | 99,97 | 35,31 | 94,78 |
| 2 | 99,95 | 75,07 | 88,42 | 81,06 | 94,18 | 77,68 |
| 3 | 90,73 | 99,75 | 98,27 | 99,54 | 99,45 | 76,24 |
| 4 | 20,07 | 89,42 | 88,41 | 67,51 | 69,87 | 26,29 |

Fonte: Autor, 2020.

A partir da tabela 9 é possível notar que o método Mindist teve um bom desempenho em relação a PA, indicando uma correta alocação dos pixels coletados, o que mostra que este método foi mais sensível que os demais. Contudo, os outros métodos não deixaram a desejar, apresentando um resultado ótimo.

De acordo com a tabela 10, nota-se que o método Maxver, em relação à PU, teve um melhor desempenho em relação aos demais, mostrando-se um método de maior confiabilidade.

Na Tabela 11, podem ser visualizados os resultados obtidos para as acurácias do produtor e do usuário para o satélite Landsat 8.

Tabela 12 - Acurácias do Produtor e Usuário para o satélite Landsat 8.

| Landsat 8 | | | | | | |
|-----------|--------|-------|---------|-------|-------|-------|
| Classes | Maxver | | Mindist | | SAM | |
| | PA | PU | PA | PU | PA | PU |
| 1 | 86,29 | 98,6 | 72,74 | 98,38 | 68,3 | 97,58 |
| 2 | 99,68 | 50,49 | 81,95 | 75,58 | 83,14 | 68,82 |
| 3 | 100 | 99,88 | 100 | 99,94 | 100 | 99,77 |
| 4 | 5,67 | 84,33 | 88,5 | 60,95 | 80,91 | 49,44 |

Fonte: Autor, 2020

Tratando-se do satélite Landsat 8, a PA que mostra o quão sensível é um determinado modelo de classificação, mostrou que o método Mindist (Distância Mínima) sobressaiu-se em relação aos demais. Nota-se a partir dos dados apresentados na Tabela 11 que a acurácia do produtor teve 100% de êxito na classe 3 (plantação em florescimento), mostrando que os três métodos de classificação tiveram maior sensibilidade, apresentando uma alocação correta das amostras feitas para plantação em florescimento.

Para a acurácia do usuário (PU) que significa uma maior confiabilidade de determinado método, por meio da visualização da tabela 11, o método Mindist e Maxver mostram-se confiáveis, tendo diferenças quase mínimas entre os dois, contudo, o método SAM se aproxima muito dos outros métodos.

Na Tabela 12, podem ser visualizados os resultados obtidos para as acurácias do produtor e do usuário para o satélite CBERS 4A.

Tabela 13 - Acurácias do Produtor e Usuário para o satélite CBERS 4A.

| CBERS 4A | | | | | | |
|----------|--------|-------|---------|-------|-------|-------|
| Classes | Maxver | | Mindist | | SAM | |
| | PA | PU | PA | PU | PA | PU |
| 1 | 86,71 | 99,66 | 80,92 | 99,69 | 73,9 | 99,31 |
| 2 | 98,21 | 62,09 | 72,43 | 63,28 | 67,87 | 66,88 |
| 3 | 94,94 | 99,73 | 99,51 | 99,05 | 99,86 | 94,49 |
| 4 | 17,99 | 80,14 | 35,11 | 73,71 | 28,94 | 60,93 |

Fonte: Autor, 2020.

De acordo com a tabela 12 o método Mindist apresentou melhores resultados para a PA.

Para a acurácia do usuário (PU), os métodos Mindist e Maxver, assim como para o satélite Landsat 8, mostraram resultados similares, indicando serem métodos confiáveis.

Os resultados para o satélite CBERS 4A apresentaram porcentagens menores se comparado com os outros satélites, isso ocorreu por conta da sua melhor resolução espacial. O CBERS 4A conta com uma resolução de 8 m, contra 30 m do Landsat 8 e contra 10 m do Sentinel 2.

