

ANA CLARA DE BARROS

**ESTIMATIVA DA PRODUÇÃO AGRÍCOLA POR MEIO DE TÉCNICAS DE
SENSORIAMENTO REMOTO**

Botucatu

2021

ANA CLARA DE BARROS

**ESTIMATIVA DA PRODUÇÃO AGRÍCOLA POR MEIO DE TÉCNICAS DE
SENSORIAMENTO REMOTO**

Tese apresentada à Faculdade de Ciências Agronômicas da Unesp Câmpus de Botucatu, para obtenção do título de Doutora em Agronomia (Energia na Agricultura).

Orientador: Dr. Zacarias Xavier de Barros

Botucatu

2021

B277e	<p>Barros, Ana Clara de</p> <p>Estimativa da produção agrícola por meio de técnicas de sensoriamento remoto / Ana Clara de Barros. -- Botucatu, 2021</p> <p>179 p. : il., tabs., mapas</p> <p>Tese (doutorado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrônômicas, Botucatu</p> <p>Orientador: Zacarias Xavier de Barros</p> <p>1. Agronomia. 2. Sensoriamento remoto. 3. Produção agrícola. 4. Índice de vegetação. 5. Geoprocessamento. I. Título.</p>
-------	---

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrônômicas, Botucatu. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

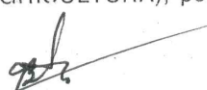
CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: ESTIMATIVA DA PRDUÇÃO AGRÍCOLA POR MEIO DE TÉCNICAS DE SENSORIAMENTO REMOTO

AUTORA: ANA CLARA DE BARROS


ORIENTADOR: ZACARIAS XAVIER DE BARROS

Aprovada como parte das exigências para obtenção do Título de Doutora em AGRONOMIA (ENERGIA NA AGRICULTURA), pela Comissão Examinadora:


Prof. Dr. ZACARIAS XAVIER DE BARROS (Participação Virtual)
Engenharia Rural e Socioeconomia / Faculdade de Ciências Agrônômicas de Botucatu - UNESP


Dr.ª YARA MANFRIM GARCIA (Participação Virtual)
Bauru/SP /


Prof.ª Dr.ª FRANCISCA FRANCIANA SOUSA PEREIRA (Participação Virtual)
Pós-Doutoranda - Engenharia Rural e Socioeconomia / Faculdade de Ciências Agrônômicas de Botucatu


Prof. Dr. DONIZETI APARECIDO PASTORI NICOLETE (Participação Virtual)
Engenharia Civil / Faculdades Integradas de Bauru


Prof. Dr. OSMAR DELMANTO JUNIOR (Participação Virtual)
Agronegócio / Faculdade de Tecnologia de Botucatu

Botucatu, 19 de julho de 2021

Aos meus amados pais e irmão,

Beto, Gil e João.

Dedico

AGRADECIMENTOS

À Deus, por me permitir alcançar e realizar os meus sonhos. Por sempre estar comigo, iluminando e abençoando meu caminho;

Aos meus pais e irmão, pela paciência, pelo amor incondicional, pelo amparo em todos os momentos e por me darem força e apoio em todas as fases da minha vida. A vocês, todo meu amor e reconhecimento;

À toda minha família, pelo incentivo e apoio. Em especial a Tia Flávia, que me inspira todos os dias a lutar e conquistar todos os meus sonhos;

À Patrícia, que me incentiva e me ajuda tanto, que me auxiliou em muitos momentos para o desenvolvimento dos meus estudos, sem sua intervenção e seu apoio não teria chegado até aqui;

Ao meu querido orientador, Prof. Dr. Zacarias Xavier de Barros, por se fazer presente em minha vida nesses seis anos, por acompanhar meu desenvolvimento acadêmico e pessoal, sempre me orientando e aconselhando da melhor forma possível. Agradeço pelo incentivo desde meus primeiros passos na pesquisa, por acreditar em mim e em minha capacidade. Pelo acolhimento, confiança, amizade e credibilidade em mim depositadas. Sou infinitamente grata pelo apoio, generosidade e por me ensinar a cada instante em ser uma profissional dedicada, colocar amor em tudo que fizer e principalmente a ser uma pessoa melhor. Nossa jornada acadêmica se encerra aqui, mas te levarei para sempre em meu coração, com grande carinho e respeito, pelo ser humano e professor incrível que és.

À Faculdade de Ciências Agrônômicas (FCA – UNESP), câmpus de Botucatu, e à Coordenadoria do Programa de Pós-Graduação em Agronomia – Energia na Agricultura, pela oportunidade, apoio e assistência;

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento Pessoal de Nível Superior – Brasil – CAPES – Código de financiamento 88887.514323/2020-00;

Aos colaboradores da Biblioteca “Prof. Paulo de Carvalho Mattos” e da Seção Técnica de Pós-Graduação da FCA, por toda assistência prestada;

A todos dos Departamentos, Engenharia Rural e Socioeconômica e Ciência Florestal, Solo e Ambiente (docentes e colaboradores), pela convivência, auxílio e aprendizados;

Aos amigos do Grupo de Estudos e Pesquisas Agrárias Georreferenciadas (GEPAG), pela convivência e trocas de conhecimentos e experiências;

A Prof. Dra. Célia Regina Lopes Zimback, por todo acolhimento, suporte e orientações desde o mestrado. Foi de suma importância nosso convívio e conversas, para a minha vida acadêmica, profissional e pessoal.

A Prof. Dra. Yara Manfrin Garcia, que foi a primeira pessoa a me incentivar a ingressar nesse mundo da pós-graduação, que me abriu muitas portas, me ensinou e me auxiliou em muitos aspectos acadêmicos;

A Prof. Dra. Renata Teixeira de Almeida Minhoni, pela parceria, ensinamentos, conselhos, por todas as contribuições e melhorias apresentadas para esse trabalho;

Ao Prof. Dr. Donizeti Aparecido Pastori Nicolete, por toda paciência, disponibilidade em ajudar, atenção e esclarecimentos;

Aos professores doutores Yara Manfrin Garcia, Donizeti Aparecido Pastori Nicolete, Osmar Delmanto Júnior e Francisca Franciana Sousa Pereira, por serem membros das bancas desse trabalho, pela disposição e contribuições proporcionadas;

Aos amigos da Pós-Graduação, que participaram de todas as fases desde o início do mestrado até o fim desse ciclo, Amanda, Letícia, Renata, Sara, Samuel e Felipe. Agradeço por todo suporte, ensinamentos, aprendizados, perrengues, aventuras e por todos os momentos maravilhosos e outros nem tanto vividos nesses anos todos. A vocês todo meu amor e carinho;

A todos os meus amados amigos, por estarem sempre ao meu lado, me apoiando, torcendo pelas minhas conquistas, me incentivando a alcançar meus sonhos e deixando os desafios da vida mais leve;

Enfim, agradeço a todos que estiveram ao meu lado, deixando o caminho mais colorido e alegre, para que eu conseguisse vencer mais essa etapa da minha vida!

RESUMO

A atividade agrícola tem grande relevância para a economia brasileira, o que torna a previsão de safras agrícolas um procedimento de grande importância. Os levantamentos agrícolas no país ainda são de caráter subjetivo e não probabilístico, fundamentalmente embasados em entrevistas ligadas as pessoas do setor agrícola. Os avanços obtidos pelas geotecnologias, principalmente as imagens orbitais e as ferramentas de Sistemas de Informação Geográfica, propiciam diversas aplicações operacionais com resultados precisos. Neste sentido, objetiva-se com essa pesquisa estimar a produção da cultura da soja, por técnicas de sensoriamento remoto, como imagens do sensor multiespectral MSI embarcado no satélite Sentinel e índices de vegetação, tendo como base áreas no município de Itaberá-SP. Os procedimentos metodológicos foram baseados em um banco de dados de imagens orbitais relacionados a safra 2019/2020 da cultura da soja, realizando cálculos de 12 índices de vegetação e correlacionando esses dados espectrais com os dados obtidos em campo, por meio da regressão de Tau de Kendall. Foi possível verificar que o resultado geral da análise apresentou uma correlação fraca e estatisticamente não significativa. Com a aplicação dos índices de vegetação foi possível analisar o comportamento espectro-temporal da cultura e verificar que o mês de maior desenvolvimento das plantas foi janeiro e comprovar que os índices realmente são um recurso importante para realizar a análise do desenvolvimento da vegetação. Por meio das análises e modelagem estatística foi possível elaborar um modelo que conseguisse prever a produtividade da cultura da soja, mas que não foi muito preciso pelo pequeno número de observações. De todos os índices calculados, apenas dois foram selecionados pelo modelo, sendo eles, o GSAVI e o NDWI. Com o modelo gerado foi possível realizar a previsão da produção da cultura da soja e estimar o erro estimado, entre a produção observada e a produção ajustada. Sendo assim, com a utilização das técnicas de sensoriamento remoto é possível realizar estudos de variabilidade espacial de produtividade de culturas agrícolas.

Palavras-chave: geoprocessamento; índice de vegetação; produção agrícola.

ABSTRACT

Agricultural activity has great relevance for the Brazilian economy, which makes the forecast of agricultural harvests a procedure of great importance. In the country, agricultural surveys are still subjective and not probabilistic, fundamentally based on interviews related to people in the agricultural sector. The advances obtained by geotechnologies, mainly the orbital images and the tools of Geographic Information Systems, provide several operational applications with precise results. Therefore, this research aimed to estimate the soybean production, using remote sensing techniques, such as images from the MSI multispectral sensor on the Sentinel satellite and vegetation indices, based on areas in the municipality of Itaberá-SP. The methodological procedures were based on a database of orbital images related to the 2019/2020 harvest of the soybean, performing calculations of 12 vegetation indices and correlating these spectral data with the data obtained in the field, through the regression of tau de Kendall. It was possible to verify that the general result of the analysis showed a weak and statistically non-significant correlation. With the application of the vegetation indices it was possible to analyze the spectro-temporal behavior of the crop and verify that the month of greatest development of the plants was January and to prove that the indices are an important resource to carry out the analysis of the vegetation development. Through analysis and statistical modeling, it was possible to develop a model that was able to predict the productivity of the soybean, but which was not very accurate due to the small number of observations. Among all the calculated indices, only two were selected by the model, namely, GSAVI and NDWI. With the generated model it was possible to make the prediction of the production of the soybean crop and estimate the estimated error, between the observed production and the adjusted production. Therefore, with the use of remote sensing techniques, it is possible to carry out studies of spatial variability in the productivity of in the crop productivity.

Keywords: geoprocessing; vegetation index; agricultural production.

LISTA DE ILUSTRAÇÕES

Figuras

Figura 1 - Comportamento espectral da vegetação e os importantes fatores que atuam na reflectância levando em consideração as distintas regiões espectrais do sensoriamento remoto.....	27
Figura 2 - Condições de interação da energia eletromagnética incidente em uma folha vegetal.....	29
Figura 3 - Esquema do monitoramento agrícola.....	32
Figura 4 - Localização da área de estudo no município de Itaberá-SP.....	53
Figura 5 - Fluxograma das fases metodológicas.....	57
Figura 6 - Diagrama de caixa (<i>boxplot</i>) da produção conforme cada mês.....	68
Figura 7 - Diagrama de caixa (<i>boxplot</i>) dos índices de vegetação conforme cada mês.....	71
Figura 8 - Matriz de correlação das variáveis em estudo.....	76
Figura 9 - Matriz de correlação das variáveis em estudo – mês de outubro.....	77
Figura 10 - Matriz de correlação das variáveis em estudo – mês de novembro...	78
Figura 11 - Matriz de correlação das variáveis em estudo – mês de dezembro...	79
Figura 12 - Matriz de correlação das variáveis em estudo – mês de janeiro.....	80
Figura 13 - Matriz de correlação das variáveis em estudo – mês de fevereiro.....	81
Figura 14 - Gráfico de dispersão resíduos vs. valores ajustados – modelo Tabelas 5 e 6.....	86
Figura 15 - Gráfico de dispersão das observações nos componentes principais para cada mês analisado.....	90
Figura 16 - Gráfico de dispersão das médias nos componentes principais para cada mês analisado.....	90
Figura 17 - Gráfico normal de probabilidades referentes ao modelo gama ajustado.....	96
Figura 18 - Gráfico de dispersão resíduos vs. valores ajustados.....	96
Figura 19 - Gráfico de comparação entre a produção observada e a produção ajustada por meio do modelo.....	98

Quadros

Quadro 1 - Especificações do satélite Sentinel 2.....	43
Quadro 2 - Dados das imagens orbitais.....	54
Quadro 3 - Dados de campo.....	55
Quadro 4 - Índices de vegetação avaliados.....	56
Quadro 5 - Pressupostos básicos para empregar a ACP.....	63

LISTA DE TABELAS

Tabela 1 - Medidas resumo da produtividade da cultura de soja segunda cada mês.....	65
Tabela 2 - Medidas resumo para os índices de vegetação da cultura da soja conforme cada mês.....	69
Tabela 3 - Teste de normalidade para as variáveis quantitativas do estudo.....	73
Tabela 4 - Avaliação da correlação entre os índices e a produção conforme cada mês.....	75
Tabela 5 - Estimativas dos parâmetros de efeitos fixos referentes ao modelo gama misto ajustado para os índices de vegetação.....	84
Tabela 6 - Diagnóstico de colinearidade para o modelo gama misto completo ajustado.....	85
Tabela 7 - Diagnóstico de colinearidade para o modelo gama (GLM) completo ajustado.....	87
Tabela 8 - Autovalores e proporções de variáveis explicadas.....	88
Tabela 9 - Coeficientes dos dois primeiros componentes principais.....	89
Tabela 10 - Comparações de médias pareadas por índice de vegetação.....	92
Tabela 11 - Processo de seleção de variáveis – <i>stepwise</i> – para compor o modelo final.....	94
Tabela 12 - Estimativas dos parâmetros referentes ao modelo Gama com efeitos multiplicativos para os índices selecionados.....	95
Tabela 13 - VIF do modelo: Produção ~ GSAVI + NDWI.....	95
Tabela 14 - Valores observados e ajustados pelo modelo Gama obtido.....	97

LISTA DE ABREVIATURAS E SIGLAS

ACP	Análise de Componentes Principais
Amis	<i>Agricultural Market Information System</i>
CEPAGRI	Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura
Chl	Teor de clorofila
CONAB	Companhia Nacional de Abastecimento
CV	Coeficiente de variação
EVI	<i>Enhanced Vegetation Index</i>
EVI 2	<i>Enhanced Vegetation Index 2</i>
G20	Grupo dos 20
GARI	<i>Green Atmospherically Resistant Vegetation Index</i>
GEOGLAM	<i>Global Agricultural Monitoring</i>
GeoSafras	Geotecnologias aplicadas ao Monitoramento Agrícola
GNSS	<i>Global Navigation Satellite System</i>
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
ICMS	Imposto sobre Circulação de Mercadorias e Serviços
IDH	Índice de Desenvolvimento Humano
INPE	Instituto Nacional de Pesquisas Espaciais
IPT	Instituto de Pesquisas Tecnológicas
IV	Índice de Vegetação
MLG	Modelo Linear Generalizado
MLGM	Modelo Linear Generalizado Misto
LAI	<i>Leaf Area Index</i>
MoBARS	<i>Monitoring Brazil Agriculture by Remote Sensing</i>
MSAVI	<i>Modified Soil Adjusted Vegetation Index</i>
NAVI	<i>Normalized Area Vegetation Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
NIR	<i>Near Infrared</i>
PREVS	Previsão de Safras

PVI	<i>Perpendicular Vegetation Index</i>
RED	Reflectância no vermelho
REM	Radiação Eletromagnética
SAVI	<i>Soil Adjusted Vegetation Index</i>
SIG	Sistema de Informação Geográfica
SR	Sensoriamento Remoto
SR	<i>Simple Ratio</i>
RVI	<i>Ratio Vegetation Index</i>
TSAVI	<i>Transformed Soil Adjusted Vegetation Index</i>
SWIR	<i>Short-wave Infrared</i>
VCI	<i>Vegetation Condition Index</i>
VIF	Fator de inflação da variância
WDVI	<i>Weighted Difference Vegetation Index</i>

SUMÁRIO

1	INTRODUÇÃO.....	23
2	REVISÃO DE LITERATURA.....	25
2.1	Sensoriamento remoto agrícola.....	25
2.2	Monitoramento agrícola via sensoriamento remoto.....	31
2.3	Previsão de safras agrícolas.....	34
2.4	Programas de previsão de safras agrícolas.....	36
2.5	Relação entre variáveis espectrais e produtividade.....	39
2.6	Sensoriamento remoto na estimativa de produtividade de culturas agrícolas.....	40
2.7	Satélite Sentinel 2.....	42
2.8	Índices de vegetação.....	43
2.8.1	EVI 2 (<i>Enhanced Vegetation Index - 2</i>).....	44
2.8.2	GARI (<i>Green Atmospherically Resistant Vegetation Index</i>).....	44
2.8.3	GNDVI (<i>Green Normalized Difference Vegetation Index</i>).....	45
2.8.4	GSAVI (<i>Green Soil-Adjusted Vegetation Index</i>).....	46
2.8.5	NAVI (<i>Normalized Area Vegetation Index</i>).....	46
2.8.6	NDRE (<i>Normalized Difference Red Edge</i>).....	47
2.8.7	NDVI (<i>Normalized Difference Vegetation Index</i>).....	48
2.8.8	NDWI (<i>Normalized Difference Water Index</i>).....	49
2.8.9	OSAVI (<i>Optimized Soil Adjusted Vegetation Index</i>).....	49
2.8.10	RVI (<i>Ratio Vegetation Index</i>).....	50
2.8.11	SAVI (<i>Soil Ajusted Vegetation Index</i>).....	51
3	MATERIAL E MÉTODOS.....	52
3.1	Área de estudo.....	52
3.1.1	Clima.....	52
3.1.2	Formação geológica e geomorfológica.....	52
3.2	Material.....	54
3.2.1	Dados de campo.....	54
3.2.2	Imagens orbitais.....	55
3.2.3	Índices de vegetação.....	55
3.2.4	Programas para processamento de dados.....	57

3.3	Métodos.....	57
3.3.1	Correlação dos dados.....	58
3.3.1.1	Modelo de regressão linear.....	58
3.3.1.2	Modelo de regressão linear múltipla.....	61
3.3.1.3	Análise de componentes principais.....	62
3.3.1.4	Análise para dados longitudinais (medidas repetidas).....	64
4	RESULTADOS E DISCUSSÃO.....	67
4.1	Análise descritiva dos dados.....	67
4.2	Teste de normalidade e correlações das variáveis.....	72
4.3	Modelagem estatística – Modelo generalizado linear misto.....	83
4.4	Modelagem estatística – Componentes principais.....	87
4.5	Análise do desempenho dos índices.....	91
4.6	Estimativas de produtividade com o modelo final.....	93
5	CONCLUSÕES.....	100
	REFERÊNCIAS.....	101
	APÊNDICES.....	115

1 INTRODUÇÃO

O planejamento da produção agrícola necessita saber o que, quanto, quando e aonde será produzido determinada cultura, essas questões vão além apenas de mercado, mas também envolvem outros setores como a economia e a segurança alimentar do país. Dessa forma, há uma crescente procura envolvendo estudos e técnicas relacionadas a previsão de safras agrícolas.

Para a obtenção das estimativas ou estatísticas agrícolas é preciso um processo de reconhecimento dos cultivos existentes na região ou município de interesse, processo de avaliação dos parâmetros estudados das culturas e valores de áreas cultivadas.

Um dos conhecimentos mais relevantes do âmbito da produção agrícola está relacionado com a produtividade por unidade de área, que associado ao conhecimento da área plantada, auxilia na informação da produção total. Sendo assim, obtendo-se informações da produtividade é possível antever se a atividade terá lucros ou prejuízos.

O Brasil ainda não dispõe de um sistema estável que expresse com precisão estatística as áreas das principais culturas agrícolas plantadas no país e em tempo quase real. Os órgãos competentes em executar as estatísticas agrícolas nacionais são o Instituto Brasileiro de Geografia e Estatística (IBGE) e a Companhia Nacional de Abastecimento (CONAB), no entanto esse levantamento é de caráter subjetivo, já que a previsão e acompanhamento das safras são realizadas por meio de entrevistas com pessoas relacionadas ao meio agrícola.

No início da década de 70, com a chegada das imagens orbitais do satélite Landsat ao país, o Instituto de Pesquisas Espaciais (INPE), utilizou essa tecnologia para as pesquisas sobre estimativas agrícolas, surgindo alguns programas relacionados a mesma temática. No entanto, algumas iniciativas estão sendo tomadas pelo programa *Monitoring of Brazilian Agriculture by Remote Sensing (MoBARS)*.

Pesquisas envolvendo metodologias para torna-se operacional as previsões de safras no país, firmada pelas técnicas de sensoriamento remoto e amostragem de áreas em campo se mostram necessárias ao obter estimativas agrícolas objetivas, com conhecimento sobre o erro das mesmas, e do mesmo modo, para pôr em prática anos de trabalho e estudos, justificando os investimentos que foram e são feitos na área.

A agricultura no país é expressa em escala estadual, o que se torna um impedimento em adquirir dados confiáveis de safras em uma determinada região ou município. O que acaba dificultando as políticas de desenvolvimento regional, de crédito e custeio, prejudicando na alocação de indústrias, silos e armazéns, o que acarreta em prejuízos no progresso do agronegócio municipal e regional.

No âmbito municipal também é importante quantificar a produção agrícola para poder realizar o cálculo Imposto sobre Operações relativas à Circulação de Mercadorias e sobre Prestações de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação (ICMS) e assim ter a possibilidade de quantificar as indenizações federais causadas por danos climáticos que tenham impactado significativamente a produção agrícola.

Com a dinâmica espaço-temporal das atividades agrícolas é difícil obter dados atualizados e confiáveis sobre a produção das safras. Mas com o auxílio das ferramentas do geoprocessamento, que engloba o Sistema de Informações Geográficas (SIGs), Sensoriamento Remoto (SR) e o Sistema Global de Navegação por Satélite (GNSS) é possível alcançar de uma forma mais rápida essas informações e com mais segurança nos dados.

A necessidade de informar os dados agrícolas por meio de imagens orbitais, para os cultivos agrícolas que disponham de precisão probabilística associada às estimativas obtidas em campo, em escala temporal o mais próximo do que ocorre no campo, faz com que este trabalho seja útil como levantamento de produção de safras.

Sendo assim, objetiva-se com essa pesquisa estimar a produção da cultura da soja, por meio de imagens orbitais e técnicas de sensoriamento remoto, tendo como base áreas no município de Itaberá-SP.

Como objetivos específicos, pretende-se:

- a) Fazer uma análise multitemporal baseada em imagens orbitais para levantar o perfil espectro-temporal da cultura;
- b) Calcular os valores de diversos índices de vegetação (IVs) para a produção da cultura;
- c) Estabelecer a correlação linear dos índices de vegetação com os dados de produtividade da cultura coletados em campo;
- d) Avaliar qual dos índices estudados respondem melhor com os dados de produtividade;

2 REVISÃO DE LITERATURA

2.1 Sensoriamento remoto agrícola

No âmbito da agricultura, o sensoriamento remoto vem apresentando uma tecnologia de grande capacidade para o monitoramento das culturas, como para estimativas de fatores biofísicos utilizados em modelos agrometeorológicos e para vários outros usos. O sistema de sensoriamento remoto é integrado por uma fonte de radiação eletromagnética (REM), conjunto plataforma/sensor e os objetos sensoriados. Sendo um dos fundamentos básicos, a extração de informações por meio dos produtos alcançados pelos sensores remotos, que em geral, são respaldados nos comportamentos de reflectância de cada alvo em diferentes regiões do espectro eletromagnético (FORMAGGIO; SANCHES, 2017).

As atividades de mapeamento amplo de algumas categorias essenciais da cobertura vegetal brasileira começaram por volta da década de 1980. Esses mapeamentos incluíam culturas agrícolas com importância econômica, por exemplo, cana-de-açúcar e feijão; inventários florestais atendendo a amostragem equivalente a dimensão da área, onde as imagens de satélite auxiliavam para o reconhecimento de áreas a tornarem-se amostradas em campo e para o dimensionamento de superfícies ocupadas pela cobertura florestal plantada; estimativas de desmatamento bruto na floresta Amazônica e mapeamento dos remanescentes florestais na Mata Atlântica. Essas iniciativas passaram por atualizações e modificações e continuam em desenvolvimento, com os resultados sendo empregues em previsões de safras agrícolas e no estabelecimento de políticas nacionais de preservação ao meio ambiente (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Segundo ainda os mesmos autores, em meados da década de 1990, houve uma evolução nos estudos com base no sensoriamento remoto da vegetação, que até o momento investigavam a identificação e mapeamento de classes de vegetação em cunho quantitativo. E passaram a explorar outros aspectos, agora no domínio qualitativo. Sendo assim, começaram a trabalhar com correlações entre fatores geofísicos do meio ambiente e/ou biofísicos da vegetação, como cálculo de Índice de Área Foliar (IAF) e biomassa, com informações obtidas de imagens orbitais. Para isso, foi essencial o entendimento dos elementos radiométricos intrínsecos aos procedimentos de constituição das imagens. Mas até esse momento, os métodos de

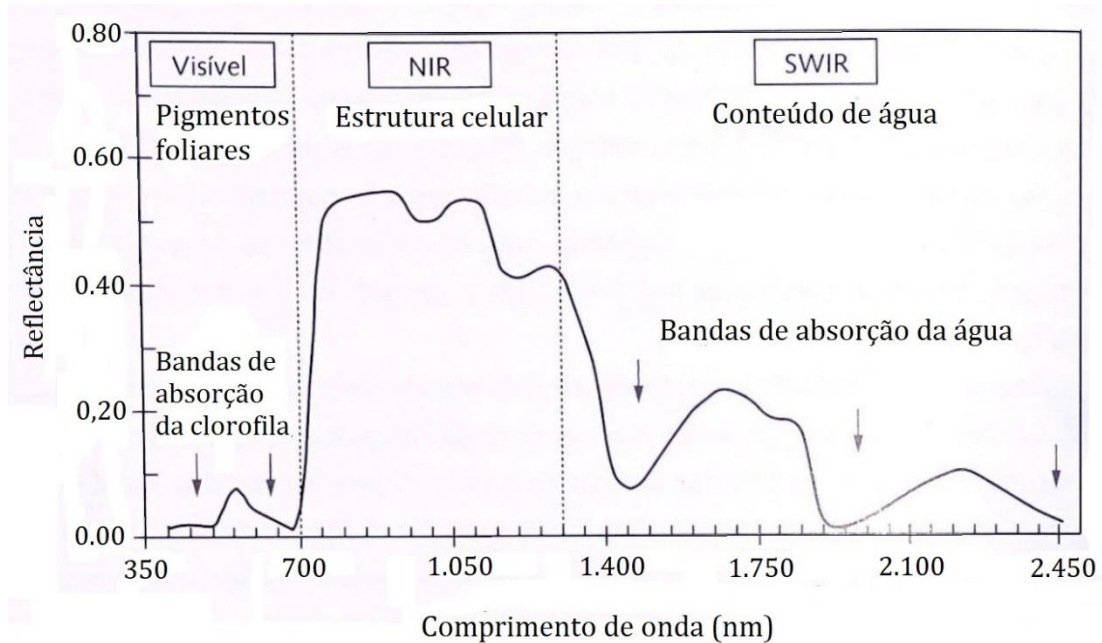
processamento de imagens que se restringiam às classificações automáticas, começaram a descobrir uma gama de diversidade conceitual, originando os modelos lineares de mistura; às normalizações radiométricas, que possibilitam a comparação de informações radiométricas de cenas de mesmo sensor ou de sensores diferentes; modelos de correção atmosférica, além de outros.

O desenvolvimento do sensoriamento remoto foi de suma importância, pois a superfície terrestre é composta aproximadamente por 70% de vegetação. E o conhecimento sobre as diversidades de espécies e das medidas de disseminação dos ecossistemas vegetais e o acompanhamento dos ciclos fenológicos das culturas, das modificações na fisiologia e morfologia das plantas, dão origem as informações relevantes sobre os aspectos climáticos, edáficos, geológicos e fisiográficos de uma região (WEIERS et al., 2004; JACKSON; JENSEN, 2005).

E com a grandeza do território nacional, a quantidade de culturas cultivadas e a rotação dessas culturas durante o ano, são razões que impossibilitam o acompanhamento e monitoramento objetivo das safras agrícolas em grande escala (MATTON et al., 2015; WALDNER et al., 2015). Mas com o advento das imagens de satélite e os métodos do sensoriamento remoto, tornaram-se ferramentas essenciais e sem fronteiras para essas análises serem realizadas (LUIZ, 2003). Sendo consideradas de grande aplicabilidade nas estimativas das safras agrícolas e em diversas regiões geográficas (ATZBERGER, 2013; RUDORF et al., 2010).

É possível obter resultados por meio do sensoriamento remoto, pois toda matéria reflete, absorve, transmite ou emite REM de maneira específica, de acordo com suas propriedades. Tendo como exemplo uma folha vegetal, aos olhos humanos distinguem como verde, que é a clorofila, pigmento interno das folhas, que absorve a REM da faixa espectral do visível nos comprimentos de onda azul e vermelho, no entanto reflete no verde. A região espectral contida entre o visível e o infravermelho de ondas curtas (400nm a 2500nm) é fundamentada em medições remotas da REM refletida pelos objetos da superfície terrestre (Figura 1). Deste modo, os dados coletados pelos sensores precisam ser interpretados baseado na suposição de que diversos objetos retratam diferentes comportamentos espectrais (FORMAGGIO; SANCHES, 2017).

FIGURA 1 - Comportamento espectral da vegetação e os importantes fatores que atuam na reflectância levando em consideração as distintas regiões espectrais do sensoriamento remoto



Nota: NIR (*Near Infrared* – infravermelho próximo), SWIR (*short-wave infrared* - infravermelho de ondas curtas)

Fonte: (FORMAGGIO; SANCHES, 2017).

Há diversos fatores consideráveis para o sensoriamento remoto agrícola, pois as associações entre os atributos morfológicos e físicos de um dossel agrícola são dinâmicos e não satisfazem de maneira única a uma assinatura espectral imutável (FORMAGGIO; EPIPHANO, 1990). Por isso, uma única imagem orbital de determinada data não proporciona dados espectrais suficientes para possibilitar identificar todas as culturas cultivadas em um determinado local. Já imagens multitemporais possibilitam obter mais elementos sobre a área plantada e dados sobre crescimento e desenvolvimento das culturas, que são capazes de vir a ser elementos-chave na diferenciação espectral para várias culturas (APAN; POTGIETER, 2002).

A obtenção de imagens de sensoriamento remoto baseia-se no registro por um sensor das interações dos alvos e a radiação eletromagnética (JENSEN, 2009). No processo de adquirir informações pode ter duas maneiras distintas, fontes de radiação eletromagnética, onde a radiação eletromagnética oriunda do Sol (sensoriamento remoto passivo) ou advinda de fontes artificiais (sensoriamento remoto ativo) (NOVO, 2010). Esta definição é importante pois os estudos de alvos agrícolas é baseado

majoritariamente no uso de imagens de sensoriamento remoto passivo (KNIPLING, 1970).

Para realizar o monitoramento da atividade agrícola de forma eficaz, é necessário acompanhar a safra periodicamente, e as tecnologias do sensoriamento remoto permitem efetivar essa prática de forma altamente qualificada. É indispensável o acompanhamento das safras, pois as plantas demoram um determinado tempo para se desenvolverem completamente e para compreender a dinâmica agrícola da cultura. Desempenhar esse monitoramento por imagens de satélite não é tarefa simples, demanda de muitos fatores para a discriminação das culturas. Por isso, uma análise multitemporal é essencial, associada ao conhecimento do executante e noções e estudos sobre a área cultivada e a cultura, promovendo um excelente resultado na identificação e monitoramento das culturas agrícolas por meio de imagens orbitais (SANCHES; EPIPHANIO; FORMAGGIO, 2005).

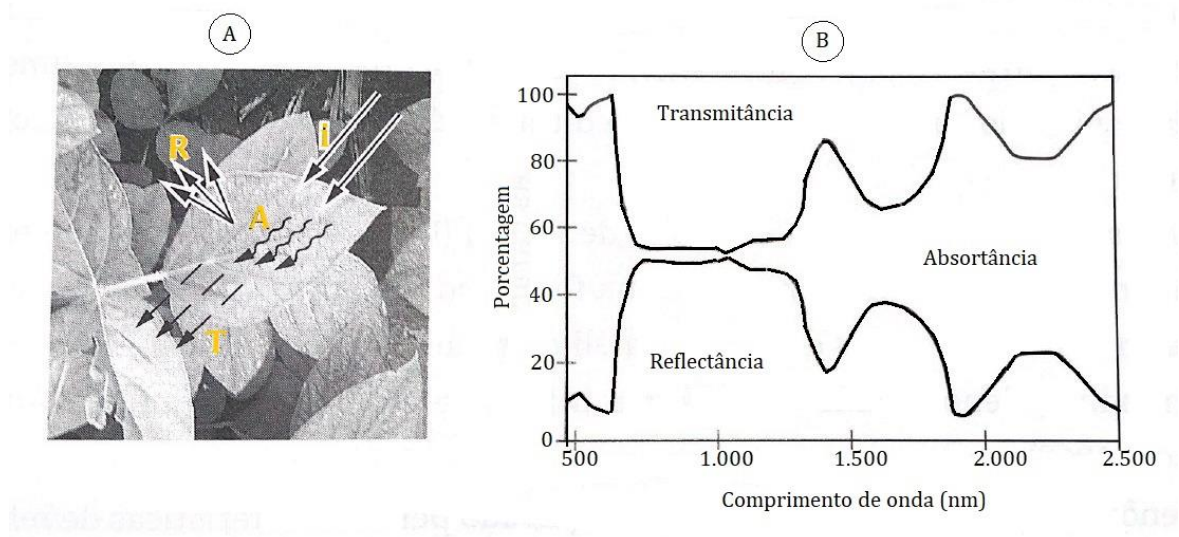
O sensoriamento remoto por meio de imagens orbitais dispõe de sensores e dispositivos para documentar e analisar as relações entre as radiações eletromagnéticas e os elementos que integram a superfície terrestre, como exemplo, as culturas agrícolas (NOVO, 1989). Para que isso seja possível, é fundamental obter informações espectrais das culturas agrícolas em estudo, objetivando o entendimento das influências entre matéria e energia (BARRETO LUIZ et al., 2001).

A apropriada maneira de utilização dos dados oriundos das imagens orbitais está relacionada às características de reflectância e absorção dos alvos da superfície terrestre e pelo comportamento da atmosfera. A atmosfera pode prejudicar as imagens orbitais pelas interações dos distintos comprimentos de onda por espalhamento, refração e absorção da luz. Essas interações ocasionam modificações consideráveis na propagação da radiação procedente de um determinado alvo (SONG; WOODCOCK, 2003).

É evidente que existem variações marcantes de estruturas de folhas entre espécies diferentes e inclusive entre folhas da própria espécie, de quais os indivíduos se desenvolveram em condições ambientais diferenciadas, mas o que é relevante compreender é que a folha em si pode ser considerada como um meio pelo qual a radiação eletromagnética transita, e dependendo do comprimento de onda dessa radiação, determinados integrantes desse meio, bem como outros fatores relacionados à fisiologia da planta, irão exercer interferência no processo de interação referido. Desse modo, quando um objeto recebe uma certa carga de radiação

eletromagnética, ocorrem três acontecimentos que retratam o procedimento da interação em questão, que são: a reflexão, transmissão e absorção (Figura 2). Que são frações espectrais da radiação incidente que serão refletidas, transmitidas e absorvidas, dependendo das especificidades físico-químicas de cada objeto. E com as folhas das plantas, acontece o mesmo processo (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Figura 2 - Condições de interação da energia eletromagnética incidente em uma folha vegetal



Nota: Em A, I representa a energia incidente, R a energia refletida, A a energia absorvida e T a energia transmitida. Em B, são visíveis as curvas de transmitância, reflectância e absortância características das folhas verdes.

Fonte: (FORMAGGIO; SANCHES, 2017).

Quando as culturas agrícolas plantadas com estrutura em fileiras são estudadas há um fator complicativo extra, pois a estrutura em fileiras intervém no modo como transcorre a penetração da radiação por meio do dossel vegetal, e também interfere na quantidade observada de folhas, solo e sombra. Sendo assim, fica evidente que são diversos os fatores consideráveis para a realização do sensoriamento agrícola e que as associações entre as especificidades físicas e morfológicas de um dossel agrícola são ativas, não condizendo a uma forma exclusiva com uma assinatura espectral única, estática e imutável (FORMAGGIO; SANCHES, 2017).

De acordo com os mesmos autores, uma das propriedades agrônômicas de grande importância tem sido o IAF (Índice de Área Foliar), que é um dos indicadores de dosséis mais empregues em pesquisas referentes ao sensoriamento remoto multiespectral de culturas agrícolas. Conforme Loomis e Williams (1969), trata-se do parâmetro com mais qualidade que tem sido utilizado para a mensuração da densidade de cobertura vegetal.

O IAF caracteriza-se em identificar a área foliar existente em campo, equivalente a área foliar presente em relação a superfície ocupada pelas plantas. Pode-se estimar a área ocupada por meio da delimitação da área foliar atual em uma superfície específica do terreno (MAGALHÃES, 1985). Esse índice está relacionado com o potencial do dossel em interceptar a radiação fotossinteticamente ativa, sendo assim, o IAF está relacionado com a fotossíntese realizada pelo dossel e com a grande quantidade de matéria seca em ocasiões em que prevalece o estresse na planta, que são em casos de estresse hídrico, ocorrências de pragas e doenças, entre outros (ASRAR et al, 1984).

A conduta do IAF no decorrer do ciclo de uma cultura anual pode ser classificada como tendência parabólica, onde no início do ciclo é encontrado valores baixos, mais tarde atinge um pico e adiante valores baixos mais uma vez. Naturalmente, alguns fatores durante o ciclo completo da cultura influenciam no crescimento e desenvolvimento das culturas, como data de plantio, cultivares, densidade de plantio, espaçamento, precipitação, pragas e doenças, adubação, entre outros, e o IAF consegue evidenciar essas intervenções, o que o torna um dos principais indicadores para o vigor vegetativo das plantas agrícolas (FORMAGGIO; SANCHES, 2017).

Os mesmos autores corroboram afirmando que as mais relevantes utilidades de dados de sensoriamento remoto na agricultura são referentes ao monitoramento das safras e a estimativa de parâmetros biofísicos das culturas agrícolas. Sendo assim, os índices de vegetação exercem um papel essencial para caracterizar a dinâmica temporal e o vigor vegetativo das culturas agrícolas. Os índices de vegetação são estabelecidos como equações matemáticas elaborados por meio de informações espectrais alcançados por sensores remotos, acima de tudo por meio das bandas do *RED* (Reflectância no vermelho) e do *NIR* (Infravermelho próximo) e podem ser de grande utilidade para a estimativa de variáveis biofísicas, como a porcentagem de cobertura verde sobre o solo, a fitomassa, o IAF, o conteúdo de água e de

componentes bioquímicos, a produtividade, e a fração da radiação fotossinteticamente ativa, entre outras características biofísicas.

Segundo Liu (2015), os IVs (Índices de Vegetação) foram desenvolvidos para conseguir quantificar e monitorar as condições e distribuições espaciais e temporais das vegetações, aplicando as informações digitais de reflectâncias espectrais da radiação eletromagnética. Num primeiro momento a finalidade é empregar esses índices para concentrar dados espectrais e distinguir o que é vegetação de não vegetação, monitorar o crescimento das culturas, as ocorrências de pragas e doenças, o estresse sofrido pelas secas e geadas e os muitos eventos meteorológicos catastróficos.

Conforme Chen, Tardin e Batista (1986) e Vygodskaia, Gorshkova e Fadeyeva (1989), há dois grandes benefícios em aplicar os IVs para quantificar e caracterizar propriedades biofísicas das culturas agrícolas, sendo elas: a) proporciona uma alta correlação com os parâmetros agrônômicos; b) possibilita a redução dos dados multiespectrais por meio de números, minimizando o efeito das condições de iluminação e visada. Contudo, há IVs que são capazes de serem afetados pelas propriedades de iluminação e visada, pelo substrato abaixo do dossel e arquitetura do dossel, sendo necessário um estudo específico para avaliar qual índice mais apropriado para cada aplicabilidade (TANAJURA; ANTUNES; UBERTI, 2005).

As técnicas de sensoriamento remoto têm-se aperfeiçoado, no âmbito das resoluções temporais, espectrais e espaciais, propiciando um número maior de recursos e ferramentas para o desenvolvimento de informações essenciais para o setor da agricultura, como a estimativa da produtividade, das áreas plantadas e da variabilidade espacial das culturas agrícolas (FORMAGGIO; SANCHES, 2017).

2.2 Monitoramento agrícola via sensoriamento remoto

O monitoramento agrícola visa supervisionar uma espécie cultivada ao decorrer de seu desenvolvimento para analisar seu progresso. E no monitoramento agrícola por meio da técnica de sensoriamento remoto (Figura 3), tem a finalidade de responder quatro questões (FORMAGGIO; SANCHES, 2017).

Figura 3 - Esquema do monitoramento agrícola



Fonte: (FORMAGGIO; SANCHES, 2017).

Na questão “Onde está crescendo?”, busca-se identificar e mapear as áreas cultivadas. “O que está crescendo?”, tem o intuito de identificar a espécie ou cultura cultivada. No “Como está crescendo?”, o objetivo é analisar o desenvolvimento das culturas e realizar uma avaliação qualitativa. No “O quanto está crescendo?” é realizar um diagnóstico quantitativo, estimando a área cultivada e a produtividade das culturas (FORMAGGIO; SANCHES, 2017).

Como apoio ao monitoramento das vegetações agrícolas, tem-se utilizado as imagens orbitais, sendo que as informações contraídas por meio do sensoriamento remoto auxiliam às pesquisas realizadas em campo, assim, diminuindo os trabalhos de campo que são muitas vezes trabalhosos e de custo elevado (FERRAZ et al., 2013).

De todas as questões que o monitoramento agrícola via sensoriamento remoto visa responder, a primeira “onde está crescendo?” é a menos complicada, sendo respondida com a identificação das áreas cultivadas. Geralmente, ao responder essa questão, procura-se obter a resposta da pergunta seguinte que é “o que está crescendo?”, que propõe distinguir quais as culturas estão sendo cultivadas. O mapeamento de diversas classes e culturas agrícolas contando com as informações do sensoriamento remoto é realizado no comportamento espectro-temporal dos alvos, podendo ser realizado por interpretação visual das imagens orbitais ou recorrendo aos classificadores automáticos ou semiautomáticos encontrados nos SIGs (FORMAGGIO; SANCHES, 2017).

O acompanhamento da cobertura vegetal e mudanças nos usos e ocupação das terras, em escalas regional e global, é indispensável para os estudos ambientais, agrícolas e das mudanças climáticas (BAAN; ALKEMADE; KOELLNER, 2013). Essas

mudanças no ambiente ocorrem principalmente pelas atividades antrópicas e outras alterações acontecem devido as causas naturais (JIN et al., 2013).

A identificação de diferentes objetos de interesses acontece, pois, os sensores remotos medem as grandezas físicas de importância. Isso ocorre por meio da radiação eletromagnética e de sua interação com a superfície terrestre e a atmosfera. Cada alvo emite ou reflete a REM de modo específico para qualquer comprimento de onda do espectro eletromagnético (ARANTES, 2014).

A questão “Como está crescendo?”, pretende averiguar qual a situação da cultura, se está crescendo naturalmente ou se está sofrendo qualquer tipo de estresse, seja ele nutricional, fitossanitário ou hídrico. Por meio das imagens orbitais é possível aplicar os índices de vegetação, que auxiliam nessa finalidade, pois os IVs adquiridos de sensores a bordo de satélites servem como indicadores da quantidade de fração da radiação fotossinteticamente ativa que é absorvida pela vegetação (FORMAGGIO; SANCHES, 2017).

No âmbito da agricultura, as especificidades da reflectância em cada faixa do espectro eletromagnético conseguem ser avaliadas por meio de cálculos matemáticos de diversas bandas espectrais. Esses cálculos são realizados principalmente com as faixas do visível e o infravermelho próximo, que possibilitam analisar as atividades da vegetação, e são considerados de índices de vegetação. Por meio dessas aplicações e dos dados de reflectância é possível analisar às características da vegetação, como o índice de área foliar, biomassa e fração radiativa interceptada fotossinteticamente (ATZBERGER, 2013).

A questão “o quanto está crescendo?” procura averiguar a produção agrícola, que compreende obter informações da estimativa de área plantada e da produtividade das espécies agrícolas cultivadas (FORMAGGIO; SANCHES, 2017).

Os principais métodos empregues para o monitoramento agrícola e a estimativa de área plantada com as culturas agrícolas são realizadas utilizando imagens de satélites, sendo o produto final, mapas de produtividade (MCROBERTS, 2011). As ferramentas do sensoriamento remoto auxiliam no monitoramento do desenvolvimento das culturas agrícolas com o auxílio das imagens de satélite, permitindo analisar as condições das culturas cultivadas, em intervalos regulares e inferiores ao período da safra, para garantir dados de alta importância (ATZBERGER, 2013, KOUADIO et al., 2014, SAKAMOTO et al., 2014).

O fornecimento de dados que acontece no período das safras agrícolas, sendo disponibilizados no período ao qual eles pertencem, é denominado como informações “em tempo quase real”. Isso decorre pela utilização das imagens orbitais e a utilização dos métodos de sensoriamento remoto, que possibilita fornecer dados sobre a localização e as áreas cultivadas no decorrer da safra (ATZBERGER, 2013).

Contudo, a maioria dos métodos desenvolvidos para estimar a produtividade das safras agrícolas fornece somente um mapa para cada safra agrícola, normalmente disponibilizado após o começo da colheita ou ao final da safra (EBERHARDT et al, 2015).

2.3 Previsão de safras agrícolas

A realização das estimativas das safras agrícolas de uma determinada cultura, o monitoramento de seu desenvolvimento e sua distribuição no ambiente são fundamentais para a realização de um planejamento estratégico, além de fornecer informações importantes para a elaboração de políticas públicas, auxiliar no abastecimento e segurança alimentar da população nacional e constituição de valores dos mercados interno e externo. No Brasil, há dois órgãos nacionais responsáveis pela previsão de safras, a CONAB e o IBGE, que tem o apoio de outros órgãos estaduais e federais. Os estudos desenvolvidos fundamentam-se em entrevistas e levantamentos subjetivos realizados com pessoas ligadas ao meio agrícola. Mas também contam com o suporte recursos modernos, como as técnicas das geotecnologias, como as imagens orbitais, os SIGs e programas de dados climáticos para a estimativa da produtividade em todas as regiões produtoras do país (MARIN, 2020).

A CONAB tem por finalidade prover dados e cumprir a Política Agrícola, estabelecida pela Lei nº 8.171, de 17 de agosto de 1991, e tem o propósito de executar os acompanhamentos das safras brasileiras de grãos, culturas de inverno e de verão, café e cana-de-açúcar. Mediante essas informações é elaborado os Boletins de Safra Agrícolas disponibilizado no próprio site do órgão, com dados como: estimativa da produção e produtividade, monitoramento agrícola, características das culturas, entre outras. O sistema de coleta dos dados aplica um método específico, com o intuito de certificar a confiabilidade e consistência das informações. Os Boletins de Safra e de Monitoramento Agrícola são elaborados apontando aspectos como: tempestividade,

acessibilidade, continuidade e transparência. O trabalho de monitoramento agrícola referente à safra de grãos é efetuado mensalmente, os de café e cana-de-açúcar tem regularidade quadrimestral (CONAB, 2020).

Ainda conforme a CONAB (2020), as divulgações dos boletins das safras agrícolas contribuem na compreensão dos resultados das safras e tem como propósito originar subsídios para o monitoramento e a formulação das políticas agrícolas e de abastecimento. Esses dados ainda contribuem para a tomada de decisão dos produtores rurais.

O órgão encarregado no país pelos Censos Agropecuários é o Instituto Brasileiro de Geografia e Estatística, elaborado por meio de pesquisas que realizam o acompanhamento do desenvolvimento das safras agrícolas. Levantando diversas informações conforme as inúmeras características de cada cultura cultivada, como: demanda de insumos agrícolas (fertilizantes, sementes, corretivos) juntamente com os produtores rurais e cooperativas agrícolas, levantamento e observações de campo, levantamento de dados sobre a comercialização, destino da produção colhida e outros dados correlacionados (IBGE, 2002).

A previsão de safras agrícolas não é somente realizar o acompanhamento das culturas, mas tem início desde a decisão governamental até a distribuição do produto final no mercado. Levando em conta os estudos científicos, os pesquisadores importam-se mais com as previsões das variações da produção agrícola provocado pelos acontecimentos naturais, como as geadas, secas, excesso de pluviosidade, pragas e doenças, furacões e ventanias. A produção agrícola de alguma cultura é estimada multiplicando-se a área plantada pela produtividade, sendo assim, a estimativa da produção final provém de dois fatores, área planta e produtividade (LIU, 2015).

Para a realização da previsão de safras de grãos, é essencial duas informações, sendo elas, a produtividade do cereal em estudo e a estimativa da área plantada, possibilitando calcular o volume de produção, auxiliando no planejamento das indústrias e processamento da safra. Essas informações contribuem para direcionar as empresas nas tomadas de decisão sobre a industrialização e comercialização das safras, diminuindo os impactos nos preços ou antecipando os futuros ganhos em condições favoráveis (NUNES; LOPES; SOUZA, 2019).

Quando se refere a previsão de safra atribuímos isso a um planejamento agrícola, utilizando ferramentas como as geotecnologias e sensoriamento remoto para

promover resultados por meio da espacialização e previsão de fatores. Essas questões constituem componentes essenciais para a implementação de uma geografia atual e moderna (BARBOSA; REIS; MENDONÇA, 2019).

Deste modo, as técnicas de geoprocessamento e sensoriamento remoto transformam-se em uma ferramenta promissora para estimar as áreas cultivadas, por serem qualificadas por propiciar informações em amplas áreas, possibilitando o monitoramento das culturas com custo mínimo e em tempo hábil. As falhas relacionadas aos resultados apresentados por essas ferramentas podem ser menores se comparados as estimativas respaldada em diversas fontes de dados (BRITO et al., 2019).

2.4 Programas de previsão de safras agrícolas

O Brasil ainda não possui um programa que realize as estimativas de safras agrícolas em tempo real que empregue ferramentas modernas como as imagens de sensores orbitais, de maneira consecutiva e sistemática para as culturas mais relevantes cultivadas no país. Fora isso, os sistemas atuais no país também não possuem mecanismos matemáticos/estatísticos de análise da capacidade da técnica de estimativa de safras (PINO, 2001). E as estimativas de safras oficiais só divulgam essas informações em tempo apropriado em escalas estaduais ou nacionais, o que dificulta a aquisição desses dados em escala municipal e pequenas regiões, podendo haver uma carência de até dois anos entre a concepção dos dados e disponibilização das estatísticas (IBGE, 2004).

Em meados da década de 1970, com o advento das imagens orbitais pioneiras do satélite Landsat disponíveis para o Brasil, os profissionais da área de sensoriamento remoto do Instituto Nacional de Pesquisas Espaciais (INPE) em parceria com outros órgãos nacionais como CONAB e IBGE, iniciaram pesquisas com essa nova tecnologia, com o intuito de monitorar e estimar as áreas agrícolas do país, com a utilização das ferramentas de geotecnologias para o levantamento objetivo de estatísticas agrícolas (SCHULTZ, 2016).

Em 1986, foi criado um importante projeto, nomeado de Pesquisa Objetiva de Previsão de Safras (PREVS) (FIGUEIREDO, 2005; RIZZI, 2005), considerado o primeiro programa brasileiro com uma metodologia operacional embasado na

utilização do sensoriamento remoto para realização das estatísticas agrícolas (EBERHARDT, 2015).

Nesse programa, os examinadores atualizavam as áreas agrícolas em campo, em parcelas elaboradas acerca das imagens e adiante em laboratório, e a ampliação acontecia por estrato (EPIPHANIO et al., 2000). Para obter a área total da cultura de importância no domínio do estudo, era realizado o somatório da área estimada com a cultura nos distintos estratos (ADAMI et al., 2004).

O programa PREVS analisava mais de uma cultura ao mesmo tempo por meio de amostra probabilística, essas culturas eram milho e soja. Mas ao examinar os resultados obtidos, identificaram que o valor de CV% (coeficiente de variação) para o milho foi muito elevado em relação ao da soja. Levando em consideração os resultados encontrados, que apresentaram baixa confiabilidade nos dados produzidos e por algumas dificuldades operacionais, o programa não foi mais utilizado em escala operacional (SCHULTZ, 2016).

Em 2002, aconteceu uma segunda iniciativa em desenvolver um programa que realizasse a estimativa de safras, denominado Geotecnologias Aplicadas ao Monitoramento Agrícola (GeoSafras) (EBERHARDT, 2015).

O projeto tem o propósito de aperfeiçoar os sistemas brasileiros de estimativas das safras agrícolas com o suporte de uma rede multi-institucional. Além disso, faz uso das técnicas das geotecnologias, como as ferramentas do sensoriamento remoto, Sistemas de Informação Geográfica e dos GPS para o monitoramento e mapeamento das culturas agrícolas, aplicação dos modelos agrometeorológicos para a previsão das condições climáticas nos períodos primordiais do desenvolvimento das culturas e de levantamentos de informações de campo como contribuição nas estimativas de área planta e de produtividade (FIGUEIREDO, 2005).

Essas duas primeiras iniciativas a PREVS e o GeoSafras, foram de essencial importância para a criação de um terceiro programa, o *Monitoring of Brazilian Agriculture by Remote Sensing* (MoBARS), pois contribuíram em muito com seus dados remotos e a metodologia de levantamento de estimativa agrícola. Mas, como esses primeiros programas ainda necessitavam de levantamentos de campo para concluir com suas metodologias, acabaram sendo inviabilizados economicamente (ADAMI, 2004; CRUSCO, 2006).

Essa terceira iniciativa, MoBARS, teve início no ano de 2013, e foi considerado um aperfeiçoamento dos demais programas de estatísticas agrícolas desenvolvidos

pelo INPE, sendo que seu principal propósito é diminuir os levantamentos de campo, que foi o que acabou inviabilizando os projetos anteriores, principalmente, o GeoSafras (EBERHARDI, 2015).

Levando em consideração os 30 anos de experiências com os programas anteriores, o projeto MoBARS tem o intuito de estimular a utilização de técnicas mais modernas, como as ferramentas das geotecnologias para o desenvolvimento de estatísticas agrícolas confiáveis, em tempo ágil e com custos reduzidos (SCHULTZ, 2015).

A metodologia do projeto MoBARS foi desenvolvido pelo INPE com a colaboração da *University of Natural Resources and Life Sciences (BOKU)* de Viena-AT, e tem como princípio empregar os Sistemas de Informações Geográficas para monitorar as áreas cultivadas pelas três fundamentais culturas agrícolas brasileiras, cana-de-açúcar, milho e soja. Esses levantamentos foram realizados em três estados, São Paulo, Paraná e Santa Catarina, em intervalos bimensais do ano safra, o que faz que esses dados sejam disponíveis em tempo “quase-real”, utilizando para esse efeito geotecnologias modernas e amostragens estatísticas (SCHULTZ, 2015).

No ano de 2011, foi fundado o programa *Global Agricultural Monitoring (GEOGLAM)*, pelo grupo constituído pelos países mais respeitáveis economicamente no mundo (G20). Esse programa tem como finalidade principal o levantamento e monitoramento dos fatores “área produzida” e “produtividade” das principais culturas agrícolas do mundo. E para atingir o objeto proposto pelo programa, foi definido que utilizariam as ferramentas e métodos mais modernos, que são dados de sensoriamento remoto para auxiliar nos levantamentos das safras agrícolas (BECKER-RESHEF et al., 2010; ATZBERGER, 2013).

A iniciativa do GEOGLAM não é somente disponibilizar os dados das estimativas agrícolas, mas também incentivar um plano de ação contra a volatilidade dos valores das commodities (GEOGLAM, 2020).

Os benefícios das iniciativas praticadas pelo programa GEOGLAM irão garantir índices menores dos passivos ambientais resultantes dos desmatamentos das florestas, domínio da volatilização dos valores de bens de consumo e a melhora no abastecimento dos alimentos (BECKER-RESHEF et al., 2010; ATZBERGER, 2013). Mas para que isso aconteça de maneira significativa, o Brasil e qualquer país membro do G20 efetuará todo o procedimento de previsão de safras, deverá comunicar e

disponibilizar suas informações ao programa em tempo apto, para acelerar as tomadas de decisão essenciais (ATZBERGER, 2013; EBERHARDT, 2015).

Outra iniciativa promovida pelo programa GEOGLAM é o *Crop Monitor*, onde a finalidade é oferecer para o *Agricultural Market Information System* (Amis) uma análise internacional, transparente e multifonte das condições de desenvolvimento das culturas agrícolas e das situações agroclimáticas que sejam capazes de impactar a produção mundial. Essa prática avalia quatro tipos principais de culturas agrícolas, sendo elas: trigo, milho, arroz e soja, e esse monitoramento ocorre nas regiões agrícolas produtoras mais relevantes pertencentes aos países do Amis. Essas análises estão sendo desenvolvidas operacionalmente desde o mês de setembro de 2013 e são disponibilizadas no boletim do Amis *Market Monitor*. Os relatórios abastecem mensalmente resumos das condições dessas culturas agrícolas. Informações de anomalias de NDVI são aplicadas nessas análises. O INPE e a CONAB são parceiros dessa iniciativa (FORMAGGIO; SANCHES, 2017).

2.5 Relação entre variáveis espectrais e produtividade

Como se sabe, para estimar a produção de qualquer cultura agrícola, é necessário conhecer a área colhida e a produtividade alcançada. No país, essas informações são adquiridas por meio de metodologias de caráter subjetivo, baseados em entrevistas de agentes vinculado ao setor agropecuário, como, agricultores, comerciantes, financiadores, entre outros. Esse método é empregue por ser de valor mais baixo e de fácil execução, mas não possibilita realizar uma análise quantitativa dos erros implicados (ADAMI et al., 2010).

Para estimar a produtividade agrícola, é necessário conhecer as características das culturas cultivadas, como o genótipo e fenótipo das plantas, as exigências climáticas e o manejo adequado para a cultura, essas informações são essenciais para aplicação do modelo da produtividade agrícola (DORIGO et al., 2007).

Os modelos de produtividade compreendem dados de abordagem mais simples, sendo os subjetivos, até os mais complexos, que são os modelos que associam as variáveis planta, solo e atmosfera. Os modelos subjetivos não possibilitam obter uma resposta completa das consequências ambientais na produtividade, já os mais complexos, esclarecem as causas e efeitos do ambiente sobre a produtividade. Para estimar corretamente a produtividade por meio desses

modelos, é preciso informações de solos, plantas, clima, data de plantio e o intervalo de tempo de cada estágio de desenvolvimento da cultura (ADAMI et al., 2010).

Outras informações são necessárias para a estimativa da produtividade agrícola, além dos dados meteorológicos e de SR. Como os conhecimentos referentes à tendência tecnológica e ao mercado, apesar de serem importantes, não são incorporados aos modelos agronômicos (SUGAWARA, 2010).

Portanto, os resultados de produtividade podem ser alcançados por meio da combinação dos modelos agrometeorológicos e dos dados obtidos pelas imagens orbitais. Essas combinações podem ser feitas de maneira indireta, utilizando as informações do SR para determinar as variáveis essenciais empregues aos padrões agrometeorológicos (RIZZI, 2005; SUGAWARA, 2010; ROSA, 2007).