5.4.1 Índice Kappa e Exatidão Global

Outra forma de medição de acurácia é por meio do Índice Kappa e da Exatidão Global. Para o Índice Kappa, os resultados são comparados com os valores do modelo proposto por Landis e Koch, indicados na tabela 4, já para a Exatidão Global, quanto mais próximo de 100% mais acurado o método.

De acordo com a tabela 13, o método com melhor desempenho em acurácia para o satélite Sentinel 2, é o de Distância Mínima, com Exatidão Global de 94% e valor Kappa de 0,83, que de acordo com a tabela 4, significa uma excelente classificação.

Para os valores do satélite Landsat 8, o método de Distância Mínima também apresentou melhor resultado, com 54,66% para Exatidão Global e 0,45% para o valor Kappa, mostrando uma razoável classificação.

Com o satélite CBERS 4A, os valores de Exatidão Global a 56,46% e Índice Kappa de 0,43 mostra que o método Mindist teve uma melhor

classificação, contudo, os valores Kappa para os três métodos foram muito semelhantes, sendo diferenciados pela segunda casa decimal, mas de acordo com os valores propostos por Landis e Koch (1977), os três métodos de classificação: Maxver, Mindist e SAM tiveram uma razoável classificação, variando de 0,4 à 0,6.

Tabela 14 - Resultados dos valores do Índice Kappa e Exatidão Global em relação a cada método de classificação para os três tipos de satélites.

| | | Exatidão Global | Índice Kappa |
|------------|---------|-----------------|--------------|
| Sentinel 2 | Maxver | 79,11 | 0,54 |
| | Mindist | 94,01 | 0,83 |
| | SAM | 20,33 | 0,17 |
| Landsat 8 | Maxver | 48,96 | 0,38 |
| | Mindist | 54,66 | 0,45 |
| | SAM | 51,5 | 0,41 |
| CBERS 4A | Maxver | 53,91 | 0,44 |
| | Mindist | 56,46 | 0,43 |
| | SAM | 54,51 | 0,42 |

Fonte: Autor, 2020.

6 CONCLUSÃO

Após concluir todas as etapas de processamento e análises, fica claro mais uma vez a grande importância da aplicação do sensoriamento remoto, sendo possível a percepção de áreas e de objetos, o mapeamento de regiões e a otimização do tempo de estudo associado a bons resultados.

A partir das análises realizadas, os três métodos Maxver, Mindist e SAM, mostraram resultados satisfatórios.

Contudo, o método de classificação supervisionada que apresentou melhor performance, foi o método da Distância Mínima (Mindist), se sobressaindo nos três satélites. O método da Máxima Verossimilhança (Maxver), sendo um modelo clássico e bastante usado, também apresentou bons

resultados, semelhantes ao método Mindist, a diferença nos resultados foi apenas por algumas casas decimais e pela análise visual das imagens geradas, como foi apresentado nos tópicos 5.1, 5.2 e 5.3.

Em relação ao desempenho dos satélites: Sentinel 2B, Landsat 8 e CBERS 4A, o que mostrou melhores resultados foi o satélite Sentinel 2B, em relação aos métodos de Maxver e Mindist, com classificação de razoável a excelente. Para o método SAM, o CBERS 4A teve melhor resultado, com classificação razoável.

REFERÊNCIAS

ALMEIDA, A., S.; SANTOS, R.; CHAVES, J. Mapeamento de Uso e Ocupação do Solo no Município de Jeremoabo-Ba: Uso do Algoritmo Máxima Verossimilhança (Maxver). Curitiba: **Simpósio Brasileiro de Sensoriamento Remoto**, 2011. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/07.12.17.17/doc/p0787.pdf>>. Acesso em: 5 jan. 2021.

ARAÚJO, M. P. **QGISBrasil**: Classificação Supervisionada de Imagens Orbitais com o Semi-Automatic Classification Plugin, 2015. Blog. Disponível em:<<http://qgisbrasil.org/blog/2015/08/18/qgis-classificacao-supervisionada-de-imagens-orbitais-com-o-semi-automatic-classification-plugin/>>. Acesso em: 19 out. 2020.