2.6 Sensoriamento remoto na estimativa de produtividade de culturas agrícolas

Há fatores que acabam atrapalhando o monitoramento objetivo das culturas em grandes áreas de plantio, que são, a imensa quantidade de culturas cultivadas, a rotação de culturas realizada durante o ano e a extensão territorial (ADAMI et al., 2012; IPPOLITI-RAMILO et al., 2003; MATTON et al., 2015; WALDNER et al., 2015).

Mas as tecnologias do SR, por meio das imagens orbitais, são consideradas as ferramentas mais úteis para suprir essa demanda de informações e capaz de sobrepor todos esses obstáculos (LUIZ, 2003), sendo estimado o uso desses recursos como auxílio nas estimativas agrícolas, em diversas regiões geográficas (ATZBERGER, 2013; GALFORD et al., 2008; MOSLEH et al., 2015; RUDORFF et al., 2010).

Com o passar do tempo as ferramentas de SR foram ganhando mais visibilidade e mais recursos, como a construção de novas plataformas orbitais e sensores, promovendo inúmeros produtos com melhorias significativas no âmbito das resoluções espaciais, espectrais, radiométricas e temporais. O aproveitamento de informações do SR nos padrões de produtividade agrícola pode auxiliar para expandir as previsões em escalas extensas e com as tais melhorias há uma ampliação das aplicabilidades destes dados além do mapeamento do uso e ocupação da terra, com vantagens de se conhecer mais sobre a variabilidade espacial da produtividade (BERNARDES, 2013).

Para executar um monitoramento das atividades agrícolas, sobretudo em países de dimensões como o do Brasil, é essencial um acompanhamento e

monitoramento periódico das culturas agrícolas, pois elas levam um tempo estabelecido para se desenvolver e para compreender a dinâmica agrícola da região estudada, sendo assim, o SR tem um papel fundamental nessa prática, auxiliando de maneira precisa nessas questões (SANCHES; EPIPHANIO; FORMAGGIO, 2005).

A colaboração das ferramentas do sensoriamento remoto nas estimativas da produção agrícola pode acontecer de diversas maneiras, sendo elas:

- i. Na elaboração de mapas para identificação e quantificação de áreas de produção agrícola;
- ii. Ferramentas para caracterizar e mapear propriedades dos solos que possibilitam constituir parâmetros de produtividade;
- iii. Ferramentas para elaborar informações meteorológicas;
- iv. Estimativas de fatores biofísicos das culturas.

Nesse modelo as informações são utilizadas como entrada em modelos de produtividade, mas também há a probabilidade de realizar as correlações entre os dados de produtividade adquiridas em campo com as variáveis espectrais (BALAGHI et al., 2008; REN et al., 2008).

Entretanto, para gerar os mapas para identificar e quantificar as áreas de produção agrícola por meio do SR, são necessários alvos que apresentem diferenças espectrotemporais satisfatórios para a compartimentação dos dados. Também é primordial dois requisitos, sendo eles: 1) imagens orbitais livres de cobertura de nuvens para a área de estudo e 2) capacidade operacional eficiente e tempo suficiente para elaborar todos os mapas durante o desenvolvimento da cultura (EBERHARDT, 2015).

As imagens orbitais com presença da cobertura de nuvens podem tornar-se uma dificuldade, pois pode impossibilitar a utilização dessas imagens por conta da invisibilidade dos alvos terrestres, além disso, podendo impedir de obter as imagens suficientes durante o ciclo da cultura (ASNER, 2001; SUGAWARA et al., 2008), de forma que, inviabiliza a realização de monitoramento e mapeamento em áreas extensas (EBERHARDT et al., 2014).

Muitos trabalhos publicados evidenciam a competência da utilização de imagens orbitais para a realização de estimativas agrícolas, para as principais culturas agrícola do país como a soja (EPIPHANIO et al., 2001; RIZZI; RUDORFF, 2005) e milho (SANCHES; EPIPHANIO; FORMAGGIO, 2005). Mas, apesar da competência das imagens multiespectro-temporais dos satélites Landsat, obter as estimativas

agrícolas em tempo quase real ainda é um desafio à comunidade científica (LOVELAND; DWYER, 2012).

2.7 Satélite Sentinel 2

O satélite Sentinel-2, foi lançado em 23 de junho de 2015, como componente do programa Copernicus da Comissão Europeia, com o intuito de fornecer uma enorme gama de dados e imagens. O satélite é constituído por um sensor multiespectral optoeletrônico com resoluções de 10, 20 e 60m nas faixas espectrais do visível, infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR), contendo 13 faixas espectrais, permitindo captura de diversos estados da vegetação, abrangendo mudanças temporais e minimizando o impacto na qualidade das fotografias atmosféricas (EOS, 2020).

Dentre as características do satélite, encontram-se 13 bandas espectrais, sendo elas, 4 bandas no visível e no infravermelho com resolução de 10m, 6 bandas no “red edge” e no infravermelho de ondas curtas com 20m de resolução e 3 bandas para correções atmosféricas apresentando resolução de 60 m (Quadro 1). Dispõe de resolução radiométrica de 12 bits por *pixel* e uma resolução temporal de 5 dias com a constelação de dois satélites, sendo eles, o Sentinel 2A e 2B. O satélite também possui três níveis de processamento de imagens, sendo dois disponibilizados, que são: imagens L1C, que aplica correções radiométricas e geométricas, incluindo ortorretificação e registro espacial e imagens L2A, que inclui uma classificação de cena e uma correção atmosférica aplicado a produtos de ortoimagem de topo da atmosfera (TOA) e um produto de refletância corrigido do fundo da atmosfera (BOA) de ortoimagem (EOS, 2020).

Quadro 1 - Especificações do satélite Sentinel 2

Resolução	Nº da banda	Nome da Banda	Comprimento de onda central (nanômetro)	Combinações de bandas
10 m	B 02	Blue (Azul)	490	Cor verdadeira RGB 04/03/02 Falsa cor 1 e 2 RGB 08/04/03 e 04/08/03
	B 03	Green (Verde)	560	
	B 04	Red (Vermelho)	665	
	B 08	NIR (Infravermelho próximo)	842	
20 m	B 05	Red Edge 1	705	SWIR 1 RGB 12/11/8A
	B 06	Red Edge 2	740	
	B 07	Red Edge 3	783	
	B 08A	Red Edge 4	865	
	B 11	SWIR 1	1610	
	B 12	SWIR 2	2190	
60 m	B 01	Aerossol	443	—
	B 09	Water Vapor	940	
	B 10	Cirrus	1375	

Fonte: (EOS, 2020).

2.8 Índices de vegetação

Os índices de vegetação são considerados equações matemáticas que foram elaboradas para estimar quantitativamente e qualitativamente a cobertura vegetal, sendo que correlacionam os parâmetros mensuráveis em campo com as assinaturas espectrais (BARBOSA, 2006).

Os Ivs são modificações lineares das bandas espectrais, normalmente realizadas nas faixas do infravermelho próximo e faixas do vermelho (V) do espectro eletromagnético (EPIPHANIO et al., 1996). A aplicação dos modelos matemáticos dos índices são os instrumentos para essas modificações serem realizadas, sendo executadas pelos sistemas de informação geográfica. As imagens de satélites são

formadas por bandas, que são constituídas por pixels, que são modificados pelas equações, destacando características de cada índice (ROSENDO; ROSA, 2005).

Com a aplicação dos IVs é possível detectar o crescimento e vigor da vegetação, sendo empregues para designar inúmeros parâmetros biofísicos, como, biomassa, área foliar, atividade fotossintética, porcentagem de cobertura do solo e produtividade (PONZONI, 2001).

São diversos os índices de vegetação aplicáveis, a seguir estão descritos os que foram utilizados no presente estudo.

2.8.1 EVI 2 (*Enhanced Vegetation Index - 2*)

Esse índice de vegetação foi desenvolvido por Jiang et al. (2008), é obtido utilizando apenas duas bandas, que tem conformidade com o índice EVI de três bandas, isso ocorre pelo motivo dos efeitos atmosféricos serem insignificantes, mantendo a qualidade dos dados (ZHANGYAN et al., 2008).

O EVI 2 é ligeiramente mais predisposto aos ruídos de aerossóis, mas com as técnicas de correções atmosféricas aplicadas as imagens de satélites esse indicativo acaba se tornando insignificante ao longo do tempo. É um índice relacionado à biomassa e que torna mínimo os efeitos do solo e da atmosfera (JIANG et al., 2008).

O EVI2 é calculado conforme a Equação 1 e pode variar de -1 a 1.

$$EVI2 = 2,5 [(NIR - Red)/(NIR + 2,4 Red + 1)] \quad (1)$$

Em que:

NIR= reflectância no infravermelho próximo;

Red= reflectância no vermelho.

2.8.2 GARI (*Green Atmospherically Resistant Vegetation Index*)

Esse índice de vegetação foi desenvolvido por Gitelson, Kaufman e Merzlyak (1996), que também tem o objetivo de diminuir os efeitos atmosféricos. Conforme a Equação 2.

$$GARI = \{NIR - [Green - (Blue - Red)]\} / \{NIR + [Green - (Blue - Red)]\} \quad (2)$$

Em que:

Blue, *Green*, *Red*, NIR= valores dos pixels nas bandas azul, verde, vermelho e infravermelho próximo, respectivamente.

É importante salientar que os tratamentos para adequar as correções atmosféricas possibilitam significativas melhorias nas informações de sensoriamento remoto e são sugeridos para aquisição de resultados mais consideráveis para a utilização de IVs (FORMAGGIO, SANCHES; 2017).

2.8.3 GNDVI (*Green Normalized Difference Vegetation Index*)

Esse índice de vegetação foi proposto por Gitelson et al. (1996), com o objetivo de analisar a taxa das pigmentações fotossinteticamente ativas e as deficiências da vegetação, sendo utilizadas imagens orbitais em áreas com vegetação adulta e vegetação em estado de senescência para determinar esse coeficiente.

É um índice muito utilizado em agricultura por utilizar a banda verde (SHANAHAN et al., 2001). Pois possibilita estimar a biomassa e o estresse das culturas, averiguar a distribuição espacial dos campos de cultivo, mapear as diferenças de vigor entre as plantas e aperfeiçoar o sentido das amostragens e observações em campo. Essas análises possibilitam realizar uma avaliação mais eficaz do potencial da produção da cultura (MACHADO, 2003).

O índice é representado pela Equação 3.

$$GNDVI = \frac{NIR - GREEN}{NIR + GREEN} \quad (3)$$

Em que:

NIR= Reflectância na banda do infravermelho próximo;

Green= Reflectância na banda do verde;

2.8.4 GSAVI (*Green Soil-Adjusted Vegetation Index*)

Esse índice de vegetação foi elaborado por Sripada et al. (2006), no decorrer de um projeto para o processo de um modelo de previsão para a necessidade de nitrogênio na cultura do milho, estando a cultura em seu estágio inicial. Sendo que esse índice foi aplicado para minimizar a influência no espectro de reflectância no dossel da cultura, motivado pela reflectância do solo que se encontra nas entranhas da vegetação, em cenas orbitais adquiridas por satélites.

Conforme Sripada et al. (2006), pesquisas antecedentes que aproveitaram a reflectância dos dosséis da cultura do milho, confirmaram que a banda do verde em associação com a banda do infravermelho próximo apresentou respostas significativas no aspecto da versatilidade dos pigmentos de clorofila, do nível de nitrogênio nas folhas da cultura e da produtividade de grãos, em relação a banda do vermelho com a banda do infravermelho.

O cálculo do GSAVI é realizado por meio da Equação 4.

$$GSAVI = 1,5 \frac{NIR-GREEN}{NIR+GREEN+0,5} \quad (4)$$

Em que:

NIR= Reflectância na banda do infravermelho próximo;

Green= Reflectância na banda do verde;

2.8.5 NAVI (*Normalized Area Vegetation Index*)

Esse índice de vegetação foi desenvolvido por Carmona, Rivas e Fonnegra (2015), conhecido como Índice de Vegetação de Área Normalizada, tem o intuito de estimar o teor de clorofila (Chl) por meio de informações do sensoriamento remoto, utilizando apenas duas bandas do espectro, sendo elas, as bandas do vermelho e infravermelho próximo. Sendo possível estimar o teor de clorofila aproveitando informações de satélite que apresentem resolução espectral média. Conforme Equação 5.

$$NAVI = 1 - \frac{Red}{NIR} \quad (5)$$

Em que:

Red= reflectância na faixa do vermelho;

NIR= reflectância na faixa de infravermelho próximo.

2.8.6 NDRE (*Normalized Difference Red Edge*)

O índice NDRE ou Diferença Normalizada na Banda da Borda Vermelha, é elaborado por meio da combinação de duas frequências diferentes de luz, sendo, uma banda demasiadamente reflexiva no infravermelho próximo (~760 nm) e a outra banda, por meio da divisão das somas nas faixas de grande absorvência de luz vermelha de clorofila (~720 nm), sendo a região de comprimento de onda mais conhecida como “*red edge*” (BERNARDI, 2014).

Um dos maiores benefícios do índice NDRE é a capacidade de mensurar o dossel das plantas, além de ser menos propenso a saturação. Por essa característica, ele acaba fornecendo uma melhor resposta quando se refere as culturas perenes ou de estágio posterior, sendo capaz de manifestar uma resposta melhor na medição de variabilidade se comparado ao índice NDVI (TAIPALE, 2018).

As bandas do “*red edge*” são caracterizadas pelo seu comprimento de onda se tornarem maiores conforme exista uma maior quantidade de clorofila (GATES, et al.; 1965).

O NDRE tem demonstrado resultados interessantes de aplicabilidade, principalmente em plantas que apresentam portes maiores, que possuem dosséis bem estruturados, sendo assim, mais próximos ao estágio da maturidade fisiológica. Sendo que, nessas condições as folhas concentram maiores quantidades de clorofila, oferecendo maiores valores na correlação entre o índice NDRE e o índice de área foliar (TAVAKOLI et al.; 2014).

O índice NDRE é definido segundo Barnes et al. (2000), pela Equação 6.

$$NDRE = \frac{NIR - Red\ Edge}{NIR + Red\ Edge} \quad (6)$$

Em que:

NIR= reflectância na faixa de infravermelho próximo.

Red Edge= energia refletida no intervalo de onda “*red edge*” do espectro eletromagnético.

2.8.7 NDVI (*Normalized Difference Vegetation Index*)

Esse índice de vegetação foi concebido por Rouse et al. (1973), seu cálculo é realizado pela diferença de reflectância entre as faixas NIR (reflectância da faixa do infravermelho próximo) e VIS (reflectância da faixa do visível). Conforme a Equação 7.

Esse índice é um dos mais aplicados e o que é utilizado há mais tempo, devido a sua excelente resposta diante as variações do vigor vegetativo (FORMAGGIO; SANCHES, 2017). Também apresenta características de adquirir informações dos fatores biofísicos das plantas, como as alterações sazonais e interanuais das condições da vegetação, retrata a sensibilidade aos resultados do solo e a saturação nas ocorrências com a quantidade de biomassa (MOREIRA, 2011; PONZONI et al., 2012).

$$\text{NDVI} = (\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red}) \quad (7)$$

Em que:

NIR= reflectância da faixa de infravermelho próximo;

Red= reflectância no vermelho;

Esse índice apresenta valores que variam de -1 a 1, sendo que os resultados negativos retratam nuvens, associado ao valor de zero caracterizam solo exposto ou sem vegetação e os resultados superiores à zero corresponde a vegetação. Os valores mais elevados determinam o grau de verde da superfície que pode ser utilizado para compreender a vegetação mais densa ou vegetação em pleno vigor vegetativo, sendo assim, o grau de verde alcança o valor máximo (LIU, 2015).

2.8.8 NDWI (*Normalized Difference Water Index*)

Esse índice de vegetação foi proposto por Gao (1996), tendo por finalidade o sensoriamento remoto da água líquida presente na vegetação. Sendo assim, esse índice quantifica as moléculas de água líquida presentes nos dosséis vegetais, as quais interagem com a radiação solar incidente. As bandas espectrais utilizadas para aplicar esse índice são menos sensíveis aos efeitos de espalhamento atmosférico do que os comprimentos de onda empregado no NDVI (FORMAGGIO; SANCHES, 2017). O NDWI é calculado conforme a Equação 8.

$$\text{NDWI} = (\text{NIR} - \text{SWIR}) / (\text{NIR} + \text{SWIR}) \quad (8)$$

Em que:

NIR= reflectância da faixa de infravermelho próximo,

SWIR= reflectância da faixa de infravermelho médio.

2.8.9 OSAVI (*Optimized Soil Adjusted Vegetation Index*)

Esse índice de vegetação foi desenvolvido por Rondeaux, Steven e Baret (1996), e tem por finalidade diminuir a interferência do solo na reflectância encontrada na vegetação. É uma modificação do índice de vegetação SAVI, e é apropriado para o acompanhamento das culturas agrícolas.

OSAVI apresenta um benefício em comparação aos outros índices de vegetação vinculado a linha do solo, ele não necessita distinguir a linha do solo, ele pode ser definido sem um conhecimento prévio do tipo de solo da área (STEVEN, 1998).

Os resultados apresentados pelo índice NDVI retratam a sensibilidade e outros princípios que resultam da reflectância do absorvimento da clorofila e do sistema foliar. As reflectâncias apresentadas sensibilizam a banda do vermelho, ocasionando intervenções nas grandezas numéricas expressas pelo NDVI. Essas interferências foram minimizadas por meio de um ajuste realizado por coeficientes proposto no OSAVI, com o coeficiente 0,16 para a diminuição da interferência do solo nos valores de reflectância dos dosséis das culturas. O OSAVI é uma variante simplificada do

índice TSAVI, pois não necessita de informações precedentes da variável solo (RONDEAUX, STEVEN, BARET; 1996).

Esse índice é obtido pela Equação 9.

$$OSAVI = \frac{(1+0,16)(NIR-RED)}{(NIR+RED+0,16)} \quad (9)$$

Em que:

NIR= Reflectância na banda do infravermelho próximo;

Red= Reflectância na banda do vermelho;

2.8.10 RVI (*Ratio Vegetation Index*)

Esse índice de vegetação foi desenvolvido por Pearson e Miller (1972), é alcançado pela simples divisão dos valores adquiridos nas bandas do infravermelho próximo e do vermelho. É um indicativo para o crescimento da cultura e da avaliação da quantidade de biomassa. Mas tem um limitante, as intervenções atmosféricas na radiação durante a passagem na atmosfera, afetam o valor absoluto do índice, o que compromete a interpretação dos resultados. O índice está representado pela Equação 10.

$$RATIO = \frac{NIR}{RED} \quad (10)$$

Em que:

NIR= banda correspondente ao Infravermelho Próximo

Red= banda correspondente ao vermelho.

O resultado da aplicação do índice apresenta a diferença entre as duas bandas utilizadas, a do infravermelho próximo e vermelho, pixels da vegetação com valores altos são determinados por associações da reflectância baixas no vermelho por conta da assimilação da clorofila e altas no infravermelho por causa da composição das folhas. Como o índice é baseado em uma associação, dificuldades

como a luminosidade variável, em decorrência da topografia e condições da iluminação solar são minimizados (EASTMAN, 1998).

2.8.11 SAVI (*Soil Adjusted Vegetation Index*)

Esse índice de vegetação foi originado por Huete (1988), que acrescentou um fator no índice NDVI para integrar o resultado da presença do solo, conservando o valor de NDVI dentro de -1 a 1. É um índice que também emprega a linha do solo para minimizar os efeitos dos solos abaixo da vegetação (FORMAGGIO, SANCHES, 2017).

O SAVI apresenta a característica de tornar mínimo os resultados do solo de fundo no sinal da vegetação ao introduzir uma constante de ajuste do solo na fórmula do NDVI, o fator L. Esse fator se transforma com a particularidade da reflectância do solo (brilho e calor) e também com a densidade da vegetação (ROSENDO, 2005). Calculado de acordo com a Equação 11.

$$SAVI = \frac{(NIR - Red)(1 + L)}{(NIR + Red + L)} \quad (11)$$

Em que:

NIR= Reflectância na banda do infravermelho próximo;

Red= Reflectância na banda do vermelho;

L= o fator de ajuste de brilho do solo na imagem.

O fator L, apresenta três valores distintos para representar as condições da superfície. Sendo L= 0,5 para cobertura média de vegetação, L= 1,0 para a superfície do solo nu ou pouca vegetação e L= 0,25 para a cobertura completa de vegetação (LIU, 2015).

O fator L foi identificado pelo método tentativa e erro, até obter um resultado com iguais IVs para solos claros e solos escuros. É necessário incorporar o termo (1 + L) na fórmula do índice, pois a inclusão desse termo multiplicativo faz com que a amplitude de variação fique entre -1 e 1, para que o índice se reduza ao índice NDVI quando o fator L seja igual a zero (FORMAGGIO; SANCHES, 2017).

3 MATERIAL E MÉTODOS

3.1 Área de estudo

O município de Itaberá encontra-se na região sudeste do estado de São Paulo, a aproximadamente 318 km da capital, a uma latitude 23°51'43" sul e longitude 49°08'14" oeste. O município detém uma área de 108.863,43 ha e uma população total de 17.858 habitantes. A densidade demográfica é de 16,08 hab/km² e apresenta Índice de Desenvolvimento Humano Municipal (IDHM) correspondente a 0,693 (IBGE, 2019). Os dados *in situ* dessa pesquisa foram adquiridos de produtores de grãos do município (Figura 4).

O município se caracteriza por ter um amplo potencial agrícola, sendo um dos grandes produtores das culturas anuais, sendo elas, milho, soja, feijão e trigo, além de ter atividades relacionada a pecuária (IPT, 2006).

3.1.1 Clima

O clima da região, conforme classificação de Köppen, é do tipo Cwa sendo estabelecido como clima subtropical/clima tropical de altitude (CEPAGRI, 2014).

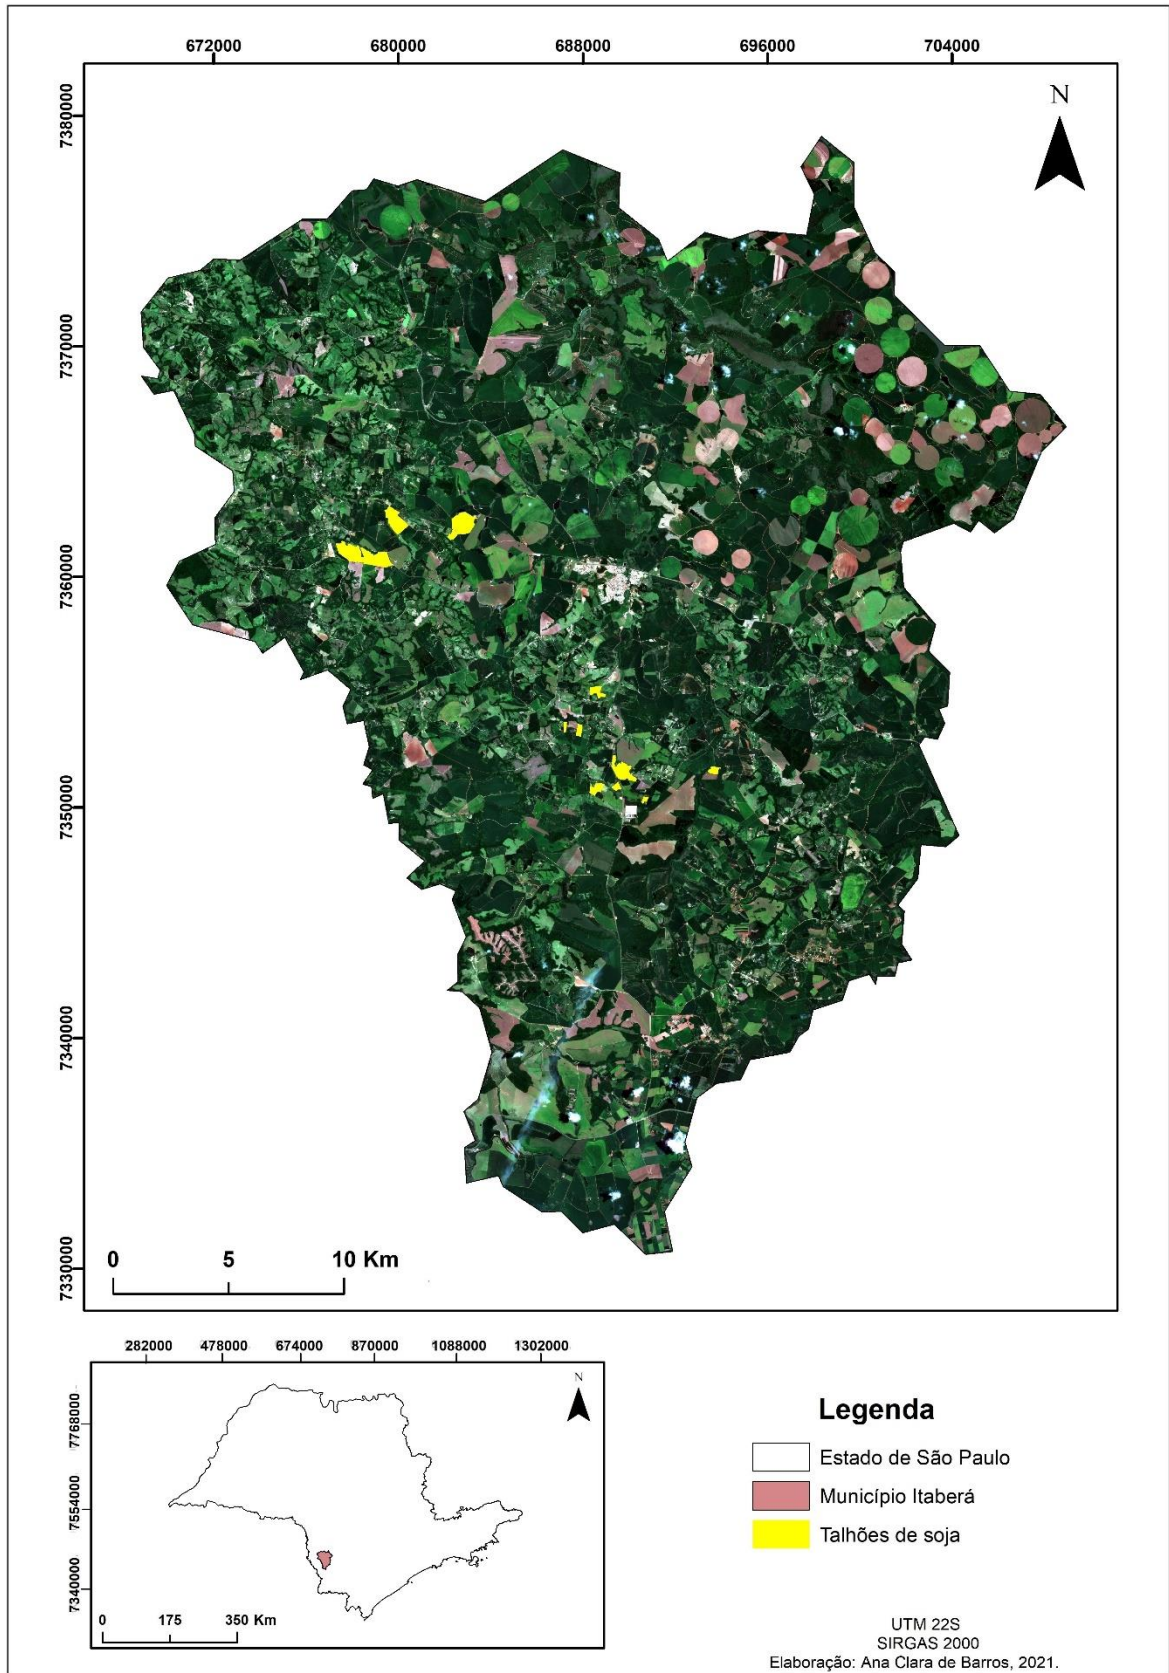
Estimativas das médias trimestrais de temperatura (°C) do município são: inverno (jun-ago): 16,42; outono (mar-mai): 19,93; primavera (set-nov): 20,08 e verão (dez-fev): 22,67. E as estimativas das médias trimestrais de precipitação pluviométrica (mm/mês) são: inverno (jun-ago): 56,36; outono (mar-mai): 80,53; primavera (set-nov): 105,49 e verão (dez-fev): 168,59 (IPEA, 2021).

3.1.2 Formação Geológica e Geomorfológica

O município de Itaberá de acordo com o mapa geológico, está estabelecido no contexto geológico da porção nordeste da Bacia Sedimentar do Paraná, pertencente ao Grupo Itararé, que é composto por arenitos finos a grosseiros, siltíticos, lamitos, diamictitos e ritmitos; cores amarelo, vermelho e cinza (LANDIM, 1984).

E conforme o Mapa Pedológico do Estado de São Paulo, o município, encontra-se localizado regionalmente na Depressão Periférica Paulista, mais especificamente na Depressão Paranapanema (ROSS; MOROZ, 1997).

Figura 4 - Localização das áreas de estudo no município de Itaberá-SP



3.2 Material

3.2.1 Dados de campo

Os dados de campo foram adquiridos por meio de produtores do município em questão. Foram alcançados valores da safra da cultura da soja 2019/2020.

Nos dados contém as seguintes informações, talhões, área (ha), produtividade de cada talhão (sacas/ha), data de plantio e data de colheita, conforme Quadro 2.

Quadro 2 - Dados de campo

Talhões	Área (ha)	Data Plantio	Data Colheita	Produtividade (sacas/ha)
1	9,53	16/10/2019	25/02/2020	64
2	21,64	17-18/10/2019	26/02/2020	66
3	51,53	10-13/10/2019	09/02/2020	70
4	5,28	20/10/2019	14/02/2020	60
5	5,35	18/10/2019	12/02/2020	70
6	13,1	22/10/2019	13/02/2020	75
7	21,56	14-15/10/2019	10/02/2020	85
8	5,67	25/10/2019	15/02/2020	50
9	11,13	16/10/2019	11/02/2020	78
10	136,75	27/09-18/10/2019	25/02/2020	68,18
11	63,33	18-20/10/2019	27/02/2020	75,2
12	11,85	24/10/2019	29/02/2020	66,46
13	74,4	04-07/10/2019	22/02/2020	98,46

Foram analisados apenas 13 talhões, pois foram os talhões que apresentaram as datas de plantio próximas e no mesmo mês de plantio, permitindo uma análise mais adequada, sendo que a cultura foi cultivada na mesma época para todos os talhões.

Lembrando que, quanto maior o número de talhões analisados, melhores os resultados tendem a ser.

3.2.2 Imagens orbitais

Foram utilizadas imagens do satélite Sentinel-2, como dados básicos para aplicação de índices de vegetação. Foram obtidas imagens de todos os meses da produção da cultura da soja (5 meses), para realizar uma análise temporal do desenvolvimento da cultura mês a mês (Quadro 3).

Para obtenção de imagens orbitais esse satélite possui uma alta capacidade de disponibilidade de dados, pois apresenta uma frequência de revisita de 10 dias se considerarmos apenas um satélite e 5 dias para os dois em conjunto, favorecendo a aquisição dessas imagens e possibilitando adquirir imagens sem nuvens. O que se torna de grande importância para análises temporais e monitoramento de culturas agrícolas.

Quadro 3 - Dados das imagens orbitais

Imagem	Data
S2A_MSIL2A	12/10/2019
S2A_MSIL2A	01/11/2019
S2A_MSIL2A	01/12/2019
S2A_MSIL2A	25/01/2020
S2A_MSIL2A	14/02/2019

A correção atmosférica se torna necessária por haver grandes efeitos produzidos pela atmosfera que acabam interferindo nas informações capturadas pelos sensores dos satélites, sendo assim, esse processo auxilia na correção desses efeitos. Nessa pesquisa foram empregadas as imagens do satélite Sentinel L2A, que já possuem as correções de reflectância realizadas.

3.2.3 Índices de vegetação

Foram calculados 11 índices de vegetação (Quadro 4), com o intuito de extrair informações da cultura durante seu ciclo fenológico por meio das imagens de satélite.

Os índices têm a competência de sugerirem a presença e as condições da vegetação monitorada, sendo assim, com a aplicação dos índices é possível obter

diversas características da vegetação, como biomassa, área foliar, vigor vegetativo, entre muitas outras.

Quadro 4 - Índices de vegetação avaliados

Sigla do IVs	Equação	Referência
EVI 2	$EVI\ 2 = 2,5 \left[\frac{(NIR - Red)}{(NIR + 2,4\ Red + 1)} \right]$	Jiang et al. (2008)
GARI	$GARI = \frac{\{NIR - [Green - (Blue - Red)]\}}{\{NIR + [Green - (Blue - Red)]\}}$	Gitelson, Kaufman e Merzlyak (1996)
GNDVI	$GNDVI = \frac{NIR - GREEN}{NIR + GREEN}$	Gitelson et al. (1996)
GSAVI	$GSAVI = 1,5 \frac{NIR - GREEN}{NIR + GREEN + 0,5}$	Sripada et al. (2006)
NAVI	$NAVI = 1 - \frac{Red}{NIR}$	Carmona, Rivas e Fonnegra (2015)
NDRE	$NDRE = \frac{NIR - Red\ Edge}{NIR + Red\ Edge}$	Barnes et al. (2000)
NDVI	$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$	Rouse et al. (1973)
NDWI	$NDWI = \frac{(NIR - SWIR)}{(NIR + SWIR)}$	Gao (1996)
OSAVI	$OSAVI = \frac{(1 + 0,16)(NIR - RED)}{(NIR + RED + 0,16)}$	Rondeaux, Steven e Baret (1996)
RATIO	$RATIO = \frac{NIR}{RED}$	Pearson e Miller (1972)
SAVI	$SAVI = \frac{(NIR - Red)(1 + L)}{(NIR + Red + L)}$	Huete (1988)

3.2.4 Programas para processamento dos dados

Utilizou-se dois programas computacionais da Microsoft Office 2016, o Word para edição de textos e o Excel para edição de planilhas.

O programa de Sistema de Informação Geográfica utilizado foi o ArcGIS 10.5, para o processamento dos dados geográficos, cálculo dos índices de vegetação e elaboração de mapas temáticos.

E para a estatística dos dados foi utilizado o programa *R Language and Environment for Statistical Computing* 3.6.3.

3.3 Métodos

Na Figura 5 está esquematizado as principais etapas e métodos dessa pesquisa.

Figura 5 - Fluxograma das fases metodológicas



3.3.1 Correlação dos dados

Correlação de dados é a analogia entre duas ou mais variáveis, que são representadas por classes numéricas que caracterizam os coeficientes de correlação. Esses coeficientes retratam o nível de associação entre as variáveis estudadas. Sendo assim, é possível obter o valor de uma variável em relação a outra.

A análise de correlação tem por finalidade considerar o nível de associação entre duas ou mais variáveis, por exemplo, X e Y, isto é, avalia o grau de associação linear entre essas variáveis (RODRIGUES, 2012).

3.3.1.1 Modelo de regressão linear

Nas áreas biológicas, em algumas situações, o pesquisador está interessado em estudar a maneira como duas variáveis quantitativas X e Y estão associadas, isto é, medir o grau de associação entre elas. Para isso, uma amostra aleatória é selecionada e as duas variáveis são observadas simultaneamente para cada indivíduo.

As regressões lineares são métodos matemáticos empregues para determinar modelos levando em consideração os valores observados, em relação os valores determinados pelas variáveis independentes, que sejam capazes de estabelecer valores para a variável dependente. Sendo que, as regressões lineares necessitam de duas variáveis para trabalhar, a independente e a dependente, sendo conhecidas como regressão linear simples e quando trabalham com duas ou mais variáveis, são denominadas de regressão linear múltipla (BRAUSS, LYRA, SILVA; 2005).

Uma maneira de descrever os dados conjuntamente é por meio do diagrama de dispersão, que é a representação gráfica dos pares de valores num sistema cartesiano. Se os pontos estiverem localizados na vizinhança de uma reta imaginária, há indicação de correlação. Se X e Y crescem no mesmo sentido, a indicação é no sentido de correlação positiva. Caso a variação aconteça no sentido oposto, existe correlação negativa entre as variáveis. A inspeção visual no diagrama de dispersão mostra, de maneira subjetiva, a associação dos dados e por isso precisa ser quantificada (BUSSAB; MORETTIN, 2012).

A força de uma associação pode ser medida pelo coeficiente de correlação de Pearson (r), que mede a intensidade de associação linear existente entre duas

variáveis quantitativas. Quando se calcula o coeficiente de correlação r em uma amostra, é necessário ter em mente que se está, na realidade, estimando a associação verdadeira entre X e Y existente. Dessa forma, faz necessário a realização de um teste de hipóteses para avaliar a significância do coeficiente de correlação. Entretanto, para realizar o teste de hipóteses, tanto a variável X quanto a variável Y devem ter distribuição normal e a relação entre X e Y deve ser linear. Nas situações em que estas pressuposições não são satisfeitas, indica-se utilizar testes de correlação não paramétricos, dentre eles, teste de correlação de Spearman e o teste de correlação Kendall.

O coeficiente Tau de Kendall avalia a associação com base nos postos (*ranking*) dos dados, em que, as variáveis são colocadas em ordem e numeradas separadamente. O coeficiente toma valores entre -1 e 1 , sendo que a correlação é dita positiva se $\tau > 0$ e indica que os postos de ambas as variáveis estão aumentando (concordância). Por outro lado, a correlação negativa ($\tau < 0$) indica que à medida que a classificação de uma variável aumenta, a classificação da outra variável é diminuir (discordância). Finalmente, $\tau = 0$ indica ausência de correlação (NOETHER, 1983).

Para avaliar a significância do coeficiente de correlação, geralmente testa-se as hipóteses:

$$\begin{cases} H_0: \text{não existe correlação} \\ H_1: \text{existe correlação} \end{cases}$$

O estudo da regressão linear aplica-se àquelas situações em que há razões para supor uma relação de causa-efeito entre duas variáveis quantitativas e se deseja expressar matematicamente essa relação. Normalmente, tem-se interesse em relacionar uma variável, dita resposta, com variáveis independentes ou explicativas (regressão linear múltipla).

Este modelo é designado por modelo de regressão linear simples, expressado pela Equação 12.

$$Y = \alpha + \beta X \tag{12}$$

Em que:

Y : variável dependente

α : coeficiente linear ou intercepto;

β : coeficiente(s) angular(es)

X : variável(is) independente(s)

O principal teste de interesse é verificar se X influencia na resposta, o que é equivalente a testar:

$$\begin{cases} H_0: \beta = 0 \\ H_1: \beta \neq 0 \end{cases}$$

As suposições necessárias para o Modelo de Regressão Linear são:

- i) os resíduos têm distribuição normal com média zero e variância σ^2 (desconhecida);
- ii) os erros são não correlacionados;
- iii) homocedasticidade dos dados.

Em modelos de regressão, além das suposições listadas, é necessário verificar a existência de colinearidade/multicolinearidade entre as variáveis explicativas, pois a relação existente entre elas pode interferir nos resultados, causando inferências errôneas ou pouco confiáveis (ESTATCAMP, 2021).

A colinearidade ocorre quando duas ou mais variáveis preditoras estão correlacionadas entre si e a multicolinearidade, quando a colinearidade existe entre três ou mais variáveis. Podem ser identificadas por meio do fator de inflação da variância (VIF), que mede o quanto a variância de um coeficiente de regressão é inflada devido à multicolinearidade no modelo.

Menores valores de VIF indicam ausência de multicolinearidade. Um valor VIF entre 5 e 10 indica uma quantidade problemática de colinearidade. E se o VIF for acima de 10, pode-se assumir que os coeficientes de regressão estão mal estimados devido à multicolinearidade (JAMES et al., 2014).

Para lidar com o problema da colinearidade, o pesquisador pode remover do modelo as preditoras altamente correlacionadas, utilizar regressão de Mínimos Quadrados Parciais ou Análise de Componentes Principais.

3.3.1.2 Modelo de regressão linear múltipla

O modelo de regressão linear múltipla é determinado como a relação linear entre a variável dependente (Y) e várias variáveis independentes ($X_1, X_2, X_3...X_n$) (RODRIGUES, 2012).

O modelo da regressão linear múltipla é estabelecido na produtividade de uma determinada cultura em atribuição aos parâmetros que comprometem a produtividade. No contexto estatístico, a produtividade é analisada como uma variável dependente, em que, os parâmetros que afetam à produtividade são denominados de variáveis independentes (LIU, 2015). Sendo assim, a Equação 13, representa o cálculo da regressão linear múltipla.

$$Y = a + X_1 + X_2 + X_3 + \dots X_n \quad (13)$$

Em que:

Y = produtividade prevista;

A = valor da interseção da linha;

$X_1, X_2, X_3... X_n$ = os n parâmetros usados para calcular Y.

Os parâmetros independentes, como X_1, X_2 a X_n , são escolhidos fundamentados nas correlações entre Y e X_1 ; Y e X_2 até a última variável selecionada X_n ,

Alguns autores realizaram estudos relacionando a produtividade de culturas agrícolas e a técnica de regressão múltipla. Em 1996, os pesquisadores Hayes e Decker utilizaram dois índices de vegetação, sendo eles, o NDVI e o VCI para monitorar a cultura do milho, na região do cinturão do milho nos EUA e elaboraram um modelo de previsão de produtividade para a cultura empregando a técnica da regressão múltipla. Em 1997 o estudioso Rasmussen, aplicou a mesma metodologia para averiguar a produtividade da cultura do milheto na África. Em seguida, Liu e Kogan (2002), exibiram um método de regressão múltipla com o intuito de estimar as produtividades da cultura da soja, nos principais estados produtores e no Brasil todo. Os resultados desses trabalhos mostraram que modelos de satélite baseados na técnica de regressão estatística podem ser viáveis. (LIU, 2015).

3.3.1.3 Análise de componentes principais

A Análise de Componentes Principais (ACP) é um método estatístico multivariado introduzido por Karl Pearson em 1901. A metodologia tem como objetivo construir combinações lineares, denominadas componentes principais, com as variáveis originais para reduzir dimensão (reduzir o número de variáveis a serem avaliadas). Desta forma, se o banco de dados possui n variáveis, então é possível obter n componentes principais. Entretanto, somente k ($k < n$) componentes serão interpretados, sendo k definido pela proporção de variância total explicada pelas k primeiras componentes. Além disso, as componentes principais não são correlacionadas e a normalidade dos dados não é um requisito para utilizar a ACP (MINGOTI, 2007).

Essa análise fundamenta-se em reescrever as coordenadas dos fatores em um sistema diferente, mais adequado para realizar as análises dos dados. Essa metodologia possibilita diminuir o número das variáveis a serem analisadas, podendo ser empregue para considerar a relevância das variáveis previamente escolhidas, sendo assim, considerar quais variáveis são mais significativas do ponto de vista estatístico (MOITA NETO; MOITA, 1998).

O método da ACP possui algumas características relevantes, sendo elas: toda componente principal é uma combinação linear das variáveis iniciais e são independentes entre si e com o propósito de acumular o maior número de informações contidas nos dados. Além de diminuir a massa de dados, com o menor prejuízo possível no número de informações (VARELLA, 2008).

Essa análise tem por finalidade principal esclarecer a composição das variâncias e covariâncias de um vetor aleatório, formada de n variáveis aleatórias, por meio da formação de combinações lineares das variáveis iniciais (MINGOTI, 2007). Para os autores Lattin, Carroll e Green (2011), essa análise possibilita que os dados sejam reorganizados permitindo explicar o maior número possível de informações disponíveis. Segundo Timm (2002), a ACP permite esclarecer que os componentes principais são aplicados para encontrar e explicar as dependências que possuem entre as variáveis, e ainda esclarecer as relações existentes entre os indivíduos.

O Quadro 5 apresenta quais são os pressupostos básicos para aplicar a Análise de Componentes Principais conforme a literatura.

Quadro 5 - Pressupostos básicos para empregar a ACP

Pressupostos	Referências
Não existe um número exato para a quantidade de amostras, mas estudos mostraram que quanto maior a quantidade melhor os resultados;	Osborne e Costello (2004)
Os dados da matriz de correlação não podem ser independentes, mas necessitam ser correlacionados;	Mingoti (2007); Field (2009); Lattin, Carroll e Green (2011)
A matriz de correlação e a de covariância não devem ser matriz diagonal, com os dados independentes;	Mingoti (2007)
A matriz de correlação não deve ser identidade (coeficientes de correlação serão zero);	Field (2009)
O teste de normalidade multivariada, que é o teste de esfericidade de Bartlett, deve apresentar o p-valor igual a 0,0000, e com o qui-quadrado calculado superior que o qui-quadrado da tabela de distribuição (valor crítico);	Mingoti (2007); Field (2009)
O determinante da matriz de correlação tem que ser superior a 0,00001;	Field (2009)
Não há pressuposições em relação às variáveis originais;	Ayres (2012)
As variáveis observadas não consistem de alguma estimativa sobre a distribuição de probabilidade;	Mingoti e Silva (1997)
As variáveis podem ou não ser contínuas e distribuídas normalmente;	Jolliffe (2002)
Os desenvolvimentos dos componentes principais não necessitam de uma multivariada normal, mas sim, de uma matriz de correlação ou variância;	Johnson e Wichern (2007)
Os componentes principais reclusos precisam de autovalores (variâncias) > 1 (Regra de Kaiser);	Kaiser (1960), Lattin, Carroll e Green (2011)
Quando a soma das variâncias obtiver porcentagem alta, sendo acima de 80%, é necessário utilizar apenas os primeiros componentes principais;	Manly (2008), Ayres (2012)
As cargas dos componentes principais simbolizam seu poder de esclarecimento da variância (coeficiente de determinação – R ²).	Lattin, Carroll e Green (2011)

Fonte: (SILVA; SILVA; BORGES, 2015).

3.3.1.4 Análise para dados longitudinais (medidas repetidas)

Os estudos envolvendo as análises para dados longitudinais tem por finalidade avaliar as alterações globais e individuais ao longo do tempo, possibilitando que a variável resposta possa ser examinada em unidades amostrais constantemente em relação as outras covariáveis que possam estar interferindo (SINGER, NOBRE, ROCHA; 2018).

Os estudos realizados por meio de análises de dados longitudinais são muito utilizados na prática, sendo empregue por pesquisadores das múltiplas áreas do conhecimento (CESTARI; COSTA; MINHO, 2012). Essa análise é utilizada para denotar medidas realizadas da mesma variável em mais de uma ocasião (CROWDER; HAND; 1990).

As análises realizadas por meio de medidas repetidas operam empregando o método dos modelos mistos, que viabiliza a aplicação de distintos arranjos para a matriz de covariância, tornando possível realizar uma modelagem da verdadeira estrutura da correlação do fator tempo, tornando assim, uma análise mais eficaz (XAVIER, 2000; MALHEIROS, 1999).

Conforme os pesquisadores Singer, Nobre, Rocha (2018), pode-se aplicar a análise das medidas repetidas por meio dos modelos mistos, conforme a Equação 14.

$$Y = \beta X + bZ + \epsilon \quad (14)$$

Em que:

Y : variável dependente

β : vetor de parâmetros de efeitos fixos desconhecidos

b : vetor de parâmetros de efeitos aleatórios desconhecidos

X e Z : matriz de variáveis independentes

ϵ : erros aleatórios.

Ao aplicar modelos lineares mistos o pesquisador assume que a distribuição da variável resposta (Y) segue uma distribuição normal. Caso isto não seja verificado, transformação de variável e modelos lineares generalizados mistos (MLGM) são alternativas muito utilizadas na literatura.

Modelos lineares generalizados (MLG), como resumido por Demétrio (1986), envolvem uma variável resposta univariada, variáveis independentes e uma amostra aleatória de n observações independentes, sendo que i) a variável resposta, componente aleatório do modelo, tem uma distribuição pertencente à família exponencial (normal, gama, normal, binomial, Poisson e binomial negativa); ii) as variáveis independentes entram na forma de uma estrutura linear, constituindo o componente sistemático do modelo; iii) a ligação entre os componentes aleatório e sistemático é feita por meio de uma função adequada, denominada função de ligação.

Os modelos lineares generalizados mistos são uma extensão dos modelos lineares generalizados, acrescido os efeitos aleatórios para acomodar alguma estrutura de covariância intraunidades amostrais. Além disso, permite, como nos MLG, incorporar distribuições não gaussianas (SINGER, NOBRE, ROCHA; 2018).

A teoria desse modelo leva em consideração somente o conhecimento das variáveis com efeito fixo. Sendo uma extensão considerada normal, os modelos que se adequem aos dados alcançados por meio de experimentos em que os níveis foram selecionados de uma população aleatória (COSTA, 2003).

Segundo Singer, Nobre, Rocha (2018), o modelo MLGM pode ser dividido em duas etapas. A primeira consiste em assumir que a distribuição condicional da resposta y_{ij} dados os efeitos aleatórios b_i pertence à família exponencial, podendo ser descrito pela Equação 15.

$$f(y_{ij}|\mathbf{b}_i) = \exp\{\phi[y_{ij}\theta_{ij} - a(\theta_{ij})] + c(y_{ij}, \phi)\}, \quad (15)$$

Em que:

a e c são funções conhecidas

ϕ é o parâmetro de escala.

E na Equação 16, tem-se também que,

$$g(\mu_{ij}) = \eta_{ij} = \mathbf{x}_{ij}^T \boldsymbol{\beta} + \mathbf{z}_{ij}^T \mathbf{b}_i \quad (16)$$

Em que:

g é uma função de ligação conveniente (log, logit, probit etc)
 x_{ij}^T e z_{ij}^T denotam, respectivamente, a j -ésima linha das matrizes de covariáveis X_i e Z_i relacionadas aos efeitos fixos e aleatórios.

Na segunda etapa, usualmente supomos que $\mathbf{b}_i \sim N[0, G(\theta)]$, entretanto, na prática, outras distribuições podem ser levadas em consideração (BRESLOW; CLAYTON, 1993).

Para verificar a adequação do modelo foi realizada análise de resíduos, por meio do gráfico resíduos padrão vs. valores ajustados, gráfico normal de probabilidades referente ao modelo e gráfico de dispersão resíduos vs. valores ajustados.

4 RESULTADOS E DISCUSSÃO

4.1 Análise descritiva dos dados

A análise descritiva dos dados da produtividade da cultura da soja e dos índices de vegetação aplicados em todos os meses do desenvolvimento da cultura permitiu investigar seu comportamento e sua variação. Na Tabela 1, estão apresentados os resultados da média, desvio padrão, 1º quartil, 2º quartil – mediana e 3º quartil da produtividade da soja.

Os quartis representam os valores que dividem os dados analisados em quatro partes iguais. Sendo o segundo quartil (Q2) que também representa a mediana, que corresponde à metade dos valores dos dados. O primeiro quartil (Q1) confere ao valor da metade da primeira parte dos dados e o terceiro quartil (Q3) equivale ao valor da metade da segunda parte do grupo de dados (FERNANDES; PINTO, 2013).

O desvio padrão de um grupo de dados, da ordem quantitativo, é um modelo que expõe o grau de dispersão de um conjunto de dados, ou seja, indica o quanto o conjunto de dados é uniforme. Podendo assumir apenas valores positivos e quanto maior esse valor, maior a dispersão dos dados (MARTINS, 2013).

Tabela 1 - Medidas resumo da produtividade da cultura de soja segundo cada mês

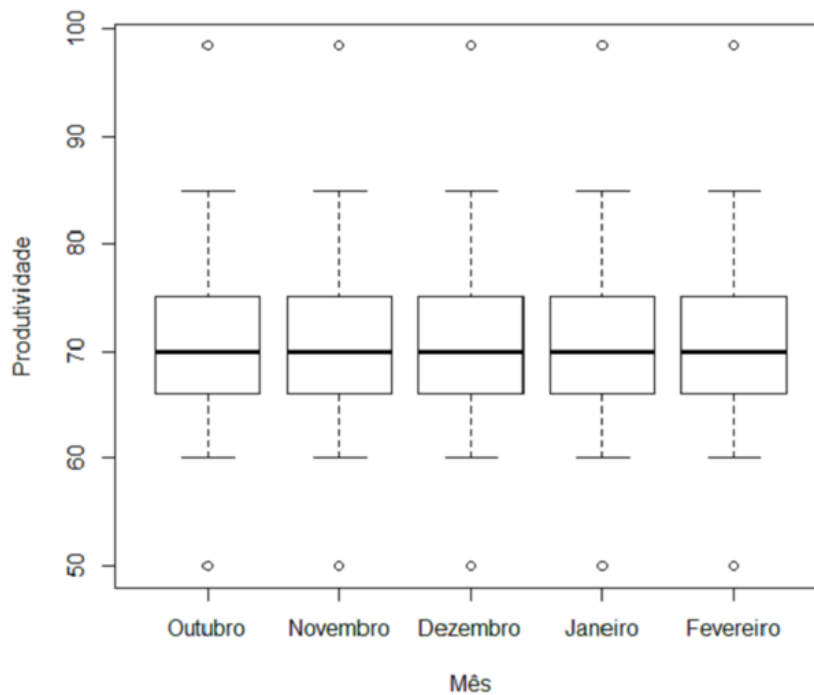
Mês	Média	DP	Q1	Q2	Q3
Geral	71,25	11,52	66,00	70,00	75,20
Outubro	71,25	11,90	66,00	70,00	75,20
Novembro	71,25	11,90	66,00	70,00	75,20
Dezembro	71,25	11,90	66,00	70,00	75,20
Janeiro	71,25	11,90	66,00	70,00	75,20
Fevereiro	71,25	11,90	66,00	70,00	75,20

Nota: DP – Desvio padrão, Q1 – quartil 1, Q2 – mediana, Q3 – quartil 3.

O desvio padrão geral teve uma pequena diferença no valor comparado ao resultado dos cinco meses, isso ocorreu por conta do tamanho da amostra, para cada mês são 12 amostras (a produção e mais onze índices de vegetação) e para o geral são 60 amostras (são as 12 amostras vezes os 5 meses).

Conforme podemos averiguar na Tabela 1 e na Figura 6, a produtividade média foi de 71,25 sacas de soja por hectare, levando em consideração a produtividade dos 13 talhões analisados. Esse resultado não muda em relação aos meses observados, por serem dados coletados ao final do ciclo da cultura, não sendo realizado um estudo minucioso para obter resultado mês a mês.

Figura 6 - Diagrama de caixa (*boxplot*) da produção conforme cada mês



Como descrito anteriormente, por ter sido realizado uma média da produção entre todos os talhões e todos os meses do desenvolvimento da cultura, o diagrama de caixa (*boxplot*) apresentou o mesmo resultado para todos os meses, levando em consideração a média da produção agrícola da cultura.

Em relação aos índices de vegetação, na Tabela 2 e Figura 7, estão expostos os resultados da média, desvio padrão, 1º quartil, 2º quartil – mediana e 3º quartil dos dozes índices avaliados.

**Tabela 2 - Medidas resumo para os índices de vegetação da cultura da soja
conforme cada mês**

Índice	Mês	Media	DP	Q1	Q2	Q3	Índice	Mês	Media	DP	Q1	Q2	Q3
EVI 2	Geral	1,06	0,72	0,34	1,01	1,77	GARI	Geral	0,40	0,28	0,12	0,38	0,65
	Outubro	0,32	0,05	0,30	0,32	0,34		Outubro	0,11	0,03	0,10	0,10	0,12
	Novembro	0,32	0,05	0,30	0,32	0,34		Novembro	0,14	0,05	0,11	0,12	0,17
	Dezembro	1,29	0,37	1,06	1,20	1,62		Dezembro	0,52	0,14	0,42	0,49	0,63
	Janeiro	2,07	0,20	2,05	2,16	2,19		Janeiro	0,79	0,09	0,76	0,81	0,84
	Fevereiro	1,24	0,49	1,01	1,19	1,58		Fevereiro	0,46	0,17	0,36	0,44	0,55
GNDVI	Geral	0,55	0,18	0,38	0,53	0,70	GSAVI	Geral	0,81	0,28	0,55	0,79	1,07
	Outubro	0,37	0,02	0,36	0,37	0,38		Outubro	0,56	0,03	0,54	0,55	0,57
	Novembro	0,37	0,05	0,35	0,38	0,40		Novembro	0,49	0,07	0,46	0,49	0,52
	Dezembro	0,61	0,09	0,56	0,59	0,69		Dezembro	0,93	0,16	0,83	0,90	1,07
	Janeiro	0,81	0,06	0,77	0,82	0,85		Janeiro	1,21	0,09	1,16	1,23	1,28
	Fevereiro	0,57	0,10	0,52	0,56	0,61		Fevereiro	0,86	0,15	0,79	0,85	0,91
NAVI	Geral	0,62	0,25	0,35	0,69	0,89	NDRE	Geral	0,35	0,24	0,12	0,30	0,54
	Outubro	0,33	0,04	0,32	0,33	0,35		Outubro	0,11	0,02	0,10	0,10	0,12
	Novembro	0,37	0,07	0,32	0,34	0,39		Novembro	0,13	0,04	0,11	0,11	0,15
	Dezembro	0,76	0,11	0,69	0,75	0,85		Dezembro	0,44	0,12	0,36	0,41	0,54
	Janeiro	0,93	0,04	0,93	0,95	0,96		Janeiro	0,69	0,10	0,64	0,72	0,77
	Fevereiro	0,73	0,16	0,66	0,74	0,85		Fevereiro	0,36	0,14	0,28	0,35	0,42
NDVI	Geral	0,51	0,28	0,21	0,53	0,80	NDWI	Geral	0,03	0,25	-0,21	-0,01	0,28
	Outubro	0,20	0,03	0,19	0,20	0,21		Outubro	-0,25	0,04	-0,28	-0,24	-0,23
	Novembro	0,23	0,05	0,19	0,21	0,25		Novembro	-0,19	0,05	-0,23	-0,20	-0,17
	Dezembro	0,63	0,14	0,55	0,61	0,75		Dezembro	0,09	0,11	-0,01	0,09	0,17
	Janeiro	0,89	0,06	0,88	0,91	0,92		Janeiro	0,36	0,06	0,35	0,38	0,40
	Fevereiro	0,60	0,19	0,52	0,60	0,74		Fevereiro	0,14	0,19	0,06	0,15	0,32
OSAVI	Geral	0,59	0,33	0,24	0,62	0,93	RATIO	Geral	8,05	9,66	1,61	3,44	9,61
	Outubro	0,23	0,03	0,22	0,23	0,24		Outubro	1,56	0,13	1,47	1,58	1,61
	Novembro	0,26	0,06	0,22	0,24	0,29		Novembro	1,64	0,19	1,50	1,58	1,71
	Dezembro	0,73	0,16	0,63	0,70	0,87		Dezembro	5,89	2,94	3,97	4,50	7,91
	Janeiro	1,03	0,07	1,02	1,06	1,07		Janeiro	25,04	7,40	22,87	25,72	29,41
	Fevereiro	0,70	0,22	0,60	0,70	0,86		Fevereiro	6,10	4,68	3,35	4,45	7,08
SAVI	Geral	0,68	0,32	0,38	0,66	1,00							
	Outubro	0,40	0,05	0,37	0,39	0,42							
	Novembro	0,34	0,08	0,29	0,31	0,37							
	Dezembro	0,79	0,17	0,68	0,76	0,94							
	Janeiro	1,11	0,08	1,10	1,14	1,15							
	Fevereiro	0,75	0,23	0,65	0,75	0,93							

Nota: DP – Desvio padrão, Q1 – quartil 1, Q2 – mediana, Q3 – quartil 3.