BARET, F; GUYOT, G. Potentials and limits of vegetation indices for LAI and APAR assessment. Montfavet, **Remote sensing of environment**, v. 35, n. 2 - 3, p. 161 - 173, 1991. Disponível em: <<https://reader.elsevier.com/reader/sd/pii/003442579190009U?token=A4F744B1587E77441A3EABBE0BA42559633AAB729B8CF6831A2551F906914A171D4BE8378E92F1AC7A6EA1C63D0F24F0> > Acesso em: 19 out 2020.

BORGES, R., O.; SILVA, R., A., A.; CASTRO, S., S. Utilização da classificação por distância euclidiana no mapeamento dos focos de arenização no setor sul da alta bacia do Rio Araguaia. Florianópolis: **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, 2007. Disponível em: <https://www.researchgate.net/publication/268180432_Utilizacao_da_classificacao_por_distancia_euclidiana_no_mapeamento_dos_focos_de_arenizacao_no_setor_sul_da_alta_bacia_do_Rio_Araguaia>. Acesso em: 04 jan. 2021.

BRASIL. **Empresa Brasileira de Pesquisa Agropecuária**. Visão 2030: O Futuro da Agricultura Brasileira, Brasília, p. 11 - 201, 2018. Disponível em:<<https://www.embrapa.br/documents/10180/9543845/Vis%C3%A3o+2030+-+o+futuro+da+agricultura+brasileira/2a9a0f27-0ead-991a-8cbf-af8e89d62829>>. Acesso em: 07 out. 2020.

BRASIL. **Instituto Brasileiro de Geografia e Estatística**. Produção Agrícola - Lavoura Temporária. 2019. Disponível em:<<https://cidades.ibge.gov.br/brasil/ce/pesquisa/14/10193?indicador=10347>> . Acesso em: 07 out. 2020.

BRASIL. **Ministério da Agricultura, Pecuária e Abastecimento**. Principais conceitos e expressões utilizados na agricultura de precisão - AP. Brasília, 2017, 1 p. Disponível em:<<https://www.gov.br/agricultura/pt-br/assuntos/sustentabilidade/tecnologia-agropecuaria/agricultura-de-precisao-1/arquivos-de-agricultura-de-precisao/conceitos-relacionados-a-agricultura-de-precisao-1.pdf>>. Acesso em: 07 out. 2020.

BRASIL. **Ministério da Agricultura, Pecuária e Abastecimento**. Portaria nº 852 - Art. 1º Criar a Comissão Brasileira de Agricultura de Precisão – CBAP.

Diário Oficial da República Federativa do Brasil, Brasília, DF, 21 set. 2012. Seção 1, n. 184. Disponível em: <http://www.cnpt.embrapa.br/biblio/do/p_do42.htm>. Acesso em: 23 nov. 2020.

CEARÁ. Centrais de Abastecimento do Ceará. **Os caminhos do milho no Ceará**. 2016. Disponível em: <<https://www.ceasa-ce.com.br/2016/05/31/os-caminhos-do-milho-no-ceara/>>. Acesso em: 19 out. 2020.

CHAVEZ JR, Pat S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. Arizona, **Remote sensing of environment**, v. 24, n. 3, p. 459 - 479, 1988. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0034425788900193>> Acesso em: 19 out 2020.

CHUVIECO, E. Fundamentos de teledetección espacial. 2. ed. Madrid, **Unigraf**. p. 453, 1990. Disponível em: <https://www.academia.edu/37242564/FUNDAMENTOS_DE_TELEDETECCION_EMILIO_CHUVIECO_pdf>. Acesso em: 19 out 2020

CHADE, J. Brasil passa a ser 3º maior exportador agrícola, mas clima ameaça o futuro. **Estadão**, São Paulo, 2018. Disponível em: <<https://economia.estadao.com.br/noticias/geral,brasil-passa-a-ser-3-maior-exportador-agricola-mas-clima-ameaca-futuro,70002506105>> Acesso em: 07 out. 2020.