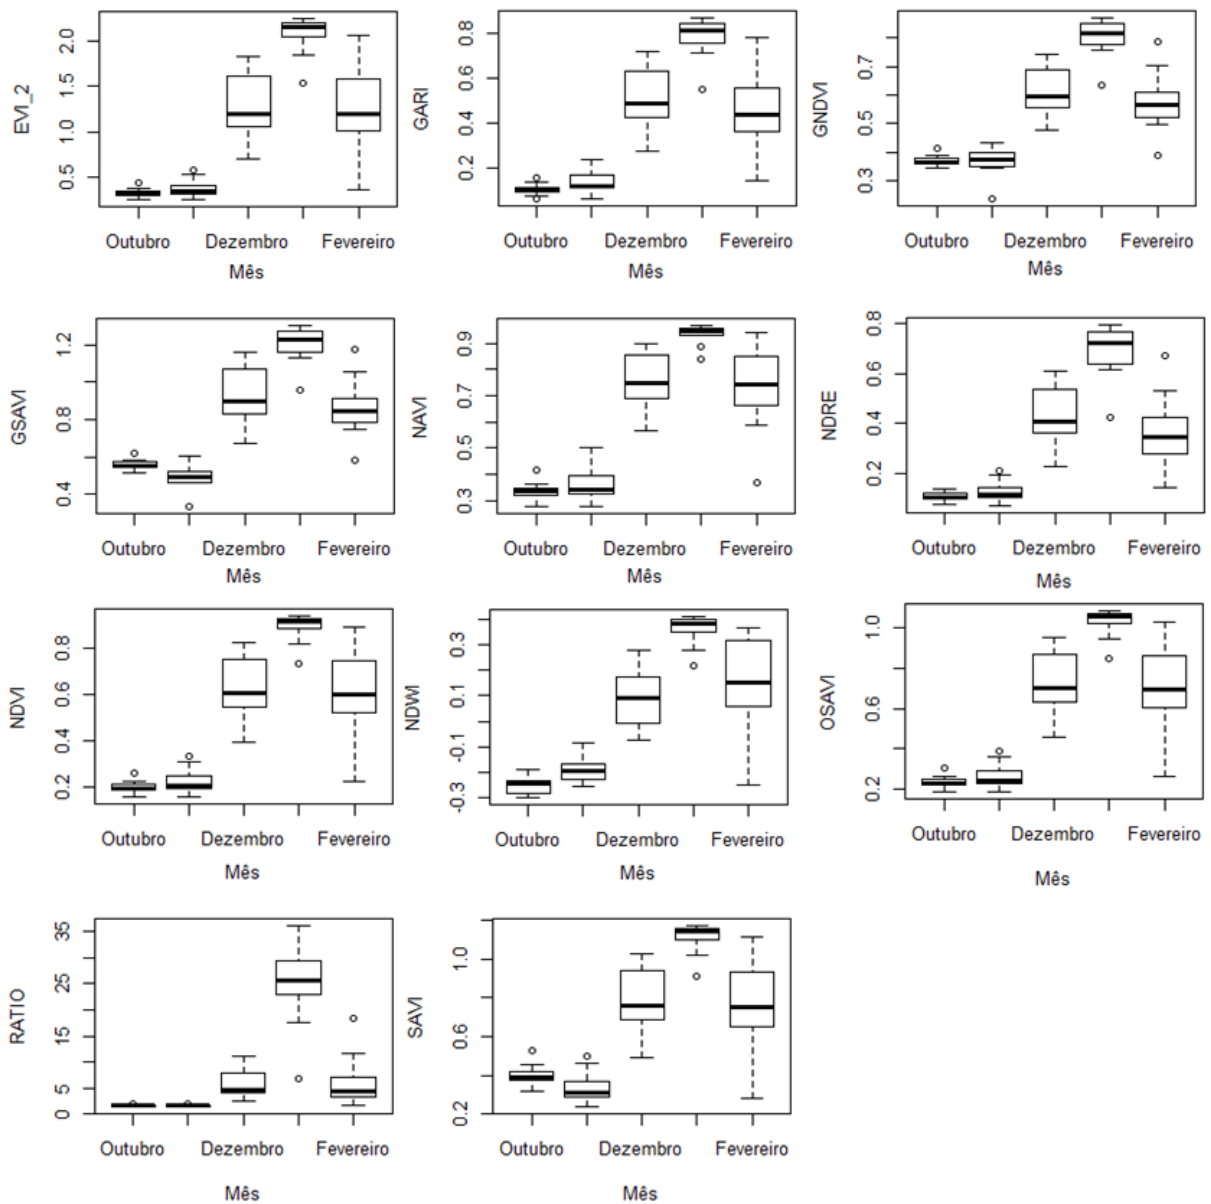
Nota-se que, em relação aos índices de vegetação, de forma geral, o mês de janeiro obteve o maior valor absoluto, isto é, sem considerar o sinal. Isso ocorre conforme esperado, pois durante a fase inicial de desenvolvimento da cultura, os índices de vegetação proporcionam valores menores devido à presença de solo e matéria seca da cultura anterior. Com o desenvolvimento vegetativo da cultura, e conseqüentemente o aumento da área foliar e o recobrimento do espaço entre as fileiras de plantio pelo dossel vegetal, os valores dos índices tendem a aumentar, por haver um aumento nos valores de reflectância das bandas espectrais, sendo esses valores intensificado no mês de janeiro, sendo o mês de máximo desenvolvimento vegetativo.

Segundo Dalmolin et al. (2005), muitos constituintes que formam a superfície do solo, como a matéria orgânica, composição mineralógica, umidade do solo, entre outros, interferem na reflectância do dossel das plantas, e por conseqüência, nos resultados dos índices de vegetação. Esses constituintes da superfície do solo são denominados de “superfície de fundo” (HUETE, 1985). A superfície de fundo, que estão presentes nos plantios em linha quando as culturas ainda não fecharam o dossel vegetal completamente, interfere na resposta espectral dos índices de vegetação (GROFF et al., 2013).

As culturas de ciclo curto, como a soja, segue uma dinâmica fenológica-espectral que pode ser dividida em três fases distintas. Na primeira fase, compreende a fase do plantio das sementes, a germinação e o desenvolvimento inicial, sendo que, nessa fase não há o recobrimento total da superfície do solo, ocorrendo assim o domínio do solo nas interações com a REM. Na segunda fase, já se considera que o dossel vegetal esteja formado, havendo o controle da cobertura verde com as interações com a REM, e partir da metade dessa fase adiante ocorre o florescimento e a formação dos grãos. A última fase é determinada pela maturação e senescência das plantas, representada pelo secamento e quedas das folhas, assim, formando a camada vegetal morta no solo e ocorrendo o domínio da vegetação seca e a de superfície de fundo (FORMAGGIO; SANCHES, 2017).

Na Figura 7 está exposto um diagrama de caixa (*boxplot*) onde se visualiza a dinâmica do desenvolvimento das plantas e as respostas dos índices de vegetação.

Figura 7 - Diagrama de caixa (*boxplot*) dos índices de vegetação conforme cada mês



Na Figura 7 é possível averiguar com clareza o comportamento e a variação do desenvolvimento da cultura e as respostas dos índices de vegetação. Nos dois primeiros meses (outubro e novembro) as respostas foram baixas, por conta de as plantas ainda estarem em fase de desenvolvimento, em dezembro as plantas estavam com o dossel vegetal formado e observamos um aumento das respostas dos índices. No mês de janeiro os índices obtiveram as maiores respostas, levando em consideração que as plantas estavam em seu estado de maior vigor vegetativo e no

mês de fevereiro ocorreu a diminuição nesses valores por conta de iniciar a senescência das plantas.

Do mesmo modo, pode-se observar um comportamento similar dos valores dos índices durante o período de estudo. Além disso, nota-se que, para os meses de dezembro e fevereiro os índices tiveram a maior variação entre eles.

4.2 Teste de normalidade e correlações das variáveis

A análise da normalidade da distribuição de um grupo de dados é essencial para uma apropriada descrição da amostra e uma avaliação assertiva (NORMAN, 2014).

A distribuição normal dos dados é relevante na estatística teórica e na aplicada por muitos motivos e um deles é que diversas variáveis se comportam de forma muitas vezes simétrica, e sendo bem caracterizada por essa distribuição. Avaliar a estimativa da normalidade em um grupo de dados é averiguar o comportamento dos mesmos, analisar qual a forma que a distribuição desses dados assume. Na literatura há diversas metodologias para avaliar e analisar a normalidade univariada dos dados, entre elas, encontra-se a de Shapiro-Wilk (SANTOS; FERREIRA, 2003).

A análise da suposição da normalidade de um grupo de dados é determinada para a execução de vários métodos que possuem influência estatística, sendo, na aplicação da correlação de Pearson, que nesse caso a significância do coeficiente de correlação só é válida se as variáveis aleatórias possuírem distribuição normal; na aplicação dos modelos da regressão linear que um do pressuposto seja que os resíduos do modelo possuam distribuição normal; a suposição de normalidade também é imposta quando pretender adquirir o intervalo de confiança ou realizar o teste de hipótese, fundamentado em estatística t; entre outros (TORMAN; COSTER; RIBOLDI, 2012).

Conforme os mesmos autores, quando os grupos de dados não se apresentarem normais, tem duas opções, a primeira é pesquisar outro modelo de teste paramétrico que se ajuste melhor aos dados e a segunda é fazer uso de testes não paramétricos. Sendo assim, na Tabela 3 está exposto o teste de normalidade, utilizando a metodologia de Shapiro-Wilk.

O teste de normalidade da metodologia Shapiro-Wilk, é um método estatístico aplicado para testar a normalidade dos dados. E apresenta algumas qualidades, como, pode ser aplicado em teste de hipótese composta, é simples de calcular, necessita apenas da tabela de coeficientes lineares, além de ser muito sensível e sendo muito favorável em diversas aplicabilidades, até mesmo em amostras com números reduzidos (SHAPIRO; WILK, 1965).

Tabela 3 - Teste de normalidade para as variáveis quantitativas do estudo

Variáveis	p
Produção	0,001
EVI 2	< 0,001
GARI	< 0,001
GNDVI	< 0,001
GSAVI	< 0,001
NAVI	< 0,001
NDRE	< 0,001
NDVI	< 0,001
NDWI	< 0,001
OSAVI	< 0,001
RATIO	< 0,001
SAVI	< 0,001

Nota: p – valor de p para o teste de normalidade Shapiro-Wilk, $\alpha = 0,05$.

Pode-se analisar na Tabela 3, o teste de normalidade para as variáveis quantitativas utilizando o método de Shapiro-Wilk, comprovou que as variáveis produção e os índices de vegetação não seguem uma distribuição normal. As variáveis apresentaram p-valores inferiores ao nível de significância adotado (5%), ou seja, p-valor < 0,05 em todos os casos, sendo assim, rejeita-se a hipótese de normalidade, significando que os dados não possuem distribuição normal.

Alguns autores realizaram estudos relacionando índices de vegetação e o teste de normalidade Shapiro-Wilk. Moreira et al., (2015), utilizaram o índice NDVI no monitoramento da cana-de-açúcar para realizar uma análise mensal da produção e realizaram o teste de normalidade Shapiro-Wilk, sendo rejeitado a normalidade dos dados e realizando testes não paramétrico. Em 2017 os pesquisadores Bertolin et al.,

realizaram a predição da produtividade do milho irrigado utilizando os índices de vegetação NDVI, NDWI, SAVI e GVI, e os dados foram considerados normais por meio do teste de Shapiro-Wilk. Já Ferreira (2020), avaliou o comportamento espectral da cultura do milho e a produtividade empregando os índices de vegetação SR, NDVI, RVI, GNDVI, CLGreen, SAVI e ICF, e aplicaram o teste de normalidade Shapiro-Wilk.

Como o teste de normalidade aplicado apontou que os dados não possuem distribuição normal, não seria possível aplicar o teste de correlação de Pearson, pois necessita que os dados apresentem distribuição normal. Então, para avaliar a correlação dos dados, utilizou-se o teste não paramétrico de tau de Kendall, e uma outra alternativa seria o teste de correlação de Spearman.

Quando as variáveis não apresentam distribuição normal as alternativas mais empregadas na investigação da correlação entre variáveis são a correlação da ordem de postos de Spearman e o coeficiente de correlação de postos de Kendall (Tau-b), que tem finalidade substituir os dados originais por postos ordenados (NORMAN; STREINER, 2014).

Outro benefício apresentado pelos testes não paramétricos de Spearman e Kendall é que eles não se limitam as correlações lineares, sendo que proporcionem comportamento gradual no mesmo sentido, seja ele ascendente ou descendente, para todos os dados analisados (MIOT, 2018)

O coeficiente de Kendall é um método que possui propriedades matemáticas que o tornam mais robustos a dados extremos, com uma capacidade de inferência populacional maior e menor erro de estimativa. Apesar de possuir a significância (p-valor) e o sentido positivo e negativo se aproximarem do método de Spearman, seu coeficiente apresenta valores menos proeminentes (ARNDT; TURVEY; ANDREASEN, 1999).

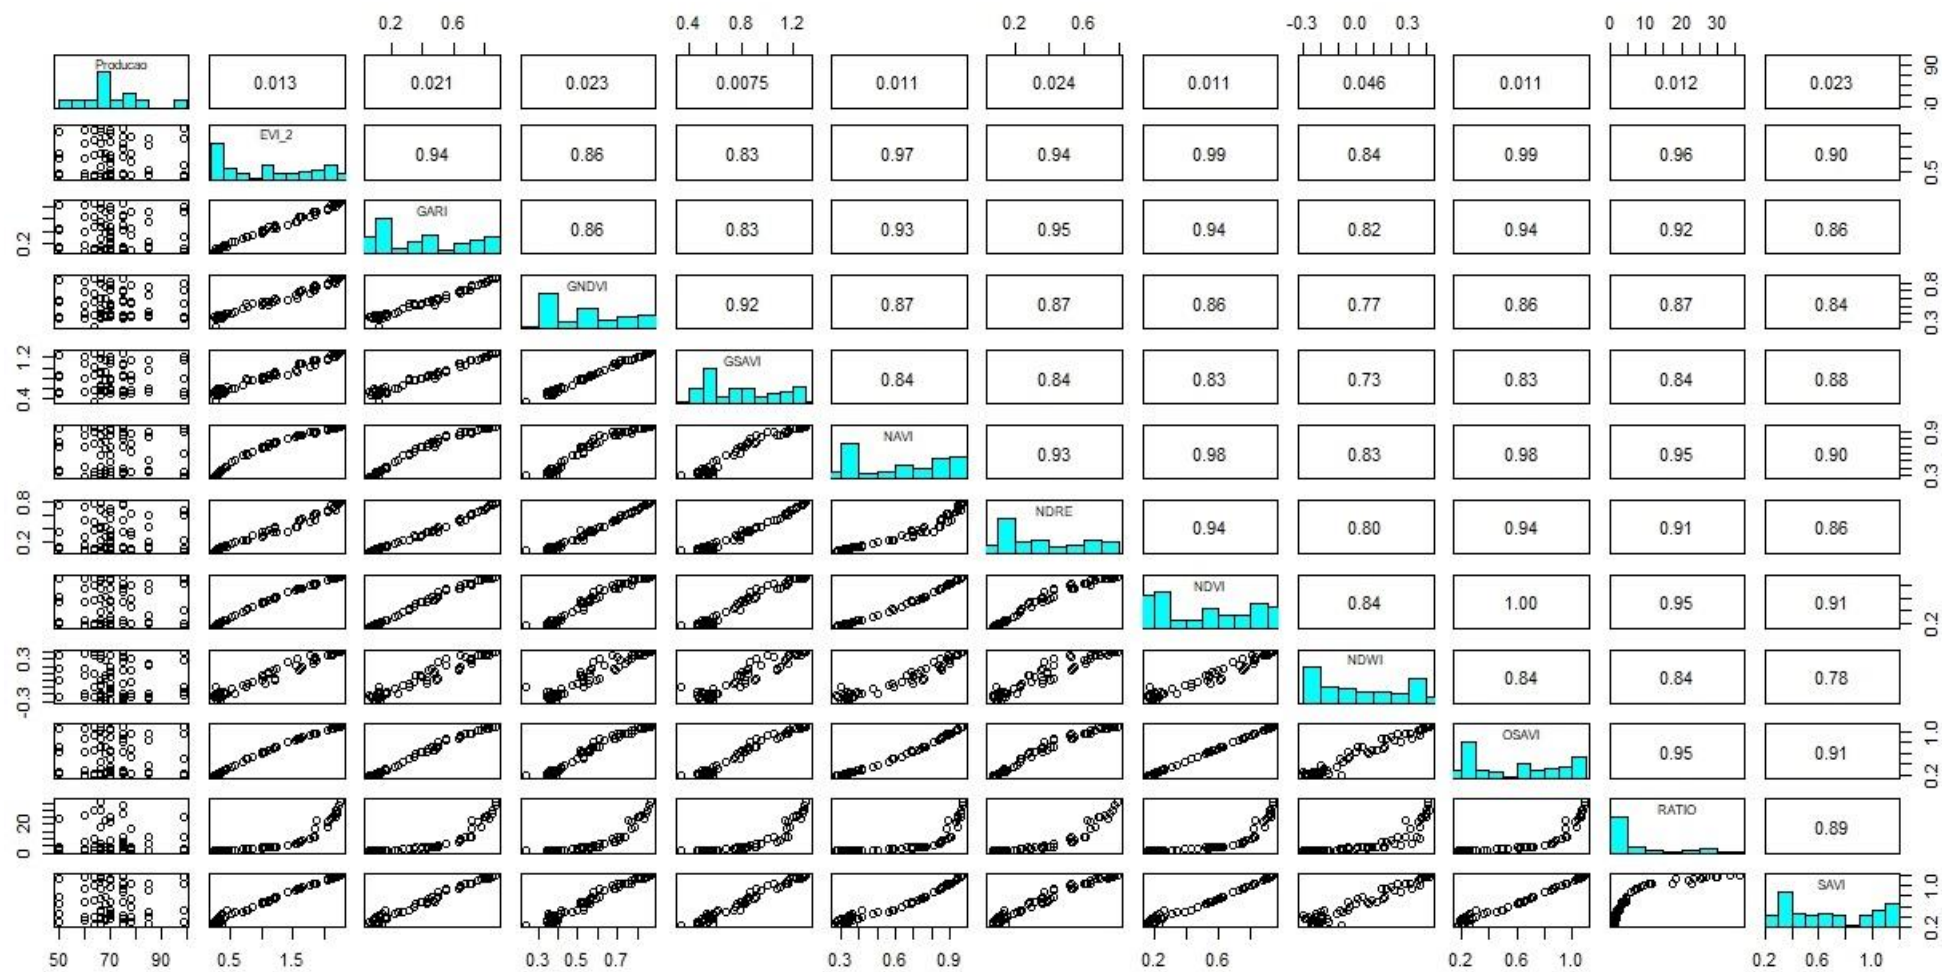
Sendo assim, na Tabela 4 e nas Figuras 8 a 13, estão apresentados a avaliação da correlação de tau de Kendall entre os índices de vegetação e a produção para cada mês da produção agrícola.

Tabela 4 - Avaliação da correlação entre os índices e a produção conforme cada mês

Índice	Mês	Correlação (tau de Kendall)	p	Índice	Mês	Correlação (tau de Kendall)	p
EVI 2	Geral	0,013	0,878	GARI	Geral	0,021	0,807
	Outubro	-0,090	0,669		Outubro	-0,065	0,760
	Novembro	0,168	0,427		Novembro	0,065	0,760
	Dezembro	0,271	0,199		Dezembro	0,271	0,199
	Janeiro	-0,090	0,669		Janeiro	-0,219	0,299
	Fevereiro	-0,245	0,246		Fevereiro	-0,245	0,246
GNDVI	Geral	0,023	0,789	GSAVI	Geral	0,007	0,932
	Outubro	-0,065	0,760		Outubro	-0,065	0,760
	Novembro	0,116	0,582		Novembro	0,116	0,582
	Dezembro	0,219	0,299		Dezembro	0,245	0,246
	Janeiro	-0,271	0,199		Janeiro	-0,271	0,199
	Fevereiro	-0,194	0,359		Fevereiro	-0,194	0,359
NAVI	Geral	0,011	0,896	NDRE	Geral	0,024	0,780
	Outubro	-0,116	0,582		Outubro	-0,194	0,359
	Novembro	0,194	0,359		Novembro	0,168	0,427
	Dezembro	0,297	0,160		Dezembro	0,219	0,299
	Janeiro	-0,142	0,501		Janeiro	-0,271	0,199
	Fevereiro	-0,245	0,246		Fevereiro	-0,271	0,199
NDVI	Geral	0,011	0,896	NDWI	Geral	0,046	0,597
	Outubro	-0,116	0,582		Outubro	-0,142	0,501
	Novembro	0,194	0,359		Novembro	0,065	0,760
	Dezembro	0,245	0,246		Dezembro	0,271	0,199
	Janeiro	-0,090	0,669		Janeiro	-0,219	0,299
	Fevereiro	-0,271	0,199		Fevereiro	-0,323	0,126
OSAVI	Geral	0,011	0,896	RATIO	Geral	0,012	0,887
	Outubro	-0,116	0,582		Outubro	-0,168	0,427
	Novembro	0,194	0,359		Novembro	0,245	0,246
	Dezembro	0,245	0,246		Dezembro	0,348	0,099
	Janeiro	-0,090	0,669		Janeiro	-0,194	0,359
	Fevereiro	-0,271	0,199		Fevereiro	-0,271	0,199
SAVI	Geral	0,023	0,789				
	Outubro	-0,116	0,582				
	Novembro	0,194	0,359				
	Dezembro	0,245	0,246				
	Janeiro	-0,090	0,669				
	Fevereiro	-0,271	0,199				

Nota: p – valor p do teste de correlação de postos de Kendall, $\alpha = 0,05$

Figura 8 - Matriz de correlação das variáveis em estudo



O coeficiente de Tau de Kendall varia seus valores entre -1 e 1 e seu p-valor com nível de significância adotado em 5%, ou seja, valores $< 0,05$.

Avaliando os valores expostos na Tabela 4, que apresentam os coeficientes da correlação de Kendall e o respectivo p-valor para o teste da correlação, entre os índices de vegetação com a produção e para todos os meses do ciclo da cultura, foi possível verificar que o resultado geral da análise é a presença de uma correlação fraca e estatisticamente não significativa, ao nível de significância de 0,05, entre a produtividade da cultura e os índices de vegetação.

Analizando as Figuras 7 a 12, que correspondem as matrizes de correlação e seus diagramas de dispersão, obtendo os mesmos resultados, de que a indicação de correlação é fraca. Nos gráficos de dispersão presente na primeira coluna das matrizes de correlação, que relacionam a produção com os índices, os pontos estão distribuídos aleatoriamente e não dispostos em uma reta crescente ou decrescente, indicando baixa ou ausência de correlação. Além disso, as matrizes de correlação indicam que os índices estão correlacionados entre si, revelando indícios de que pode haver problemas de multicolinearidade no modelo de regressão.

Para realizar uma análise adequada de uma matriz de correlação entre duas variáveis quantitativas é necessário observar o diagrama de dispersão, para reconhecer se há uma variabilidade gradual entre os dados, se essa variação é predominantemente ascendente ou descendente, se atribui uma tendência proporcional (linear) e se a distribuição subjacente dos dados é normal (MIOT, 2018).

Quando na correlação dos dados é diagnosticado multicolinearidade significa que há uma relação linear exata entre algumas ou entre todas as variáveis detalhadas em um modelo de regressão (MIOT, 2018). E para um modelo de regressão ser apropriado, as variáveis não podem evidenciar multicolinearidade (CARVALHO, 2016).

Alguns pesquisadores utilizaram o método de correlação de Kendall para analisar alguns trabalhos. Em 2018, o pesquisador Carmello, estudou a variabilidade pluviométrica e a produção de soja, realizando uma análise comparativa entre regiões produtoras do Brasil, Estados Unidos e Índia e para a verificação das análises estatísticas empregou as correlações de Pearson, Kendall e Spearman. Em 2017, os autores Borges e Baptista, avaliaram a potencialidade dos índices de vegetação SFDVI, NDVI e EVI para testar o potencial de discretização da cobertura do solo em áreas rurais, utilizando a correlação de Kendall para obter as respostas estatísticas.

Em 2017, o autor Lemes, utilizou técnicas de sensoriamento remoto com a aplicação dos índices NDVI e RS para detecção de seringais infestados por nematoides, e executando as correlações de Pearson, Kendall e Spearman para as análises estatísticas.

4.3 Modelagem estatística – Modelo generalizado linear misto

Quando os dados não apresentam uma distribuição normal e não possuem uma função linear, é possível utilizar os modelos lineares generalizados, para conseguir linearizar os dados e obter um formato adequado para a função.

Mas os dados dessa pesquisa são longitudinais, identificado pela repetição de medições de características num mesmo indivíduo ao longo de um período, ou seja, analisando o mesmo índice de vegetação por cinco meses. Nestas situações, utiliza-se modelos lineares mistos. Os modelos lineares de efeito misto são aplicados para caracterizar a relação entre a variável dependente e uma ou diversas covariáveis em dados agrupados, que obtenha um ou mais fatores, sejam, dados longitudinais, medidas repetidas, dados com estruturas hierárquicas e/ou planejamento em blocos (PINHEIRO; BATES, 1995).

Entretanto, como a variável produção não segue uma distribuição normal, logo ajustou-se um modelo generalizado linear misto. Antes do ajuste é reconhecido uma distribuição de probabilidade que se adeque a variável resposta (variável dependente). Nos dados, a produtividade é uma variável contínua e não normal, logo a distribuição Gama pode ser adequada. Sendo que essa análise de distribuição Gama é constantemente empregue em trabalhos que possuem problemas com análises de confiabilidade (CHAGAS, 2018).

Testando as hipóteses, H_0 : a distribuição segue uma Gama vs. H_1 : a distribuição não segue uma Gama, por meio do teste de ajuste para a distribuição Gama, obteve-se p-valor igual a 0,5, ou seja, tem-se indícios de que a produtividade segue uma distribuição Gama.

Para modelagem, assumiu-se que Y_{ij} segue uma distribuição gama de média μ_i e parâmetro de dispersão ϕ^{-1} . A fim de facilitar as interpretações dos resultados, foi proposto um modelo gama com ligação identidade, sendo que a parte sistemática é dada pela Equação 17.

$$\mu_i = \mu + X_{ij}\beta + Z_{ij}b_i \quad (17)$$

Na Tabela 5, estão apresentadas as estimativas para os parâmetros dos efeitos fixos referentes ao modelo gama misto ajustado para os índices de vegetação.

Tabela 5 - Estimativas dos parâmetros de efeitos fixos referentes ao modelo gama misto ajustado para os índices de vegetação

Parâmetro	Estimativa	Erro Padrão	T	valor p
Intercepto	72,780	0,000	1904000,000	< 2e-16
EVI 2	0,000	0,000	5,737	0,000
GARI	0,000	0,000	1,972	0,049
GNDVI	0,000	0,000	-5,285	0,000
GSAVI	0,000	0,000	4,693	0,000
NAVI	0,000	0,000	9,504	< 2e-16
NDRE	0,000	0,000	-3,486	0,000
NDVI	-0,036	0,000	-8156,000	< 2e-16
NDWI	0,000	0,000	0,277	0,782
OSAVI	0,031	0,000	7213,000	< 2e-16
RATIO	0,000	0,000	-0,010	0,992
SAVI	0,000	0,000	-1,861	0,063
Mês: novembro	0,000	0,000	0,125	0,900
Mês: dezembro	0,000	0,000	-0,119	0,905
Mês: janeiro	0,000	0,000	-0,034	0,973
Mês: fevereiro	0,000	0,000	-0,181	0,856

Os resultados expressos na Tabela 5, compõem os resultados do modelo gama misto ajustado com todas as variáveis. As estimativas e seus respectivos desvio padrão e t (estatística do teste) podem indicar problemas na adequabilidade, por isso, antes de seguir com a análise, a multicolinearidade foi avaliada. Além disso, o ajuste apresentou problemas devido aos altos valores de autovalores. Também se verifica na Tabela 6, que o modelo Gama identifica os resíduos com média zero, variância desconhecida e homogeneização dos resíduos. Sendo assim, o ajuste do modelo

Gama, possibilitou que os erros pendessem a uma distribuição aleatória em torno de zero (CARVALHO et al., 2011).

Sendo assim, na Tabela 6, está apresentado o diagnóstico de colinearidade para o modelo ajustado.


Tabela 6 - Diagnóstico de colinearidade para o modelo gama misto completo ajustado

Variável	VIF	Variável	VIF
EVI 2	1,01	NDVI	1,10
GARI	1,09	NDWI	1,06
GNDVI	1,04	OSAVI	1,07
GSAVI	1,08	RATIO	1,00
NAVI	1,07	SAVI	1,08
		Mês	1,02

As informações contidas na Tabela 6 indicam não haver problema de multicolinearidade no modelo gama misto contendo todas as variáveis, pois para análise de parâmetros da colinearidade o valor de VIF indicado é que seja menor que 10 (SANTOS et al., 2020). E como é possível verificar os valores estão bem à baixo, descartando problemas de colinearidade.

Todavia, na Figura 14, temos o gráfico de dispersão de resíduos. Os resíduos são utilizados para analisar o modelo ajustado, se está adequado ou não, conforme a opção empregue, sendo função de variância, função de ligação e de termos do preditor linear. Sendo significativo também na identificação de *outliers* e na verificação da discrepância entre os valores observados e ajustados (CORDEIRO; LIMA NETO, 2006).

Figura 14 - Gráfico de dispersão resíduos vs. valores ajustados – modelo Tabelas 5 e 6



Como é permitido visualizar no gráfico de dispersão, o modelo não ficou bem ajustado, e o gráfico de dispersão dos resíduos é um indicador para análise, pois os pontos deveriam estar aleatoriamente distribuídos e isso não ocorre, eles possuem uma tendência linear e isso demonstra uma dependência linear e heterocedasticidade. Problemas de heterocedasticidade é diagnosticado quando o modelo expõe variâncias para Y e X ($X_1, X_2, X_3, \dots, X_n$) não idênticas para todas as observações e/ou falta de normalidade (CARVALHO, 2019).

O cenário do ajuste se manteve inadequado mesmo fazendo diferentes combinações das variáveis explicativas no modelo. A alternativa para se fazer uma análise inferencial adequada, considerando o estudo longitudinal, é buscar por novas metodologias paramétricas ou não paramétrica.