CONGALTON, G. R. A review of assessing the accuracy of classifications of remotely sensed data. Berkeley, **Remote sensing of environment**, v. 37, n. 1, p. 35 - 46, 1991. Disponível em: <<https://www.sciencedirect.com/science/article/pii/003442579190048B>>. Acesso em: 19 out. 2020

CONGALTON, G,R. Accuracy assessment and validation of remotely sensed and other spatial information. [S.l.], **International Journal of Wildland Fire**, v. 10, n. 4, p. 321 - 328, 2001. Disponível em: <https://www.researchgate.net/publication/220040678_Accuracy_assessment_and_validation_of_remotely_sensed_and_other_spatial_information> Acesso em: 19 out 2020.

CONGALTON, R., G. Putting the map back in map accuracy assessment. **Remote sensing and GIS accuracy assessment**. United States America. CRC Press, p. 1-11, 2004. Disponível em: <[https://books.google.com.br/books?hl=pt-BR&lr=&id=KFUV1LL25EIC&oi=fnd&pg=PA1&dq=Congalton+e+Mead+\(1993\)&ots=MW_ZSW_Vje&sig=oLGDq4dmmcGQHuhlwwBlyowH8P8#v=onepage&q=Congalton%20e%20Mead%20\(1993\)&f=false](https://books.google.com.br/books?hl=pt-BR&lr=&id=KFUV1LL25EIC&oi=fnd&pg=PA1&dq=Congalton+e+Mead+(1993)&ots=MW_ZSW_Vje&sig=oLGDq4dmmcGQHuhlwwBlyowH8P8#v=onepage&q=Congalton%20e%20Mead%20(1993)&f=false)>. Acesso em: 06 jan 2021.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. Florianópolis, **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, v. 13, p. 5755 - 5762, 2007. Disponível em: <<https://docplayer.com.br/21802379-Estudo-do-comportamento->

dos-indices-de-exatidao-global-kappa-e-tau-comumente-usados-para-avaliar-a-classificacao-de-imagens-do-sensoriamento-remoto.html> Acesso em: 19 out 2020.

FOODY, G., M.; MCCULLOCH, M., B.; YATES, W., B. Classification of remotely sensed data by an artificial neural network: issues related to training data. Mayland. **Photogrammetric Engineering Remote Sensing**, v. 61, n. 4, p. 391-401, 1995. Disponível em:<https://www.researchgate.net/publication/243774601_Classification_of_remotely_sensed_data_by_an_artificial_neural_network_Issues_related_to_training_data_characteristics>. Acesso em: 04 jan. 2021.

FREIRES, E. V. et al. Comparação de Imagens OLI/Landsat-8 e MSI/Sentinel-2 no Mapeamento de Cobertura e Uso da Terra no Maciço de Uruburetama, Ceará. [S.l.], **Anuário do Instituto de Geociências**, v. 42, n. 4, p. 427- 442, 2020. Disponível em:<<https://revistas.ufrj.br/index.php/aigeo/article/view/31379>>. Acesso em: 19 out 2020.

FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento Remoto em agricultura. 1 ed. São Paulo: Oficina de Textos, p. 285, 2017.

INPE/CBERS. Disponível em: <<http://www.cbbers.inpe.br/sobre/index.php>>. Acesso em: 26 nov. 2020.

INPE/CBERS. Disponível em: <<http://www.cbbers.inpe.br/sobre/cameras/cbbers04a.php>>. Acesso em: 26 nov. 2020.

KRUSE, F. A. et al. The spectral image processing system (SIPS) - interactive visualization and analysis of imaging spectrometer data. **Remote Sensing of Environment**, v. 44, n. 2 - 3, p. 145 - 163, 1993. Disponível em:<<https://www.sciencedirect.com/science/article/pii/003442579390013N>>. Acesso em: 05 jan 2021

KAVZOGLU, T.; VIEIRA, C. A. O. An Analysis of Artificial Neural Network Pruning Algorithms in Relation to Land Cover Classification Accuracy. **Proceedings of the Remote Sensing Society Student Conference**: Oxford, p. 53 - 58, 1998. Disponível em: <(PDF) An Analysis of Artificial Neural Network Pruning Algorithms in Relation to Land Cover Classification Accuracy (researchgate.net)>. Acesso em: 05 jan. 2021.

LANDIS, R. J.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159 - 174, 1977. Disponível em: <<https://www.jstor.org/stable/2529310?seq=1>>. Acesso em: 19 out. 2020.

Landsat 8 Overview | Landsat Science. Disponível em: <<https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview>>. Acesso em: 25 nov. 2020.

LILLESAND, T.M.; KIEFER, R. W.; CHIPMAN, J. W. Remote sensing and image interpretation. 5. ed. New York: **John Wiley & Sons**, 2003. Disponível em: <<https://b-ok.lat/book/1167981/6e2070>>. Acesso em: 19 out 2020.

MASTELLA, A. F. M.; VIEIRA, C. A. O. Acurácia temática para classificação de imagens utilizando abordagens por pixel e por objetos. **Revista Brasileira de Cartografia**, v. 70, p. 1618-1643, 31 dez. 2018. Disponível em: <<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/4455>>. Acesso em: 06 jan 2021.

MENESES, P. R.; ALMEIDA, T. de. Introdução ao processamento de imagens de sensoriamento remoto. Universidade de Brasília, Brasília, 2012. Disponível em: <https://d1wqtxts1xzle7.cloudfront.net/33333156/MENESES__ALMEIDA_2012_INTRO_AO_PROCESSAMENTO_DE_IMAGEM.pdf?1395991613=&response-content-disposition=inline%3B+filename%3DMENESES_and_ALMEIDA_2012_INTRO_AO_PROCES.pdf&Expires=1606533470&Signature=L9ybmogogJrAUoeFFoT2RIPu48D~I-1XgK1O8qwuaxCRmX5cO2k-Hd0R~GhhFOu9oEAdpFTt6RliS~8gHTDGAF7vKO4aq~vpRuvdLrRGSeQvgti2iF5z4OKPt22Bh8~h4OaZKOz86o8W4UOMtstSeOd3oWFxrBjGsVx6Q10i9uOBXtd7LFQ3K66LhXmHmRGCEyujD8YguTHvIXJ0fCE4CeMYaESJB8gMw2QHmwAiY4gSP4C6M89fW5yzxsLrHzCGvwrgLKYK38CMBp8IXklM07X8HQP7NwnUEf9z5rxYnF3~IVSrt-nPMZTuGAfwYpOduLkqIL2trTFGMWPHFBh~Fiw__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA>. Acesso em: 27 de nov. 2020

MENESES, P., R.; SANO, E., E. Classificação Pixel a Pixel de Imagens. *In*: MENESES, P., R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: Universidade de Brasília, 2012, p.191-206. Disponível em: <<http://memoria.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso em: 04 jan. 2021.

MOLIN, J., P.; AMARAL, R., L.; COLAÇO, A., F. **Agricultura de Precisão**. 1 ed. São Paulo: Oficina de Textos, 2015. Disponível em: <<https://www.bibliotecaagpatea.org.br/agricultura/precisao/livros/AGRICULTURA%20DE%20PRECISAO%20-%20OFICINA%20DE%20TEXTOS.pdf>>. Acesso em: 07 out. 2020.

MONICO, G. et al. Acurácia e Precisão: Revendo os Conceitos de Forma Acurada. Curitiba. **Boletim de Ciências Geodésicas**, v. 15, n. 3, p. 469 - 483, 2009. Disponível em: <https://www.researchgate.net/publication/265248657_Acuracia_e_precisao_revendo_os_conceitos_de_forma_acurada_Accuracy_and_Precision_Reviewing_the_concepts_by_means_of_an_accurate_procedure>. Acesso em: 06 jan 2021.