Uma outra abordagem seria desconsiderar fator de medidas repetidas (tempo) e para cada mês aplicar modelos lineares generalizados (distribuição gama), no entanto, a quantidade de observações é muito pequena ($n = 13$) para estimar a quantidade de parâmetros que podem compor o modelo final. Por outro lado,

considerar todas as observações de todos os meses ($N = 60$) para ajustar o modelo de regressão, também não será adequado pois as observações são dependentes.

Foi realizado um novo modelo (Tabela 7), desprezando a variável mês, que continha no modelo anterior para observar se iria ter alteração.

Tabela 7 - Diagnóstico de colinearidade para o modelo gama (MLG) completo ajustado

Variável	VIF	Variável	VIF
EVI 2	9733,9	NDVI	41538720000,0
GARI	1948,5	NDWI	71,4
GNDVI	313,4	OSAVI	41553340000,0
GSAVI	244,9	RATIO	39,0
NAVI	3381,8	SAVI	135,9

Conforme podemos analisar na Tabela 7, os valores de VIF foram muito altos, lembrando que, o valor tolerável é até 10. Demonstram que todos os índices de vegetação são multicolineares.

Alguns autores também testaram essa metodologia de modelo linear generalizado e distribuição Gama em outras áreas do conhecimento. Em 2016, o autor Salvatierra, aplicando o índice NDVI, informações de precipitação e outras bases de dados, fazendo uso do modelo linear generalizado para averiguar a relação entre o índice de vegetação e a precipitação em áreas de desmatamento e unidades de conservação. Em 2015, os autores Hess et al., utilizaram o método do modelo linear generalizado com distribuição Gama na predição do crescimento em altura da cultura de *Pinus taeda L.* em função da idade e diâmetro.

4.4 Modelagem estatística – Componentes principais

A análise de componentes principais é um método da estatística multivariada que tem como princípio modificar um grupo de variáveis iniciais em outro grupo de variáveis da mesma dimensão nomeadas de componentes principais. Sendo que esses componentes principais possuem algumas características essenciais, como, cada componente principal representa uma combinação linear de todas as variáveis

iniciais existentes, sendo independentes entre si e com o intuito de preservar o maior número de informação possível. Considerada uma técnica que diminui a massa de dados, com o menor prejuízo de informações e agrupa os indivíduos conforme as variações se suas características (VARELLA, 2008).

A metodologia tem alguns benefícios ao ser aplicada, como eliminar a multicolinearidade das variáveis, possibilitando a alteração de um grupo de variáveis iniciais intercorrelacionadas, em um novo grupo de variáveis não correlacionadas (HONGYU, 2015).

Portanto, a seguinte análise terá como foco o desempenho dos índices de vegetação a partir da metodologia de componentes principais. Sendo que, doze componentes foram obtidos a partir da matriz de correlações entre os pares de índices mensuradas no experimento, como exposto na Tabela 8.

Tabela 8 - Autovalores e proporções de variáveis explicadas

Componente	Autovalor	Variância Explicada (%)	Variância Acumulada (%)
CP1	3,32	0,92	0,92
CP2	0,81	0,05	0,98
CP3	0,43	0,02	0,99
CP4	0,26	0,01	1,00
CP5	0,13	0,00	1,00
CP6	0,10	0,00	1,00
CP7	0,09	0,00	1,00
CP8	0,05	0,00	1,00
CP9	0,04	0,00	1,00
CP10	0,02	0,00	1,00
CP11	0,01	0,00	1,00

Essa análise é realizada unicamente em cima dos índices, sem considerar a variável produção, para observar o comportamento de cada índice e analisar qual está obtendo a melhor resposta e contribuindo mais para o componente. É utilizado o método dos componentes principais quando se tem uma relação linear entre todas as variáveis explicativas, gerando assim um componente, e isso se torna possível por meio da matriz de correlação. Cada componente é um índice e esses componentes são independentes entre si.

Como é possível averiguar na Tabela 10, foi obtido os componentes, o autovalor e a variância explicativa. Foram consideradas as 65 observações e apenas os dois primeiros componentes foram significativos, sendo que o primeiro componente explica 92% da variabilidade e acrescentando o segundo componente consegue explicar 98% da variabilidade. Dessa forma, para a análise foram considerados apenas os dois primeiros componentes que explicam juntos aproximadamente 98% da variabilidade total dos dados. Portanto, na Tabela 9, apresenta-se os valores dos coeficientes dos componentes principais selecionados.

Tabela 9 - Coeficientes dos dois primeiros componentes principais

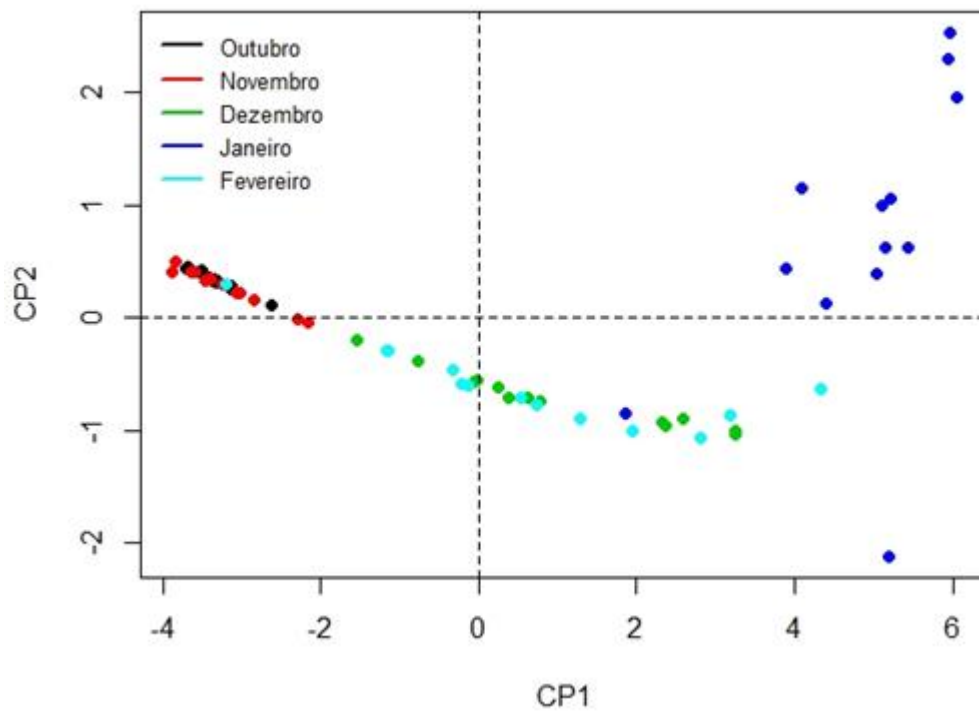
Variáveis	CP1	CP2
EVI 2	0,300	-0,068
GARI	0,300	-0,073
GNDVI	0,298	-0,015
GSAVI	0,298	-0,051
NAVI	0,293	-0,223
NDRE	0,299	0,003
NDVI	0,298	-0,145
NDWI	0,293	-0,111
OSAVI	0,298	-0,145
RATIO	0,268	0,366
SAVI	0,298	-0,103

A primeira componente caracterizou-se pelos índices EVI 2 e o GARI com, tecnicamente, maior contribuição. Na segunda componente o índice que mais contribuiu foi o RATIO.

Com a redução do número de parâmetros, para duas componentes, cada observação recebeu um *escore* correspondente a cada componente e, dessa forma foi possível construir gráficos de dispersão para cada mês de estudo, apresentados na Figura 15.

Na Figura 16 tem a representação das médias dos componentes principais conforme cada mês, nessa figura será possível analisar que o comportamento dos índices é similar ao que foi exposto anteriormente na análise descritiva.

Figura 15 - Gráfico de dispersão das observações nos componentes principais para cada mês analisado



Os gráficos demonstraram os valores dos componentes principais, baseado nos valores dos índices. E podemos analisar que o comportamento dos índices realmente é diferente de um mês para o outro, como afirmado anteriormente na análise descritiva e comprovando que janeiro é o mês que os índices obtiveram as melhores respostas.

Pelos gráficos, os meses de outubro e novembro apresentam comportamento similar, CP1 com escore médio negativo e CP2 com escore médio positivo, isto é, o RATIO é o que representa esses meses. Os meses dezembro e fevereiro também apresentam comportamento similar, CP1 positivo e CP2 negativo, ou seja, todos os índices contribuíram, não ficando claro qual caracterizou mais, certamente o ideal é aquele como maior efeito absoluto. E finalmente, janeiro é caracterizado por CP1 e CP2 escores médios positivos, desta forma, todos os índices de certa forma contribuíram, mas o destaque é o índice RATIO.

Alguns autores também aplicaram essa técnica da análise de componentes principais em alguns estudos. Em 2014, os autores Santos et al., propuseram gerar uma metodologia para estimar a área cultivada pela cultura da soja por meio de um perfil espectro-temporal utilizando valores do índice NDVI e um dos métodos de análise foi por meio da análise de componentes principais. Em 2012, os pesquisadores Santi et al., avaliaram por meio da técnica de análise de componentes principais os atributos do solo, químicos e físicos, para compreender a variabilidade espacial e temporal da produtividade de culturas de grãos.

4.5 Análise do desempenho dos índices

Como visto anteriormente, foram encontradas muitas dificuldades durante o processo de modelagem, com o ajuste do modelo linear generalizado misto (Gama misto) e pelo baixo número de observações para ajustar o modelo Gama utilizando simultaneamente todos os índices. Assim sendo, foi definido um critério para identificar os melhores índices, para que fosse possível ajustar um modelo com menor número de variáveis.

Para considerar o índice de vegetação um bom candidato para compor o modelo ele tem que se demonstrar sensível a evolução mensal do desenvolvimento da cultura cultivada. Para realizar essa análise, testou-se as médias das observações pareadas do mês de referência com o mês posterior. Desta forma, os índices que

apresentarem diferenças estatisticamente significativa para todas as comparações serão considerados índices candidatos a compor o modelo final.

A fim de realizar essa análise foi aplicado o teste de Wilcoxon pareado, também a 5% de probabilidade, para identificar diferenças que justifiquem a opção por um ou outro índice (Tabela 10). É um teste não paramétrico empregue para avaliar a igualdade de médias de grupos de amostras que não atendem uma distribuição normal (WILCOXON, 1945).

Essa técnica foi aplicada por Risso et al. (2012), utilizando dois índices de vegetação, o EVI e NDVI, para discriminar áreas de produção agrícola, pastagem e floresta, avaliando as diferenças dos valores dos índices pelo método do teste de Wilcoxon. E Breunig (2011), avaliou os efeitos direcionais, em diferentes ângulos de visada, a reflectância dos dosséis de soja em diferentes estádios de desenvolvimento, aplicando alguns índices de vegetação e utilizando o teste não paramétrico de Wilcoxon para avaliação.

Tabela 10 - Comparações de médias pareadas por índice de vegetação

Índices	Comparações			
	Out - Nov	Nov - Dez	Dez - Jan	Jan - Fev
EVI 2	0,168	< 0,001	< 0,001	< 0,001
GARI	0,068	< 0,001	0,001	< 0,001
GNDVI	0,839	< 0,001	0,001	< 0,001
GSAVI	0,010	< 0,001	0,002	< 0,001
NAVI	0,168	< 0,001	< 0,001	< 0,001
NDRE	0,127	< 0,001	0,001	< 0,001
NDVI	0,168	< 0,001	< 0,001	< 0,001
NDWI	0,003	< 0,001	< 0,001	< 0,001
OSAVI	0,168	< 0,001	< 0,001	< 0,001
RATIO	0,244	< 0,001	< 0,001	< 0,001
SAVI	0,068	< 0,001	< 0,001	< 0,001

Nota: Os valores internos são os valores p do teste de Wilcoxon pareado, $\alpha = 0,05$.

Como já verificado, os índices de vegetação analisados não seguem uma distribuição normal, dessa forma, com a análise do teste de Wilcoxon foi possível averiguar quais índices foram mais sensíveis para a detecção da evolução das plantas

e determinar quais os melhores para serem candidatos a compor o modelo de regressão.

Os índices foram selecionados a partir do p-valor próximo ao nível de significância, que é de 5%, ou seja, $< 0,05$. Portanto, levando em consideração esse valor, os índices considerados adequados são o GSAVI e o NDWI. Mas como têm dois índices que se aproximaram desse valor também, mesmo não possuindo a primeira comparação significativa, sendo eles, o GARI e o SAVI, também serão candidatos para o modelo de regressão.

Ressaltando que para ajustar um MLG, não se deve utilizar os dados com todos os meses, pois nesta situação, deve-se incluir ao modelo a variabilidade decorrente das medidas repetidas por indivíduo.

4.6 Estimativas de produtividade com o modelo final

No período de observação a partir do cultivo, janeiro é o mês ápice do desenvolvimento do cultivo de soja, neste sentido, a análise descritiva corrobora com esse fato, pois os valores dos índices de vegetação neste mês foram em módulo maiores do que nos demais meses, tal fato já foi observado na Tabela 2 e na Figura 7. Logo, optou-se em fazer uma avaliação dos índices para o mês de janeiro.

A primeira etapa consistiu em ajustar um modelo completo com os quatro índices, selecionados na seção anterior, mais sensíveis para detectar o desenvolvimento da cultura cultivada, expresso pela Equação 18.

$$\text{Log(Produção)} \sim \alpha + \beta_1 \cdot \text{GARI} + \beta_2 \cdot \text{GSAVI} + \beta_3 \cdot \text{NDWI} + \beta_4 \cdot \text{SAVI} \quad (18)$$

Prosseguiu-se com a seleção das variáveis via regressão *stepwise* direção *backward*, o critério utilizado pelo algoritmo foi valores AIC (*Akaike Information Criterion*), ou seja, quanto menor o AIC melhor o ajuste do modelo (Tabela 11). A regressão *stepwise* tipo *backward*, é quando todas as variáveis são inseridas todas de uma única vez na equação, sendo retiradas depois, uma de cada vez, até que se reconheçam as melhores variáveis (KEPPEL, 1991; TABACHNICK; FIDELL, 1996).

Para fim de comparação entre os modelos ajustados, foi aplicado o método do AIC, que conforme Burnham e Anderson (2002), é um método objetivo, simples e eficiente para poder considerar o modelo mais apropriado, sendo que considera o

modelo que minimiza o AIC. Um resultado mínimo para o AIC é classificado como um ajuste de melhor adequação, sendo o objetivo ter a minimização desse valor (HESS et al., 2015).

Tabela 11 - Processo de seleção de variáveis – *stepwise* – para compor o modelo final

Passo 1			
Produção ~ GARI + GSAVI + NDWI + SAVI			
Variável	Graus de liberdade	Deviance	AIC
- SAVI	1	0,20	105,62
- GARI	1	0,20	105,62
- GSAVI	1	0,20	105,67
- NDWI	1	0,21	106,13
COMPLETO		0,20	108,18
*AIC = 108,18 (modelo)			
Passo2			
Produção ~ GARI + GSAVI + NDWI			
Variável	Graus de liberdade	Deviance	AIC
- GARI	1	0,20	103,06
- GSAVI	1	0,21	103,41
- NDWI	1	0,22	103,89
COMPLETO		0,20	105,62
* AIC = 105,62 (modelo)			
Passo 3			
Produção ~ GSAVI + NDWI			
Variável	Graus de liberdade	Deviance	AIC
COMPLETO		0,20	103,06
- NDWI	1	0,27	103,89
- GSAVI	1	0,31	105,87
* AIC = 103,06 (modelo)			

Sendo que o modelo selecionado por meio da regressão *stepwise* direção *backward*, está representado pela Equação 19.

$$\text{Log(Produção)} \sim \alpha + \beta_1 \cdot \text{GSAVI} + \beta_2 \cdot \text{NDWI} \quad (19)$$

Em seguida, foi realizado as estimativas dos parâmetros referentes ao modelo Gama selecionado e conferido se há a existência de multicolinearidade entre os índices selecionados (Tabelas 12 e 13).

Tabela 12 - Estimativas dos parâmetros referentes ao modelo Gama com efeitos multiplicativos para os índices selecionados

Parâmetro	Estimativa	Erro Padrão	t	p
Intercepto	6,455	0,892	7,236	0,000
GSAVI	-2,924	1,293	-2,261	0,047
NDWI	3,746	2,091	1,791	0,104

Conforme avaliado o índice GSAVI é significativo, apresenta o p-valor <0,05 e apesar do índice NDWI não ser significativo, este modelo foi o que teve melhor ajuste segundo o Critério de Informação de Akaike (AIC).


Tabela 13 - VIF do modelo: Produção ~ GSAVI + NDWI

GSAVI	NDWI
9,17	9,17

Quanto à existência de multicolinearidade, os valores indicaram a existência, no entanto, só é considerado problemático para as estimativas do modelo quando o VIF é maior do que 10.

Em seguida, é apresentado o gráfico normal de probabilidades com envelope para os componentes padronizados do desvio, expresso na Figura 17.

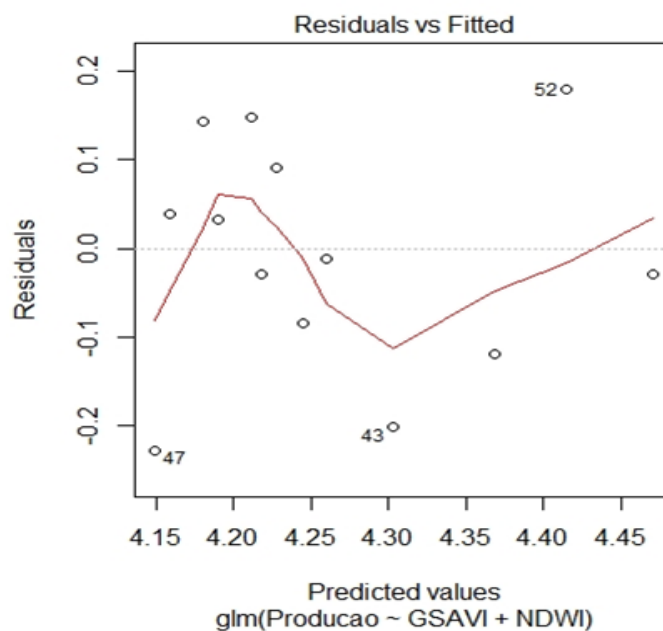
Figura 17- Gráfico normal de probabilidades referente ao modelo gama ajustado



Nota-se, pelo gráfico, que não há indícios de afastamentos sérios da suposição de distribuição gama para a produtividade de soja, isto porque, todos os pontos estão localizados dentro do envelope simulado.

Na Figura 18, está apresentado o gráfico de dispersão resíduos vs. valores ajustados.

Figura 18 - Gráfico de dispersão resíduos vs. valores ajustados



O gráfico de resíduos mostra um indicativo de dependência dos resíduos. O teste Durbin Watson evidenciou a independência dos resíduos (*valor p* = 0,09) atendendo uma das pressuposições do modelo.

O modelo final obtido é expresso pela Equação 20.

$$\widehat{Produção} \sim e^{6,455 - 2,924 \cdot GSAVI + 3,746 \cdot NDWI} \quad (20)$$

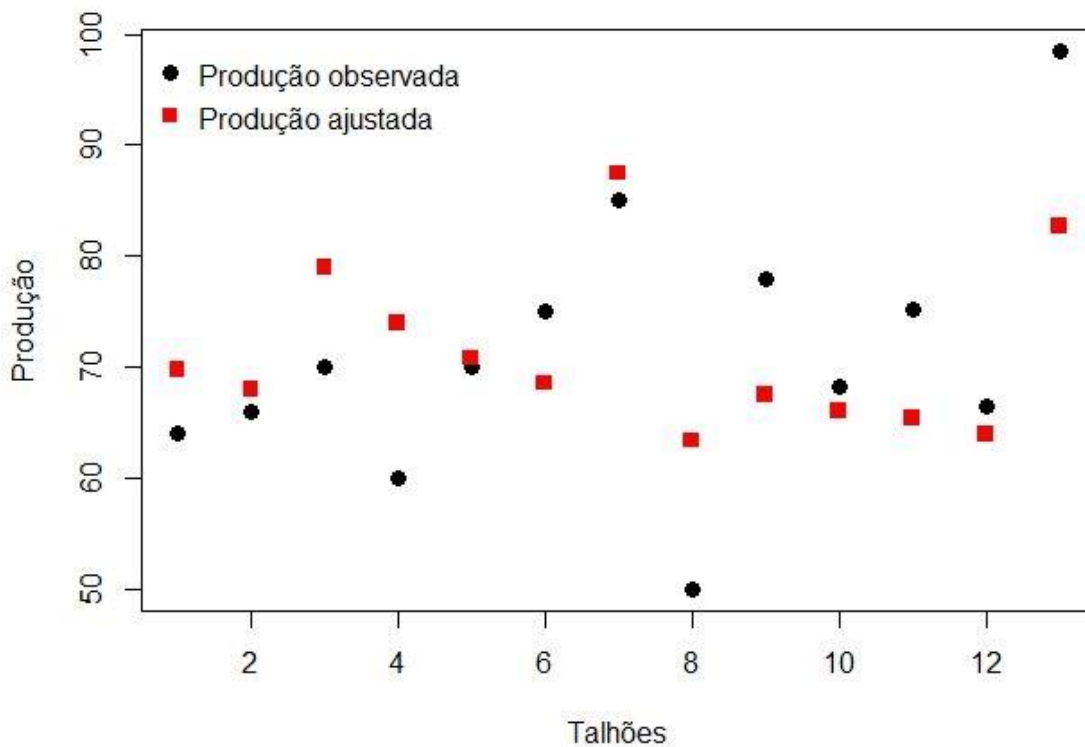
Indicando que, o aumento em uma unidade do índice GSAVI acarreta num aumento da produção em 0,054 ($e^{-2,924}$), considerando as demais variáveis constantes. Em contrapartida, o aumento em uma unidade do NDWI o aumento relativo esperado da produtividade é de 42,35 ($e^{3,746}$), considerando as demais variáveis constantes.

Assim sendo, foi realizado a predição da produção por meio do modelo ajustado para analisar se de fato, os valores se aproximam dos valores adquiridos em campo. Estas comparações estão apresentadas na Tabela 14 e Figura 19.

Tabela 14 - Valores observados e ajustados pelo modelo Gama obtido

Talhão	Produção observada	Produção ajustada	Erro estimado
1	64,00	69,72	5,72
2	66,00	67,93	1,93
3	70,00	78,98	8,98
4	60,00	73,94	13,94
5	70,00	70,80	0,80
6	75,00	68,54	- 6,46
7	85,00	87,48	2,48
8	50,00	63,37	13,37
9	78,00	67,46	- 10,54
10	68,18	66,04	- 2,14
11	75,20	65,37	- 9,83
12	66,46	63,96	- 2,5
13	98,46	82,67	- 15,79

Figura 19 - Gráfico de comparação entre a produção observada e a produção ajustada por meio do modelo



A avaliação do modelo foi feita a partir de um conjunto de dados de 13 talhões do cultivo de soja da safra dos anos 2019 a 2020, obtidos junto à produtores do município de Itaberá-SP. A produtividade de cada talhão foi comparada à produtividade estimada pelo modelo para os mesmos talhões.

De maneira geral, as estimativas no âmbito de talhão não foram boas, considerando o erro estimado para cada talhão.

Há de se considerar, entretanto, que as amostras analisadas não foram adquiridas de uma única propriedade, mas sim, de algumas. Sendo assim, isso acarreta em algumas desvantagens para o modelo proposto. Pois, além das limitações na quantidade de dados para amostragem, a data de plantio e colheita da cultura de cada talhão, os tipos de cultivares cultivadas, o ciclo da cultura, se são áreas irrigadas ou não, tipo de manejo, entre outras características, são todos fatores que interferem nos dados e acabam intervindo no resultado final.

É necessário entender que cada cultura tem suas propriedades fenológicas durante todo o ciclo biológico, seja na questão da dinâmica de desenvolvimento, ou em decorrência da arquitetura das plantas e as características dos tratos culturais, levando em consideração as diferentes plantações da mesma cultura. Além disso,

outros fatores são determinantes como as alterações em razões culturais e ambientais, envolvendo data de plantio, cultivar, espaçamento inter e intrafileiras, adubação, umidade do solo, entre outros (FORMAGGIO; SANCHES, 2017).

Portanto, se todas as amostras analisadas fossem de uma mesma propriedade, com todas as características e manejo semelhantes, talvez o modelo fosse mais preciso ou se os números de amostras fossem mais abrangentes.

Alguns autores também trabalharam com informações de sensoriamento remoto para estimar produção de culturas agrícolas. Moura (2013), estimou a variabilidade espacial de graus de produtividade da cultura da cana-de-açúcar empregando ferramentas do sensoriamento remoto. Mercante (2010), calculou índices de vegetação para comparar as produtividades de 36 municípios com as estatísticas obtidas pelo IBGE. Benvenuti (2005), trabalhou com índices de vegetação e imagens do Landsat 7/ETM+ para averiguar a produtividade da cana-de-açúcar e Liu e Kogan (2002) monitoraram a cultura da soja, em diversas regiões do Brasil, empregando índices de vegetação diversos nas imagens Landsat 7/ETM+ e MODIS.

Lembrando que os índices selecionados pelo modelo para estimar a produção agrícola da cultura da soja auxiliam no monitoramento das culturas em duas vertentes distintas, o GSAVI evidencia melhor os pigmentos de clorofila, os níveis de oxigênio nas folhas e a produtividade de grãos (SRIPADA et al., 2006). E o NDWI é o índice que monitora o conteúdo de água foliar, associa a investigação da escassez hídrica e avalia o estresse hídrico na vegetação (GAO, 1996).

O modelo selecionou dois índices que acabam se completando, pois avaliam e analisam comportamentos distintos da vegetação, podendo auxiliar em análises mais completas. Mas vale ressaltar que há a necessidade de uma amostragem mais abundante, com maior nível de informação ou com dados que ocorram em um mesmo ambiente. Pois, uma vez que a densidade amostral empregada é de apenas 13 talhões para observação e que não foram extraídas do mesmo local e nem com os mesmos tratos culturais, não sejam adequadas para uma análise tão complexa.

5 CONCLUSÕES

Esse trabalho empregou técnicas de sensoriamento remoto, como imagens orbitais e índices de vegetação para realizar estimativas de variabilidade espacial de produtividade para a cultura da soja.

Pelos resultados alcançados nessa pesquisa, pode-se concluir que:

- A aplicação dos índices de vegetação é um recurso relevante para realizar a análise do desenvolvimento do estado da vegetação;
- Por meio dos doze índices de vegetação empregues foi possível analisar o comportamento espectro-temporal da cultura, verificando que o mês de maior desenvolvimento foi janeiro;
- Foi possível elaborar um modelo estatístico que conseguiu prever a produtividade da cultura da soja, mas que não foi tão preciso por contar com uma pequena quantidade de observações;
- Os índices selecionados pelo modelo para estimar a produção agrícola da cultura da soja foram o GSAVI e o NDWI, nas condições do presente trabalho;
- Por meio de técnicas de sensoriamento remoto é possível realizar estudos de variabilidade espacial de produtividade de culturas agrícolas.

REFERÊNCIAS

- ADAMI, M. **Estimativa de áreas agrícolas por meio de técnicas de sensoriamento remoto, geoprocessamento e amostragem**. 2004. p. 183. Dissertação (Mestrado na Área de Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.
- ADAMI, M.; MOREIRA, M. A.; FRIEDRICH, B.; RUDORFF, T.; FREITAS, C. Análise da eficiência dos estimadores de expansão direta e de regressão para áreas cultivadas do café, milho e soja no município de Cornélio Procópio, Estado do Paraná. **Agricultura de São Paulo**, v. 51, n. 2, p. 5–13, 2004.
- ADAMI, M.; RIZZI, R.; MOREIRA, M. A.; RUDORFF, B. F. T. FERREIRA, C. C. Amostragem probabilística estratificada por pontos para estimar a área cultivada com soja. **Pesquisa Agropecuária Brasileira**, v.45, p.585-592. 2010.
- ADAMI, M.; RUDORFF, B. F. T.; FREITAS, R. M.; AGUIAR, D. A.; SUGAWARA, L. M.; MELLO, M. P. Remote Sensing Time Series to Evaluate Direct Land Use Change of Recent Expanded Sugarcane Crop in Brazil. **Sustainability**, v. 4, n. 12, p. 574–585, 2 abr. 2012.
- ANDRADE, D. D. Estimativas de carbono na cobertura vegetal da APA Fernão Dias (MG) por meio de dados espectrais de campo. **Caderno de estudos geoambientais CADEGEO**, v. 05, n. 01, p. 05-16, 2015.
- APAN, A.; POTGIETER, A. Using satellite imagery in determining winter crop area planted in support of regional commodity forecasting: a case study of the Darling Downs, Queensland. Australia: University of Southern Queensland/Faculty of **Engineering and Surveying**, 2002.
- ARANTES, T. B. **Análise de séries temporais compostas por imagens sintetizadas a partir da fusão de dados modis - TM**. 2004. 91f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2014.
- ARNDT, S.; TURVEY, C.; ANDREASEN, N. C. Correlating and predicting psychiatric symptom ratings: Spearman's r versus Kendall's tau correlation. **J Psychiatr Res.**, v.33, n.2, p.97-104, 1999.
- ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, vol. 22, p. 18, 3855–3862, 2001.
- ASRAR, G.; FUCHS, M.; KANEMASU, E. T.; HATFIELD, J. L. Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat, **Agronomy Journal**, v.76, p. 300 – 306, 1984.
- ATZBERGER, C. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. **Remote Sensing**, v. 5, n. 2, p. 949–981, 22 fev. 2013.
- AYRES, M. **Elementos de bioestatística: a seiva do açazeiro**. 2. ed. Belém: Supercores, p. 588, 2012.

- BAAN, L. de; ALKEMADE, R.; KOELLNER, T. Land use impacts on biodiversity in LCA: a global approach. **The International Journal of Life Cycle Assessment**, v. 18, n. 6, p. 1216-1230, 2013.
- BALAGHI, R.; TYCHON, B.; EERENS, H.; JLIBENE, M. Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco. **International Journal of Applied Earth Observation and Geoinformation**. v. 10, 438–452, 2008.
- BARBOSA, A. I. G.; REIS, C. H.; MENDONÇA, J. C. Previsão de safras da produção de cana-de-açúcar no município de Campos dos Goytacazes – RJ utilizando sensoriamento remoto. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto - INPE**. Santos, SP. Abril, 2019.
- BARBOSA, K. M. N. **Monitoramento espacial de biomassa e carbono orgânico da vegetação herbácea de várzea na Amazônia Central**. 2006. 131 p Tese (Doutorado em Ciências Florestais) - Universidade Federal do Paraná, Curitiba, 2006.
- BARNES, E. M.; CLARKE, T. R.; CLARKE, S. E. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. In: **International Conference On Precision Agriculture**, 2000, Bloomington. Madison: ASA: CSSA: SSSA, 2000.
- BARRETO LUIZ, A. J.; BARROS, M. G. M.; FORMAGGIO, A. R.; EPIPHANIO, J. C. N. Comportamento espectral associado a parâmetros agronômicos de soja (*Glycine max*) e feijão (*Phaseolus vulgaris*). **Anais X Simpósio Brasileiro de Sensoriamento Remoto – INPE**, Foz do Iguazu – PR, p.103 – 110, 2001.
- BECKER-RESHEF, I.; JUSTICE, C.; SULLIVAN, M.; VERMOTE, E.; TUCKER, C.; ANYAMBA, A.; SMALL, J.; PAK, E.; MASUOKA, E.; SCHMALTZ, J.; HANSEN, M.; PITTMAN, K.; BIRKETT, C.; WILLIAMS, D.; REYNOLDS, C.; DOORN, B. Monitoring global croplands with coarse resolution Earth observations: the Global Agriculture Monitoring (GLAM) project. **Remote Sensing**, v. 2, n. 6, p. 1589–1609, 18 jun. 2010.
- BENVENUTI, F.A. **Relação de índices espectrais de vegetação com a produtividade da cana-de- -açúcar e atributos edáficos**. 2005. 115 f. Dissertação (Mestrado em Engenharia Agrícola) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2005.
- BERNARDES, T. **Modelagem de dados espectrais e agrometeorológicos para estimativa da produtividade de café**. 2013. 127 p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.
- BERNARDI, A.C.C. et al. **Variabilidade de propriedades do solo, índices de vegetação e produtividade de pastagem sob manejo intensivo**. São Carlos, SP, Embrapa Pecuária Sudeste, 2014.
- BERTOLIN, N. O.; FILGUEIRAS, R.; VENANCIO, L. P.; MANTOVANI, E. C.; Predição da produtividade de milho irrigado com auxílio de imagens de satélite.

Revista Brasileira de Agricultura Irrigada, Fortaleza, v. 11, n. 4, p. 1627-1638, 2017.

BORGES, B. C.; BAPTISTA, G. M. M. Avaliação da potencialidade do índice de vegetação SFDVI (*Spectral Feature Depth Vegetation Index*) para a discretização da cobertura do solo em áreas rurais. **Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, Santos, p. 1931-1938, 2017.

BRESLOW, N. E.; CLAYTON, D. G. Approximate inference in generalized linear mixed models. **Journal of the American statistical Association**, v. 88, n. 421, p. 9-25, 1993.

BREUNIG, F. M. **Influência da geometria de aquisição sobre índices de vegetação e estimativas de IAF com dados Modis, Hyperion e simulações prosail para a soja**. 2011. 210 p. Tese (Doutorado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais – São José dos Campos, 2011.

BRITO, M. V. A.; TAVARES, B. I.; MOURA, V.; CASTRO, J. P. M.; SOUZA, R. A. Previsão de área plantada com soja, safra 2017/18, no sul de Rondônia. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto - INPE**. Santos, SP. Abril, 2019.

BURNHAM, K. P.; ANDERSON, D. R. **Model selection and multimodel inference: a practical informationtheoretic approach**. Nova York: Spring-Verlag, 2ª ed., 2002.

BUSSAB, W. O.; MORETTIN, P. A. **Estatística básica**. 7.ed. São Paulo: Saraiva, 2004.

CARMELLO, V. **Variabilidade pluviométrica e produção de soja: análise comparativa entre regiões produtoras do Brasil, Estados Unidos e Índia**. 2018. 236 f. Tese (Doutorado em Geografia). Faculdade de Ciências e Tecnologia - Universidade Estadual Paulista, Presidente Prudente, 2018.

CARMONA, F.; RIVAS, R.; FONNEGRA, D. C. Vegetation index to estimate chlorophyll content from multispectral remote sensing data. **European Journal of Remote Sensing** 48, p. 319–326, 2015.

CARVALHO, L. F. D. **Índices de vegetação obtidos por sensor proximal e embarcado em aeronave remotamente pilotada e sua relação com a produtividade do milho**. 2019. 91 p. Tese (Doutorado em Ciência do Solo), Universidade Federal de Santa Maria, Santa Maria, 2019.

CARVALHO, S. P. C.; CALEGARIO, N.; SILVA, F. F.; BORGES, L. A. C.; MENDONÇA, A. R.; LIMA, M. P. Modelos não lineares generalizados aplicados na predição da área basal e volume de Eucalyptus clonal. **Cerne**, Lavras, v. 17, n. 4, p. 541-548, 2011.

CARVALHO, T. M. **Modelagem digital de atributos de solo da fazenda Edgárdia – Botucatu-SP**. 2016. 143 p. Tese (Doutorado em Agronomia – Energia na Agricultura) – Faculdade de Ciências Agrônômicas – Universidade Estadual Paulista “Júlio de Mesquita”, Botucatu, 2016.

CEPAGRI. Unicamp. Centro de pesquisas meteorológicas e climáticas aplicadas a agricultura: **Clima dos Municípios Paulistas** 2014. Disponível em: <http://www.cpa.unicamp.br/outras-informacoes/clima_muni_251.html>. Acesso em 15 dez. 2016.

CESTARI, A. A.; COSTA, S. A.; MINHO, A. P. Análise de dados longitudinais em experimentação em animal. Semina: **Ciências Agrárias**, Londrina, v. 33, n. 4, p. 1565-1580, 2012.

CHAGAS, K. D. **Inferência Bayesiana para testes acelerados “step-stress” com dados de falha sob censura e distribuição Gama**. 2018. 180 p. Dissertação (Mestrado em Matemática Aplicada e Computacional). Faculdade de Ciências e Tecnologia – Universidade Estadual Paulista, Presidente Prudente, 2018.

CHEN, C. S.; TARDIN, A. T.; BATISTA, G. T. Índices de Vegetação e suas aplicações na agricultura. São José dos Campos, SP: Instituto Nacional de Pesquisas Espaciais, **INPE**, 24p. 1986.

CONAB – Companhia Nacional de Abastecimento, Acompanhamento da safra brasileira, 2020. Disponível: <<https://www.conab.gov.br/info-agro/safras>>. Acesso em: 11 fev 2020.

CORDEIRO, G. M.; LIMA NETO, E. A. **Modelos paramétricos**. Recife: Universidade Federal Rural de Pernambuco, Departamento de Estatística e Informática, p. 256, 2006.

COSTA, S. C. **Modelos lineares generalizados mistos para dados longitudinais**. 2003. 110 p. Tese (Doutorado em Agronomia – Estatística e Experimentação Agronômica) – Escola Superior de Agricultura Luiz de Queiroz - Universidade de São Paulo, Piracicaba, 2003.

CROWDER, M. J.; HAND, D. J. **Analysis of repeated measures**. London: Chapman & Hall, p.257, 1990.

CRUSCO, D. **Sensoriamento remoto para análise multitemporal da dinâmica de áreas agrícolas**. 2006. p. 183. Dissertação (Mestrado na Área de Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

DALMOLIN, R. S. D.; GONÇALVES, C. N.; KLAMT, E.; DICK, D. P. Relação entre os constituintes do solo e seu comportamento espectral. **Ciência Rural**, Santa Maria, v. 35, n. 2, p. 481-489, 2005.

DEMÉTRIO, C. G. B. **Modelos Lineares Generalizados**. Campinas: UNICAMP, IMECC, 1986.

DIDAN, K.; HUETE, A. **Modis vegetation index product series collection 5 change summary**. Arizona: The University of Arizona, 2006.

DORIGO, W.A.; ZURITA-MILLA, R.; DE WIT, A.J.W.; BRAZILE, J.; SINGH, R.; SCHAEPMAN, M.E. A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. **International Journal of Applied Earth Observation and Geoinformation**, v. 9, n. 2, p. 165-193, May 2007.

EASTMAN, J. R. Idrisi for Windows. Manual do usuário. Trad. HASENACK, H.; WEBER, E. Porto Alegre: UFRGS, Centro de Recursos Idrisi, Brasil, 1998.

EBERHARDT, I. D. R. **Estimativa em tempo quase real de área de milho e soja no Rio Grande do Sul, por sensoriamento remoto e amostragem**. 2015. p. 134. Dissertação (Mestrado na Área de Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.

EBERHARDT, I. D. R.; LUIZ, A. J. B.; FORMAGGIO, A. R.; SANCHES, I. A. Detecção de áreas agrícolas em tempo quase real com imagens Modis. **Pesquisa Agropecuária Brasileira**, v.50, n.7, p.605 – 614, 2015.

EBERHARDT, I. D. R.; MELLO, M. P.; RIZZI, R.; FORMAGGIO, A. R.; ATZBERGER, C.; FOSCHIERA, W.; SCHULTZ, B.; LUIZ, A. J. B.; TRABAQUINI, K.; GOLTZ, E. In: IEEE GEOSCIENCE AND REMOTE SENSING SOCIETY (GRSS), 2014, Quebec. **Proceedings...** v. 1, p. 2126-2129, 2014.

EOS - Earth Observing System Sentinel – 2, 2020. Disponível em: <<https://eos.com/sentinel-2>> Acesso em: 18 jun 2020.

EPIPHANIO, J. C. N.; BARROS NETO, O. O.; LUIZ, A. J. B.; FORMAGGIO, A. R. Sistema de amostragem em imagens como base para estimativa de áreas de culturas agrícolas no município de Ipuã. In: Simpósio Brasileiro de Sensoriamento Remoto, 10., Foz do Iguaçu, 2001. **Anais**. São José dos Campos: INPE, 2001.

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa Agropecuária Brasileira**, Brasília, v. 31, n. 6, p. 445-454, 1996.

EPIPHANIO, J. C. N.; LUIZ, A. J. BARRETO; FORMAGGIO, A. R. Estimativa de áreas agrícolas municipais, utilizando sistema de amostragem simples sobre imagens de satélite. **Bragantia**, v. 3, n. 1, p. 187–197, 2000.

ESTATCAMP. Portal Action. 3. **Análise de resíduos**. Disponível em: <<http://www.portalaction.com.br/analise-de-regressao/analise-dos-residuos>>. Acesso em: 07 de abr de 2021.

FERNANDES, S.; PINTO, M. Afinal o que são e como se calculam os quartis? Universidade do Algarve – Departamento de Matemática, 2013.

FERRAZ, A. S.; SOARES, V. P.; SOARES, C. P. B.; RIBEIRO, C. A. S. A.; GLERIANI, J. M. Uso de imagens do satélite IKONOS II para estimar biomassa aérea de um fragmento de floresta estacional semidecidual. Simpósio Brasileiro de Sensoriamento Remoto. **Anais** [...] Foz do Iguaçu, p. 2794-2801, 2013.

FERREIRA, E. J. S. **Avaliação de índices de vegetação para estimativa de produtividade do milho em sistemas de manejo do solo no cerrado**. 2020. 193 f. Dissertação (Mestrado em Agronomia – Sistemas de Produção) – Faculdade de Engenharia de Ilha Solteira - Universidade Estadual Paulista, Ilha Solteira, 2020.

FIELD, A. Descobrimo a estatística usando o SPSS. Tradução de Lorí Viali. 2. ed. Porto Alegre: **Artmed**, p. 687, 2009.

- FIGUEIREDO, D.C. Projeto GeoSafras: aperfeiçoamento do sistema de previsão de safras da Conab. **Revista de Política Agrícola**, v.14, p.110-120, 2005.
- FORMAGGIO, A. R.; EPIPHANIO, J. C. N. Características espectrais de culturas e rendimento agrícola. São José dos Campos: **INPE**, p. 178, 1990.
- FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento remoto em agricultura. 1ª edição. São Paulo, SP. 285p. 2017.
- GALFORD, G. L.; MUSTARD, J. F.; MELILLO, J.; GENDRIN, A.; CERRI, C. C.; CERRI, C. E. P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**, v. 112, n. 2, p. 576–587, fev. 2008.
- GAO, B. C. NDWI – A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water from space. **Remote Sensing of Environment**, v.58, p.257-266, 1996.
- GATES, D. M., H. J. KEEGAN, J. C. SCHLECTER, and V. R. WEIDNER. Spectral Properties of Plants. **Applied Optics** v.4, x1, p.11-20, 1965.
- GEOGLAM – Global Agricultural Monitoring, 2020. Disponível em: <<http://www.geoglam-crop-monitor.org/>>. Acesso: 10 jan. 2020.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v.58, n.3, p.289-298, 1996.
- GROFF, E. C.; NANNI, M. R.; POVH, F. P.; CEZAR, E. Características agrônômicas associadas com índices de vegetação medidos por sensores ativos de dossel na cultura da soja. **Ciências Agrárias**, Londrina, v. 34, n.2, p. 517-526, 2013.
- HAYES, M. J.; DECKER, W. L. Using NOAA AVHRR data to estimate maize production in the US Corn Belt. **International Journal of Remote Sensing**, Taylor & Francis Ltd, London, UK. 17:3189-3200, 1996.
- HESS, A. F.; CIANORSCHI, L. D.; SILVESTRE, R.; SCARIOT, R.; RICKEN, P. Aplicação dos modelos lineares generalizados para estimativa do crescimento em altura. **Brazilian Journal of Forestry Research**, v. 35, n. 84. P. 427-433, 2015.
- HONGYU, K. **Comparação do GGEbiplot ponderado e AMMI-ponderado com outros modelos de interação genótipo x ambiente**. 2015. 155 p. Tese (Doutorado em Estatística e Experimentação Agrônômica) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2015.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295-309, 1988.
- HUETE, A. R. *Spectral response of a plant canopy with different soil background*. **Remote Sensing of Environment**, New York, v. 17 p. 37-53, 1985.

HUETE, A.; LIU, H. Q.; BATCHILY, K.; LEWEEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, p. 440-451, 1997.

IBGE - Instituto Brasileiro de Geografia e Estatística. “Pesquisas agropecuárias”. Rio de Janeiro: ed. 2, v.6, p. 92., 2002.

IBGE – Instituto Brasileiro de Geografia e Estatística. Panorama municipal. Disponível em: <<https://cidades.ibge.gov.br/brasil/sp/itabera/panorama>>. Acesso em: 29. Fev. 2020.

IBGE - Instituto Brasileiro de Geografia e Estatística. Previsão e Acompanhamento de safras nos estados de São Paulo, Paraná, Santa Catarina e Distrito Federal. Safras de 1986/1987 a 1999/2000. **Séries retrospectivas**. Rio de Janeiro, 2004. Disponível em: <http://www.ibge.gov.br/home/estatistica/economia/agropecuaria/estatisticas_previsao_safras/Previsao_safras.pdf>. Acesso em: 17 jan. 2020.

IPEA. Instituto de Pesquisa Econômica Aplicada. IPEAdata: dados geográficos municipais. Disponível em:<<http://www.ipeadata.gov.br>>. Acesso em: 11 jan. 2021.

IPPOLITI-RAMILO, G. A.; EPIPHANIO, J. C. N.; SHIMABUKURO, Y. E. Landsat 5 Thematic Mapper data for pre planting crop area evaluation in tropical countries. **International Journal of Remote Sensing**, v. 24, n. 7, p. 1521–1534, jan. 2003.

IPT. Instituto de Pesquisas Tecnológicas do Estado de São Paulo. Plano diretor participativo do município de Itaberá, SP. São Paulo: **IPT**, 2006. 55 p. (Parecer Técnico n. 10.852-301, v. 1, 2 e 3).

JACKSON, M. W.; JENSEN, J. R. An evaluation of remote sensing-derived landscape ecology metrics for reservoir shoreline environmental monitoring. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 12, p. 1387 – 1397, 2005.

JAMES, G.; WITTEN, D; HASTIE, T; TIBSHIRANI, R. An Introduction to Statistical Learning: With Applications in R. New York: **Springer Publishing Company**, 2014.

JENSEN, J. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. Tradução, José Carlos Neves Epiphânio. 2.ed. São José dos Campos: **Editora Parêntese**, 2009.

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v.112, p. 3833-3845, 2008.

JIN, S.; YANG, L.; DANIELSON, P.; HOMER, C.; FRY, J.; XIAN, G. A comprehensive change detection method for updating the National Land Cover Database to circa 2011. **Remote Sensing of Environment**, v. 132, p. 159-175, 2013.

JOHNSON, R. A.; WICHERN, D. W. Applied multivariate statistical analysis. 6. Edition. New Jersey: **Prentice Hall**, p.794, 2007.

JOLLIFFE, I.T. Principal component analysis. 2nd. edition. New York: **Springer-Verlag**, p.520, 2002.

JUSTICE, C. O.; VERMOTE, E.; TOWNSHEND, J. R. G.; DEFRIES, R.; ROY, P. D.; HALL, D. K.; SALOMONSON, V.; PRIVETTE, J. L.; RIGGS, G.; STRAHLER, A.; LUCHT, W.; MYNENI, B.; KNYAZIKHIN, Y.; RUNNING, W. S.; NEMANI, R. R.; WAN, Z.; HUETE, A. R.; LEEUWEN, W. V.; WOLFE, R. F.; GIGLIO, L.; MULLER, J. P.; LEWIS, P.; BARNESLEY, M. The Moderate Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, n.4, p.1228-1247, 1998.

KAISER, H. F. The application of electronic computers to factor analysis. **Educational and Psychological Measurement**, v. 20, p. 141 – 151, 1960.

KEPPEL, G. Design and analysis: A researcher's handbook, (3a ed). Englewood Cliffs: **Prentice-Hall**, 1991.

KNIPLING, E. B. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. **Remote Sensing of Environment**, v.1, p.155-159, 1970.

KOUADIO, L.; NEWLANDS, N. K.; DAVIDSON, A.; ZHANG, Y.; CHIPANSHI, A. Assessing the performance of MODIS NDVI and EVI for seasonal crop yield forecasting at the ecodistrict scale. **Remote Sensing**, v.6, p.10193-10214, 2014.

LANDIM, P. M. B. (Coord.). Mapa Geológico do Estado de São Paulo. Escala 1:50.000, São Paulo: **IGCE/UNESP**, 1984.

LATTIN, J.; CARROLL, J. D.; GREEN, P. E. Análise de dados multivariados. Tradução de Harue Avritscher. São Paulo: **Cengage Learning**, p. 456, 2011.

LEMES, E. M. **Sensoriamento remoto para detecção de seringais infestados por *Meloidogyne exigua***. 2017. 68p. Tese (Doutorado em Agronomia – Fitotecnia), Universidade Federal de Uberlândia, Uberlândia, 2017.

LIU, W. T. H. Aplicações de sensoriamento remoto. 2ª edição. Campo Grande, MS. 908 p. 2015.

LIU, W. T. H.; KOGAN, F. Monitoring brazilian soybean production using NOAA/AVHRR based vegetation condition indices. **International Journal of Remote Sensing**, London, v.23, n.6, p.1.161-1.179, 2002.

LOOMIS, R. S.; WILLIAMS, W. A. Productivity and the morphology of crop stands: pattern with leaves. In: EASTIN, J. D. (Org.) Physiological aspects of crop yield. Madison: **American Society of Agronomy**, p. 27 – 47, 1969.

LOVELAND, T. R.; DWYER, J. L. Landsat: Building a strong future. **Remote Sensing of Environment**, n.122, p.22-29, 2012.

LUIZ, A. J. B. **Estatísticas agrícolas por amostragem auxiliadas pelo sensoriamento remoto**. 2003. p. 112. Tese (Doutorado na Área de Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003.

- LUIZ, A. J. B. **Estatísticas agrícolas por amostragem auxiliadas pelo sensoriamento remoto**. 2009. p. 112. Tese (Doutorado na Área de Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003.
- MACHADO, H. M. **Determinação da biomassa de cana-de-açúcar considerando a variação espacial de dados espectrais do satélite LANDSAT 7 – ETM+**. 2003. p. 74. Dissertação (Mestrado em Engenharia Agrícola -Área de concentração em Planejamento e Desenvolvimento Rural Sustentável) – Universidade Estadual de Campinas – Faculdade de Engenharia Agrícola, Campinas, 2003.
- MAGALHÃES, A. C. N. Análise quantitativa do crescimento. In: FERRI, M. G. (Org.) *Fisiologia Vegetal 1*. São Paulo: **Editora Pedagógica e Universitária**, p. 333 – 350, 1985.
- MALHEIROS, E. B. Precisão de análise de dados longitudinais, com diferentes estruturas para a matriz de variância e covariâncias, quando se utiliza o esquema em parcelas subdivididas. **Revista de Matemática e Estatística**, São Paulo, v. 17, n. 1, p. 263-273, 1999.
- MANLY, B. J. F. *Métodos estatísticos multivariados: uma introdução*. Tradução de Sara Ianda Carmona. 3. ed. Porto Alegre: **Bookman**, p. 229, 2008.
- MARIN, F. R. **Previsão de safras** – Agência Embrapa de Informação Tecnológica, 2020. Disponível em: <http://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01_65_22122006154840.html>. Acesso em: 11 fev 2020.
- MARTINS, E.G.M. Desvio padrão amostral. **Revista de Ciência Elementar**, Porto, v. 1, n. 1, p.22, 2013.
- MATTON, N.; CANTO, G.; WALDNER, F.; VALERO, S.; MORIN, D.; INGLADA, J.; ARIAS, M.; BONTEMPS, S.; KOETZ, B.; DEFOURNY, P. An Automated Method for Annual Cropland Mapping along the Season for Various Globally-Distributed Agrosystems Using High Spatial and Temporal Resolution Time Series. **Remote Sensing**, v. 7, n. 10, p. 13208–13232, 6 out. 2015.
- MCROBERTS, R. E. Satellite image-based maps: scientific inference or pretty pictures? **Remote Sensing of Environment**, v.115, p.715-724, 2011.
- MERCANTE, E.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A.; ROCHA, J. V. Modelos de regressão lineares para estimativa de produtividade da soja no oeste do Paraná utilizando dados espectrais. **Engenharia Agrícola**, v.30, n.3, p.504-517, 2010.
- MINGOTI, S. A. Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada. 1ª reimpressão. Belo Horizonte: **Editora UFMG**, 2007.
- MINGOTI, S. A.; SILVA, A. F. Um exemplo de aplicação de técnicas de estatística multivariada na construção de índices de preços. **Nova Economia**, Belo Horizonte, v. 7, n. 2, 1997.

- MIOT, H. A. Análise de correlação em estudos clínicos e experimentais. **Jornal vascular brasileiro**, v. 14, n. 4, p. 275-279, 2018.
- MOITA NETO, J.M.; MOITA, G.C. Uma introdução à análise exploratória de dados multivariados. **Química Nova**, v.21, p.467-469, 1998.
- MOREIRA, M. A. Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação. 4. ed. Viçosa: **Ed. UFV**, 2011.
- MOREIRA, M. E. M.; LEAL, M. R. L. V.; PICOLI, M. C. A.; DUFT, D. G. Análise estatística do uso da média mensal do NDVI no monitoramento da cana-de-açúcar no estado de São Paulo. XLIV Congresso Brasileiro de Engenharia Agrícola – CONBEA, São Pedro, **Anais**, p. 1-10, 2015.
- MOSLEH, M. K.; HASSAN, Q. K.; CHOWDHURY, E. H. Application of remote sensors in mapping rice area and forecasting its production: a review. **Sensors (Basel, Switzerland)**, v. 15, n. 1, p. 769–91, jan. 2015.
- MOURA, M. C. F. **Correlação entre produtividade em cana-de-açúcar e índices de vegetação espectrais: estudo de caso na região de Oratórios, MG**. 2013. 91 p. Tese (Doutorado em Engenharia Agrícola. Universidade Federal de Viçosa, 2013.
- NOETHER, G. E. Introdução à estatística: uma abordagem não paramétrica. Rio de Janeiro: **Guanabara Dois**, 1983.
- NORMAN, G. R.; STREINER, D. L. Biostatistics. The bare essentials. 4th ed. Shelton: **People's Medical Publishing House**; 2014.
- NOVO, E. M. L. Sensoriamento remoto: princípios e aplicações. 4. ed. São Paulo: **Edgar Blücher**, 388 p., 2010.
- NOVO, E. M. L. Sensoriamento remoto: princípios e aplicações. São Paulo: **Edgard Blucher**, p. 308, 1989.
- NUNES, L. F.; LOPES, C. S.; SOUZA, C. C. Aplicação de lógica *Fuzzy* em imagens de satélites para a previsão da produção de safras de grãos. **10º Seminário de Iniciação Científica** | 1º Seminário de Pesquisa e Pós-Graduação Stricto Sensu. Ago, 2019.
- OSBORNE, J. W.; COSTELLO, A. B. Sample size and subject to item ratio in principal components analysis. **Practical Assessment, Research & Evaluation**, v. 9 n.11, 2004.
- PEARSON, R. L.; MILLER, L. D. Remote sensing of standing crop biomass for estimation of the productivity of the shortgrass prairie. Proceedings of the 8th **Symposium on Remote Sensing of Environment**, University of Michigan, Ann Arbor, Michigan, USA. p.1357-1381, 1972.
- PINHEIRO, J. C.; BATES, D. M. Mixed effects models in S and S-PLUS. Madison: University of Wisconsin, (Technal Report, 89), p. 32, 1995.
- PINO, F. A. Estimativa subjetiva de safras agrícolas. **Informações Econômicas**, SP, v.31, n. 6, jun., 2001.

PONZONI, F. J. **Comportamento Espectral da Vegetação**. In: MENESES, P. R., NETTO, J. S. M. (org) Sensoriamento remoto, reflectância dos alvos naturais. Brasília – DF: Editora Universidade de Brasília - UNB, Embrapa Cerrados, p 157-199, 2001.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento remoto no estudo da vegetação. São José dos Campos. **Editora Parêntese**, 2007.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. Sensoriamento Remoto da vegetação. 2. Ed. Atualizada e ampliada. São Paulo: **Oficina de Textos**, 2012.

R CORE TEAM. R: A Language and Environment for Statistical Computing. R **Foundation for Statistical Computing**, Vienna, Austria, 2020.

RASMUSSEN, M. S. Operational yield forecasting using AVHRR NDVI data: prediction of environmental and inter-annual variability. **International Journal of Remote Sensing**, Taylor & Francis Ltd, London, UK. 18:1059-1077, 1997.

REN, J.; CHEN, Z.; ZHOU, Q.; TANG, H. Regional yield estimation for winter Wheat with MODIS-NDVI data in Shandong, China. **International Journal of Applied Earth Observation and Geoinformation**, v. 10, p. 403-413, 2008.

RISSO, J.; RIZZI, R.; RUDORFF, B. F. T.; ADAMI, M.; SHIMABUKURO, Y. E.; FORMAGGIO, A. R.; EPIPHANIO, R. D. V. Índices de vegetação Modis aplicado na discriminação de áreas de soja. **Pesquisa Agropecuária Brasileira**, v.47, n.9, p. 1317 - 1326, 2012.

RIZZI, R. **Geotecnologia de um sistema de estimativa da produção de soja: estudo de caso do Rio Grande do Sul**. 2005 p. 214. Tese (Doutorado na Área de Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

RIZZI, R.; RUDORFF, B. F. T. Estimativa da área de soja no Rio Grande do Sul por meio de imagens Landsat. **Revista Brasileira de Cartografia**, v.57, p.226-234, 2005.

RODRIGUES, S. C. A. **Modelo de regressão linear e suas aplicações**. Universidade da Beira Interior, Covilhã, Portugal, 2012.

RONDEAUX, G., STEVEN, M., BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing Environment**. v. 55, n. 2, p. 95–107, 1996.

ROSA, V. G. C. **Modelo agrometeorológico-espectral para monitoramento e estimativa da produtividade do café na região Sul/Sudoeste do estado de Minas Gerais**. 2007 p.143. Dissertação (Mestrado na Área de Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

ROSENDO, J. S.; ROSA, R. Exemplo de aplicação do Produto MOD13Q1 disponibilizado pelo sensor MODIS/Terra. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais...** Goiânia: INPE, p. 3285-3292, 2005.

ROSS, J. L. S.; MOROZ, I. C. Mapa geomorfológico do estado de São Paulo. Laboratório de Geomorfologia. São Paulo: Departamento de Geografia – FFLCH – **USP/Laboratório de Cartografia Geotécnica – Geologia Aplicada** – IPT/FAPESP (Fundação do Amparo à Pesquisa do Estado de São Paulo). 1997.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: Earth Resources Technology Satellite Symposium, 3., 1973, Washington. **Proceedings**. Washington: NASA, v. 1, p. 309-317, 1973.

RUDORFF, B. F. T.; AGUIAR, D. A. DE; SILVA, W. F. DA; SUGAWARA, L. M.; ADAMI, M.; MOREIRA, MAURÍCIO A. Studies on the Rapid Expansion of Sugarcane for Ethanol Production in São Paulo State (Brazil) Using Landsat Data. **Remote Sensing**, v. 2, n. 4, p. 1057–1076, 9 abr. 2010.

SAKAMOTO, T.; GITELSON, A. A.; ARKEBAUER, T. J. Near real-time prediction of U.S. corn yields based on time-series MODIS data. **Remote Sensing of Environment**, v.147, p.219-231, 2014.

SALVATIERRA, L. H. A. **Variação espaço-temporal da cobertura de vegetação da caatinga, usando o índice de vegetação normalizada (NDVI)**. 2016. 87 p. Dissertação (Mestrado em Ciências Biológicas – Área de Conservação da Biodiversidade Tropical) – Universidade Federal de Alagoas – UFAL, Maceió, 2016.