MÜLLER, S., I., M., G.; RAKI, H. **Comparação entre os métodos de máxima verossimilhança, distância mínima e o método de Fisher para reconhecimento de padrões em imagens coloridas**. Dissertação (Mestrado em Ciências) - Pós Graduação em Ciências Geodésicas do Setor de

Tecnologia, Universidade Federal do Paraná. Paraná, p.116. 1997. Disponível em:<<https://www.acervodigital.ufpr.br/bitstream/handle/1884/44185/D%20-%20SONIA%20ISOLDI%20MARTY%20GAMA%20MULLER.pdf?sequence=1&isAllowed=y>>. Acesso em: 04 jan 2021.

PANTALEÃO, E.; SCOFIELD, G., B. Comparação entre medidas de acurácia de classificação para imagens do satélite ALOS. **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, v. 14, p. 7039-7046. Disponível em:<<http://martel.sid.inpe.br/col/dpi.inpe.br/sbsr%4080/2008/11.17.20.26/doc/7039-7046.pdf>>. Acesso em: 06 jan 2021.

ROUSE JR, J. W. et al. Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation. Washington, **NASA. Goddard Space Flight Center 3d ERTS-1 Symp.**, v. 1, p. 309 - 317, 1973. Disponível em: <<https://ntrs.nasa.gov/citations/19740022614>> Acesso em: 19 out 2020.

Sentinel-2 - Missions - Sentinel Online. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 25 nov. 2020.

Sentinel-2 - Missions - Instrument Payload - Sentinel Handbook. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2/instrument-payload/>>. Acesso em: 25 nov. 2020.

TRABAQUINI, K.; FORMAGGIO, R. A.; GALVÃO, S. L. Changes in physical properties of soils with land use time in the Brazilian savanna environment. **Land Degradation & Development**, v. 26, n. 4, p. 397 - 408, 2015. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/ldr.2222>> Acesso em: 07 out. 2020.

VALE, J., R., B. et al. Análise comparativa de métodos de classificação supervisionada aplicada ao mapeamento da cobertura do solo no município de Medicilândia, Pará. **InterEspaço: Revista de Geografia e Interdisciplinaridade**, v. 4, n. 13, p. 26-44, 2018. Disponível em:<<http://www.periodicoseltronicos.ufma.br/index.php/interespaco/article/view/7884>>. Acesso em: 04 jan. 2021.

VENTURIEIRI, A. Introdução às técnicas de Sensoriamento Remoto. Belém: UFPA, 2007.

YENGOH, G. T.; DENT, D.; OLSSON, L.; TENGBERG, A. E.; TUCKER III, C. J. Use of the Normalized Difference Vegetation Index (NDVI) to Assess Land Degradation at Multiple Scales: Current Status, Future Trends, and Practical Considerations. Springer Briefs in Environmental Science, 2015. Disponível em: <[https://books.google.com.br/books?hl=pt-BR&lr=&id=IPnpCgAAQBAJ&oi=fnd&pg=PR5&dq=YENGOH,+G.+T.%3B+DENT,+D.%3B+OLSSON,+L.%3B+TENGBERG,+A.+E.%3B+TUCKER+III,+C.+J.+Use+of+the+Normalized+Difference+Vegetation+Index+\(NDVI\)+to+Assess+Land+Degradation+at+Multiple+Scales:+Current+Status,+Future+Trends,+and+Prac](https://books.google.com.br/books?hl=pt-BR&lr=&id=IPnpCgAAQBAJ&oi=fnd&pg=PR5&dq=YENGOH,+G.+T.%3B+DENT,+D.%3B+OLSSON,+L.%3B+TENGBERG,+A.+E.%3B+TUCKER+III,+C.+J.+Use+of+the+Normalized+Difference+Vegetation+Index+(NDVI)+to+Assess+Land+Degradation+at+Multiple+Scales:+Current+Status,+Future+Trends,+and+Prac)>

tical+Considerations.+Springer+Briefs+in+&ots=URU6SJlbgU&sig=mDcCBBsTlNyfXQsEm72AtBDoZgc#v=onepage&q&f=false>. Acesso em: 27 de nov. 2020.