SANCHES, I. D.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Culturas Agrícolas em imagens multitemporais do satélite Landsat. **Agricultura de São Paulo**, v.52, n. 1, p. 83–96, 2005.

SANTI, A. L.; AMADO, T. J. C.; CHERUBIN, M. R.; MARTIN, T. N.; PIRES, J. L.; FLORA, L. P. D.; BASSO, C. J. Análise de componentes principais de atributos químicos e físicos do solo limitantes à produtividade de grãos. **Pesquisa Agropecuária Brasileira**, v.47, n.9, p. 1346-1357, 2012.

SANTOS, A. C.; FERREIRA, D. F. Definição do tamanho amostral usando simulação monte carlo para o teste de normalidade baseado em assimetria e curtose e abordagem univariada. Lavras, **Ciência e Agrotecnologia**, v. 27, n. 2, p. 432-437, 2003.

SANTOS, J. S.; FONTANA, D. C.; SILVA, T. S. F.; RUDORFF, B. F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.18, n.1, p.54-63, 2014.

SANTOS, S.; ZIEGLER, N.; COMERLATO, P. H.; CAPP, E.; NIENOV, O. T. **Modelos lineares generalizados. Modelos lineares generalizados**. In: ____Bioestatística Quantitativa Aplicada. 1ª edição. Porto Alegre, RS, p. 217-231, 2020.

SCHULTZ, B. **Análise de imagens orientada a objetos e amostragem estatística no monitoramento de cana-de-açúcar, milho e soja no estado de São Paulo**.

2016. 210 p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

SHANAHAN, J. F.; SCHEPERS, J. S.; FRANCIS, D. D.; VARVEL, G. E.; WILHELM, W.; TRINGE, J. M.; SCHLEMMER, M. R.; MAJOR, D. **Use of Remotesensing imagery to estimate corn grain yield**. Agronomy Faculty Publications, 2001.

SHAPIRO, S. S.; WILK, M. B. Na analysis of variance test for normality (complete samples). *Biometrika*, **Archival Journals** (JSTOR), v. 52, n.4, p. 591-611, 1965.

SILVA, M. C.; SILVA, J. D. G.; BORGES, E. F. Análises de componentes principais para elaborar índices de desempenho no setor público. **Revista Brasileira de Biometria**, São Paulo, v. 33, n.3, p. 291-309, 2015.

SINGER, J. M.; NOBRE, J. S.; ROCHA, F. M. M. **Análise de dados longitudinais. Versão parcial preliminar**. Departamento de Estatística – Universidade de São Paulo, São Paulo, 2018.

SONG, C.; WOODCOCK, C.E. Monitoring forest succession with multitemporal landsat images: factors of uncertainty. **IEEE Transactions on Geosciences and Remote Sensing**, New York, v.41, n.11, p.280-392, 2003.

SRIPADA, R. P.; HEINIGER, R. W.; WHITE, J. G.; MEIJER, A. D. Aerial color infrared photography for determining early in-season nitrogen requirements in com. **Agronomy Journal**, v. 98, p. 968-977, 2006.

STEVEN, M. The sensitivity of the OSAVI vegetation index to observational parameters. **Remote Sensing of Environment**. v. 63, n. 1, p. 49-60, 1998.

SUGAWARA, L. M. **Variação interanual da produtividade agrícola da cana-de-açúcar por meio de um modelo agrônômico**. 2010, p. 114. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010.

SUGAWARA, L. M.; RUDORFF, B. F. T.; ADAMI, M. Viabilidade de uso de imagens do Landsat em mapeamento de área cultivada com soja no Estado do Paraná. **Pesquisa Agropecuária Brasileira**, Brasília, v.43, n.12, p.1777-1783, 2008.

TABACHNICK, B.; FIDELL, L. S. Using multivariate statistics (3a ed.). New York: **Harper Collins**, 1996.

TAIPALE, E, Sentera. NDVI vs. NDRE: What's the Difference? (2018). Disponível em: Acesso em: 28 jan 2019.

TANAJURA, E. L. X.; ANTUNES, M. A.; UBERTI, M. A. Avaliação de Índices de Vegetação para a Discriminação de Alvos Agrícolas em Imagens de Satélites, Simpósio Brasileiro de Sensoriamento Remoto, 12, **Anais...**Goiânia, Instituto Nacional de Pesquisas Espaciais, Goiânia, Brasil. Abr. 2005.

TAVAKOLI, H.; MOHTASEBI, S. S.; ALIMARDANI, R.; GEBBERS, S. Evaluation of different sensing approaches concerning to nondestructive estimation of leaf area index (lai) for winter wheat, **international journal on smart sensing and intelligent systems**. Vol. 7 no. 1, march, 2014.

TIMM, N. H. Applied multivariate analysis. New York: **Springer-Verlag**, p. 519, 2002.

TORMAN, V. B.; COSTER, R.; RIBOLDI, J. Normalidade de variáveis: métodos de verificação e comparação de alguns testes não-paramétricos por simulação. **Revistas HCPA**. Porto Alegre, v.32, n.2, p. 227-234, 2012.

VARELLA, C. A. A. **Análise Multivariada Aplicada as Ciências Sociais – Análise de Componentes Principais**. Universidade Federal Rural do Rio de Janeiro, 2008.

VYGODSKAYA, N. N.; GORSHKOVA, I.; FADEYEVA, Y. E. V. Theoretical estimates of sensitivity in some vegetation indices to variation in the canopy condition. **International Journal of Remote Sensing**, v10, n12, p.1857-72, 1989.

WALDNER, F.; CANTO, G. S.; DEFOURNY, P. Automated annual cropland mapping using knowledge-based temporal features. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 110, p. 1–13, dez. 2015.

WEIERS, S., BOCK, M., WISSEN, M., ROSSNER, G. Mapping and indicator approaches for the assessment of habitats at diferente scales using remote sensing and GIS methods. **Landscape and urban planning**, v. 67, p. 43-65, 2004.

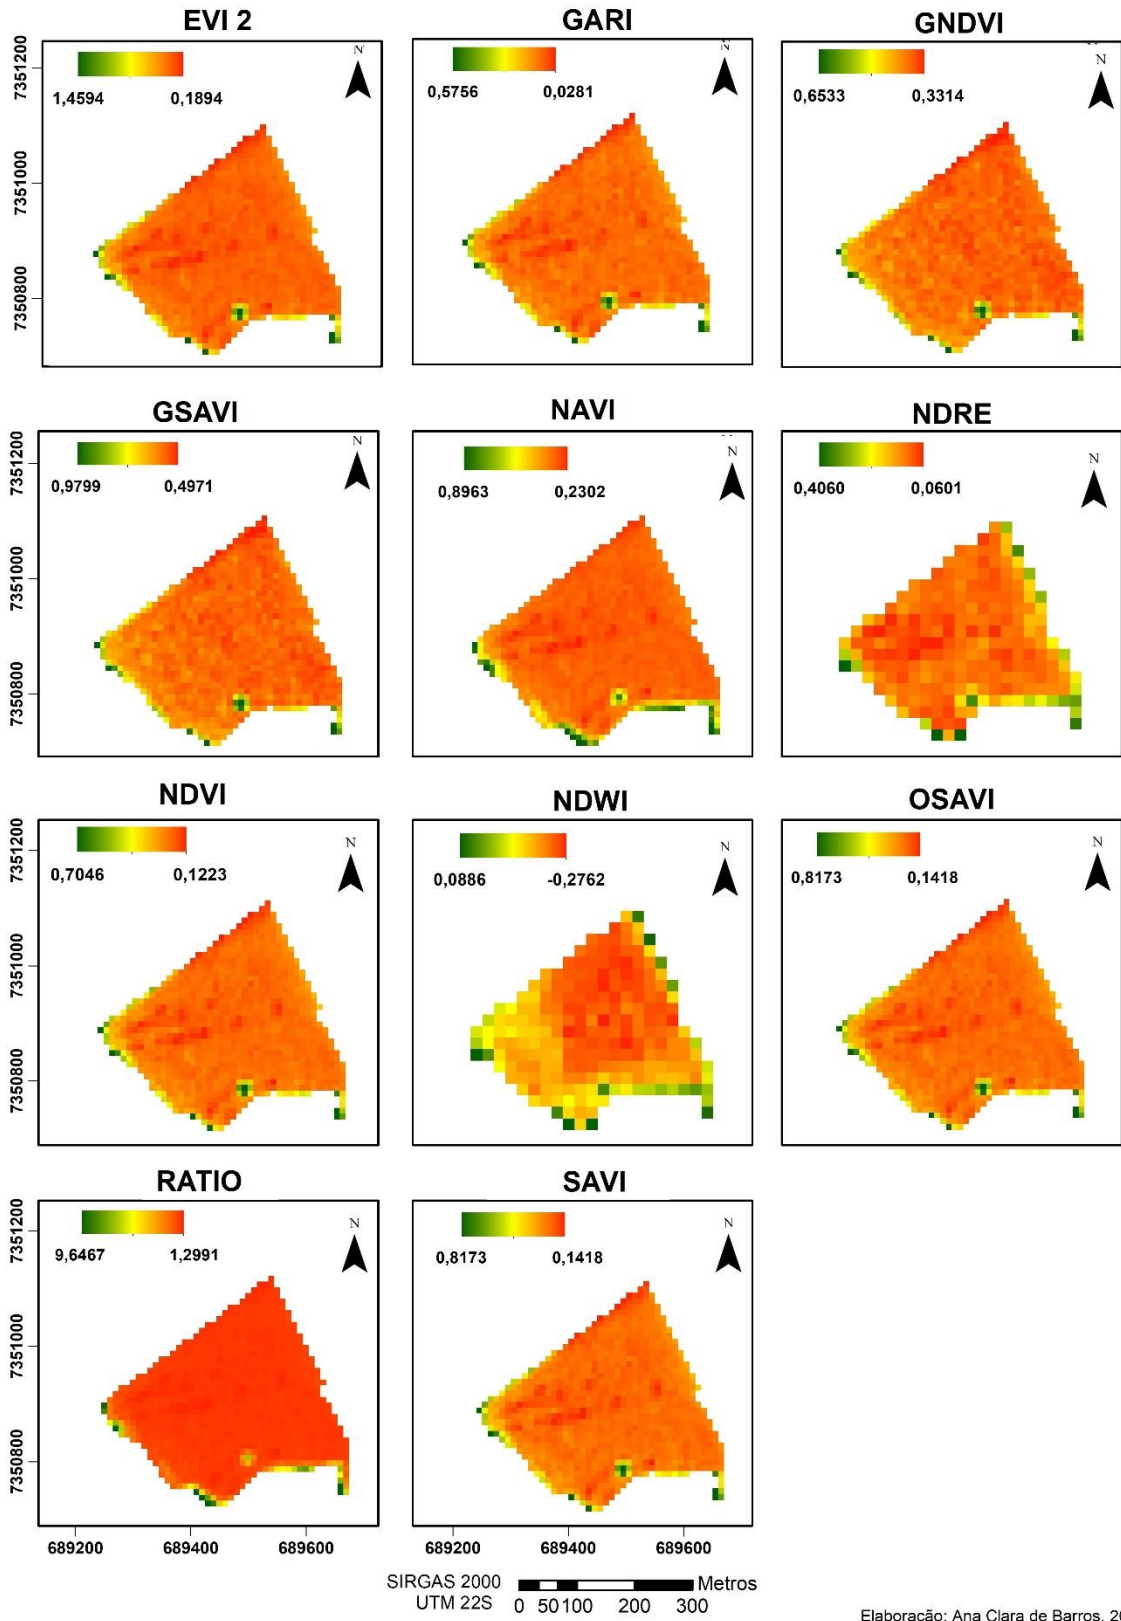
WILCOXON, F. Individual comparisons by ranking methods. **Biometrics Bulletin**, v.1, n.6, p. 80-83, 1945.

XAVIER, L. H. **Modelos univariado e multivariado para análise de medidas repetidas e verificação da acurácia do modelo univariado por meio de simulação**. 2000. Dissertação (Mestrado em Estatística e Experimentação Agronômica) – Escola Superior de Agricultura Luiz de Queiroz. Universidade de São Paulo, São Paulo, 2000.

ZHANGYAN, J.; HUETE, A. R.; YOUNGWOOK, K.; KAMEL, D. 2 band enhanced vegetation index without a blue band and its application to AVHRR data. SPIE 6679, **Remote Sensing and Modeling of Ecosystems for Sustainability IV**, V Proceedings...,67905 (October 09,2007), 2007.

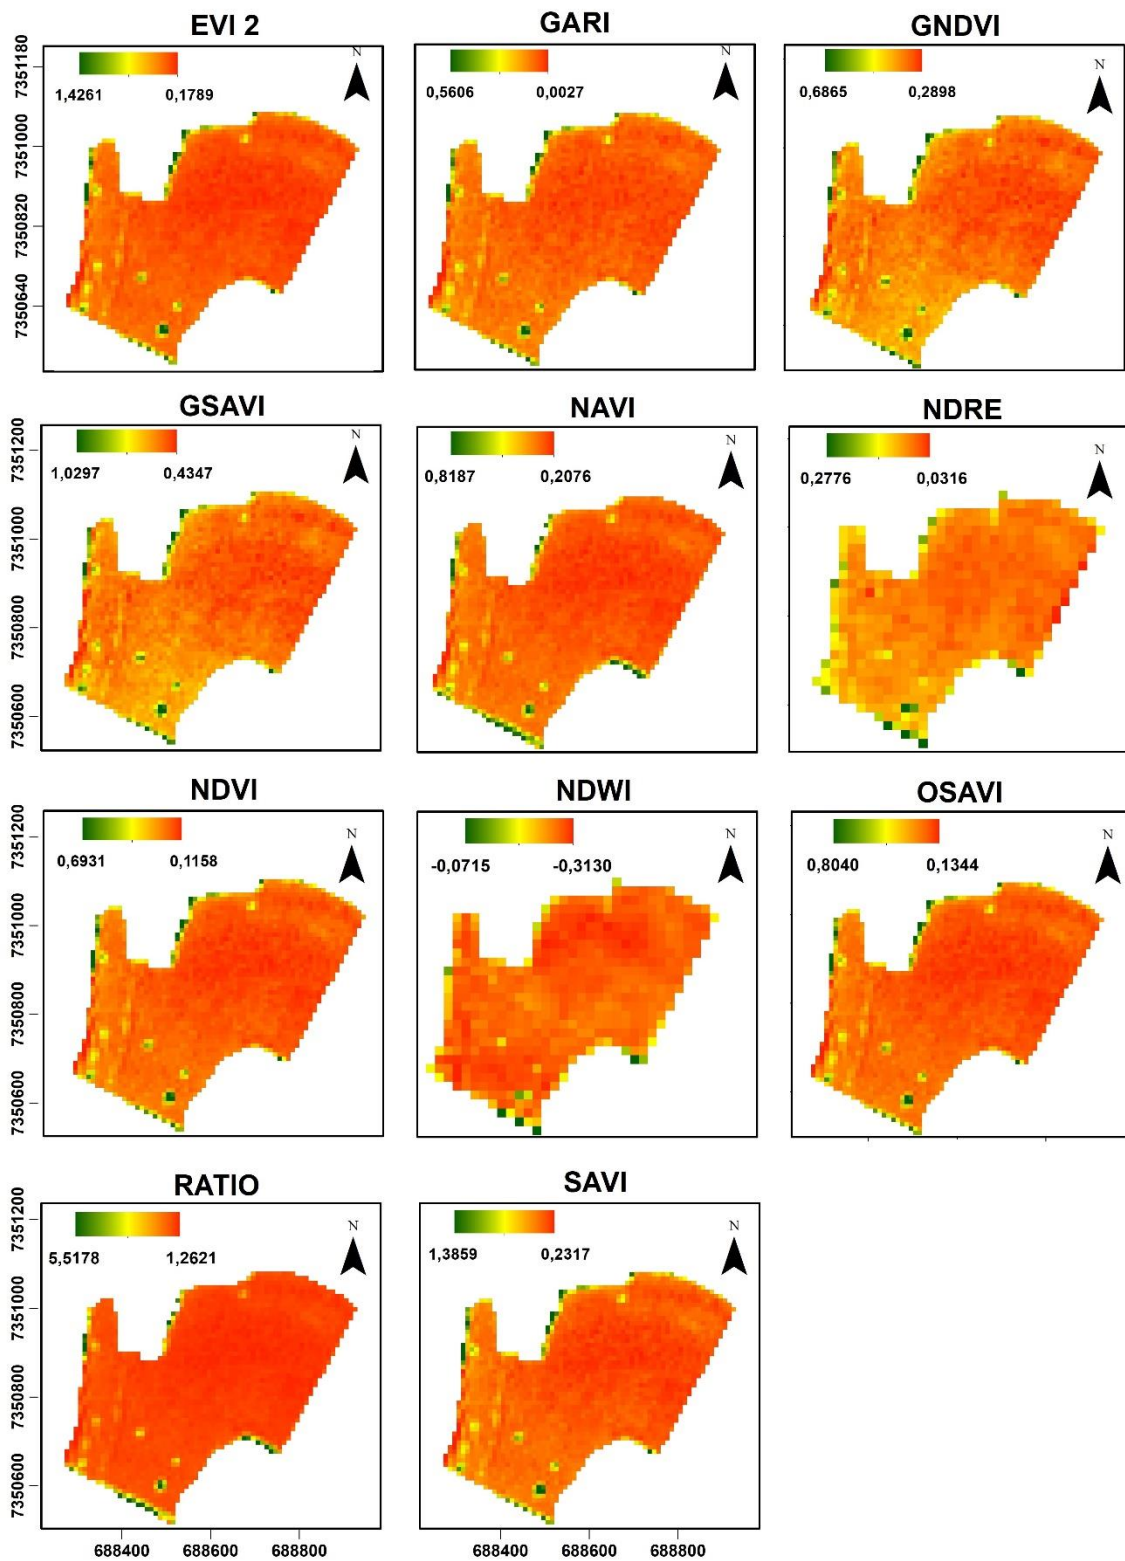
APÊNDICE A - Índices calculados para o talhão 1 do mês de outubro de 2019

TALHÃO 1 - OUTUBRO 2019



APÊNDICE B - Índices calculados para o talhão 2 do mês de outubro de 2019

TALHÃO 2 - OUTUBRO 2019

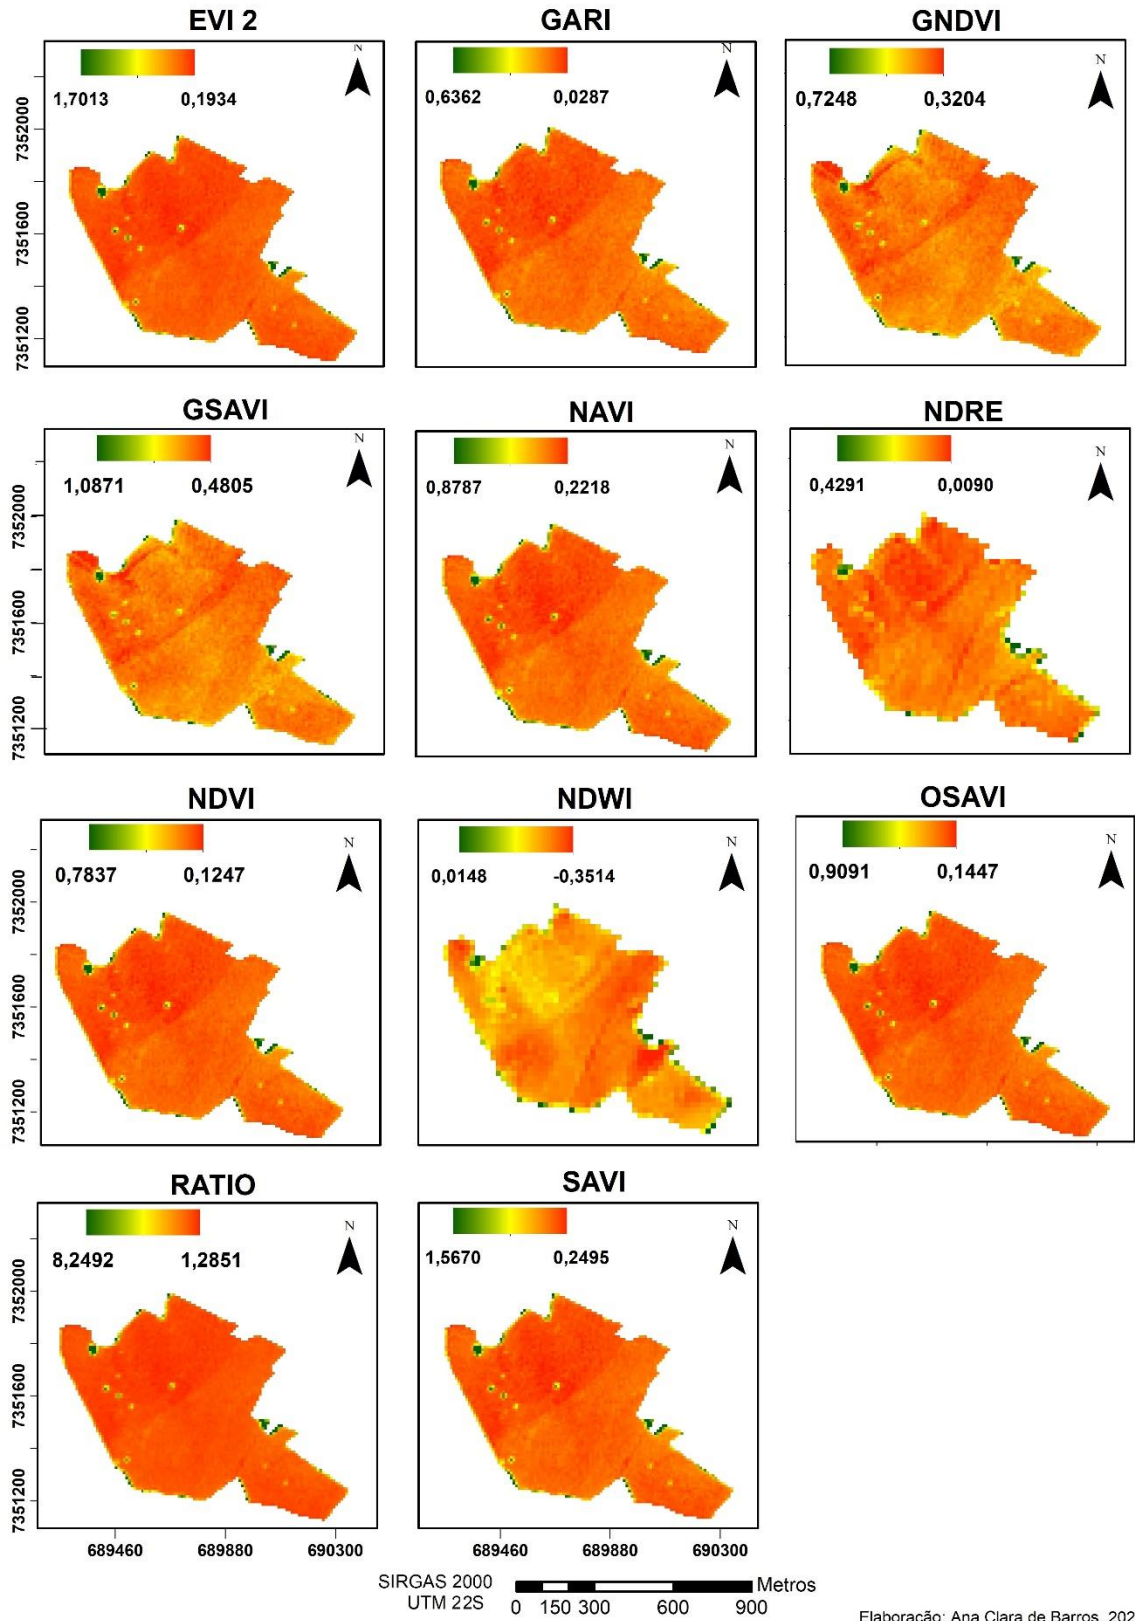


SIRGAS 2000 UTM 22S 0 80 160 320 480 Metros

Elaboração: Ana Clara de Barros, 2021.

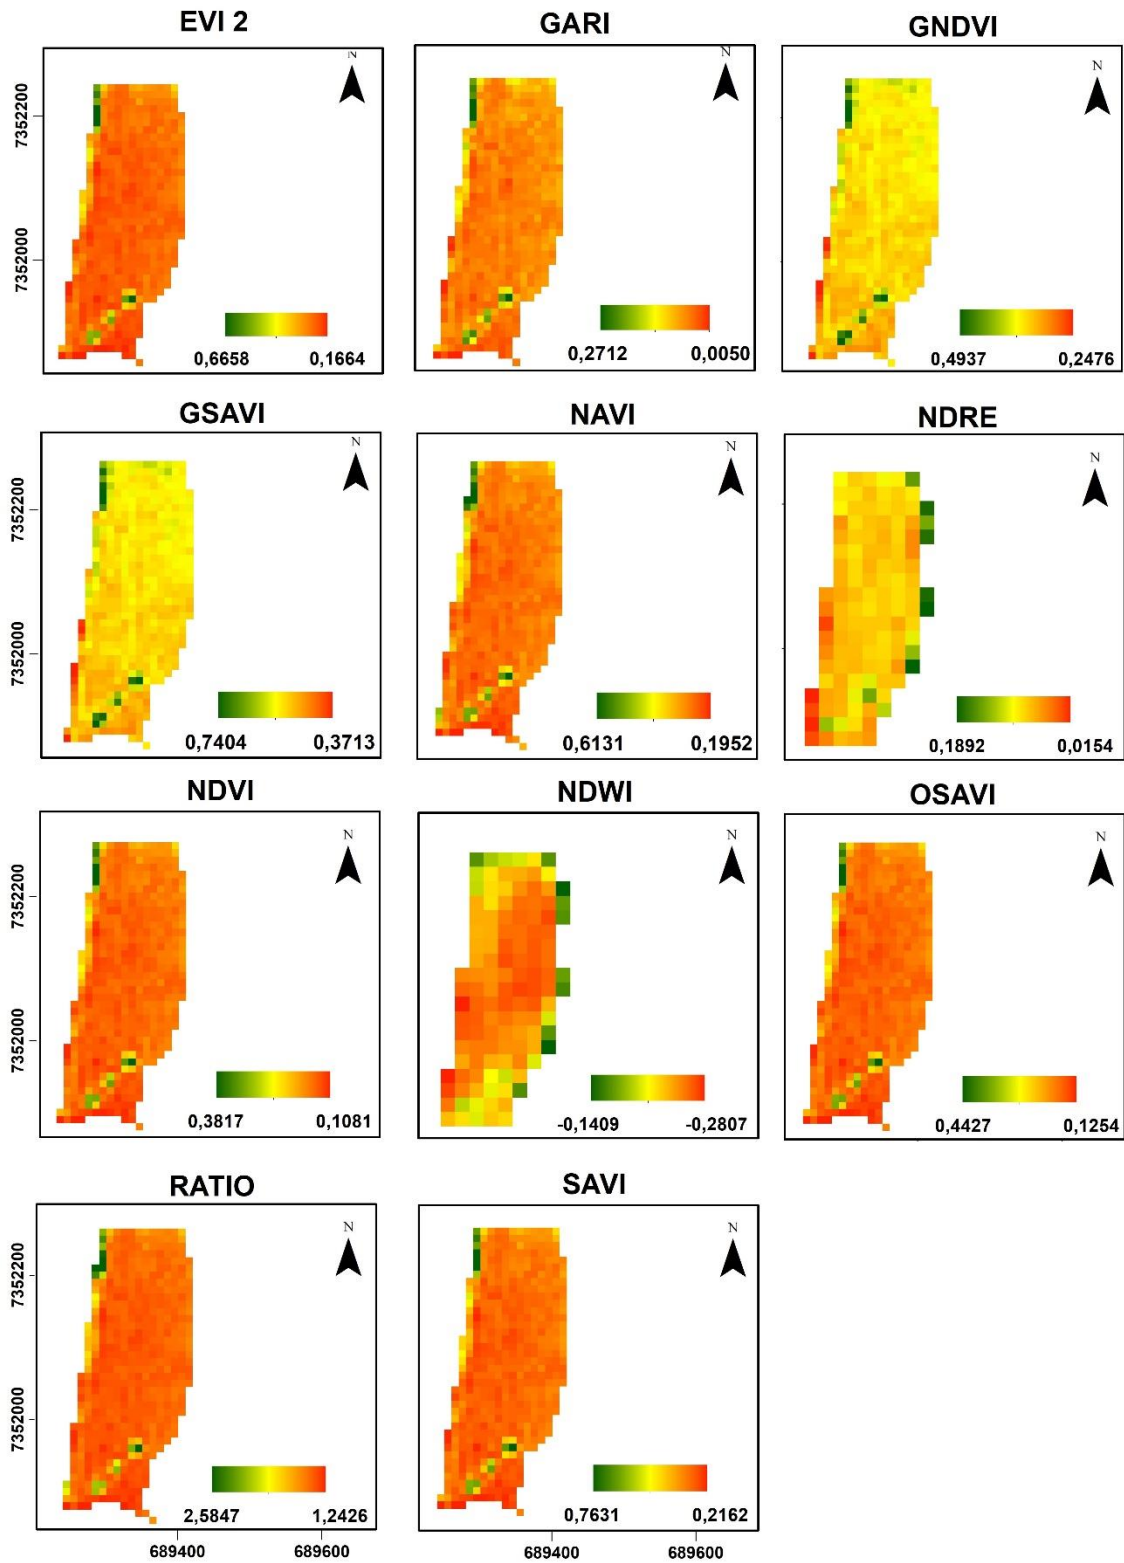
APÊNDICE C - Índices calculados para o talhão 3 do mês de outubro de 2019

TALHÃO 3 - OUTUBRO 2019



APÊNDICE D - Índices calculados para o talhão 4 do mês de outubro de 2019

TALHÃO 4 - OUTUBRO 2019

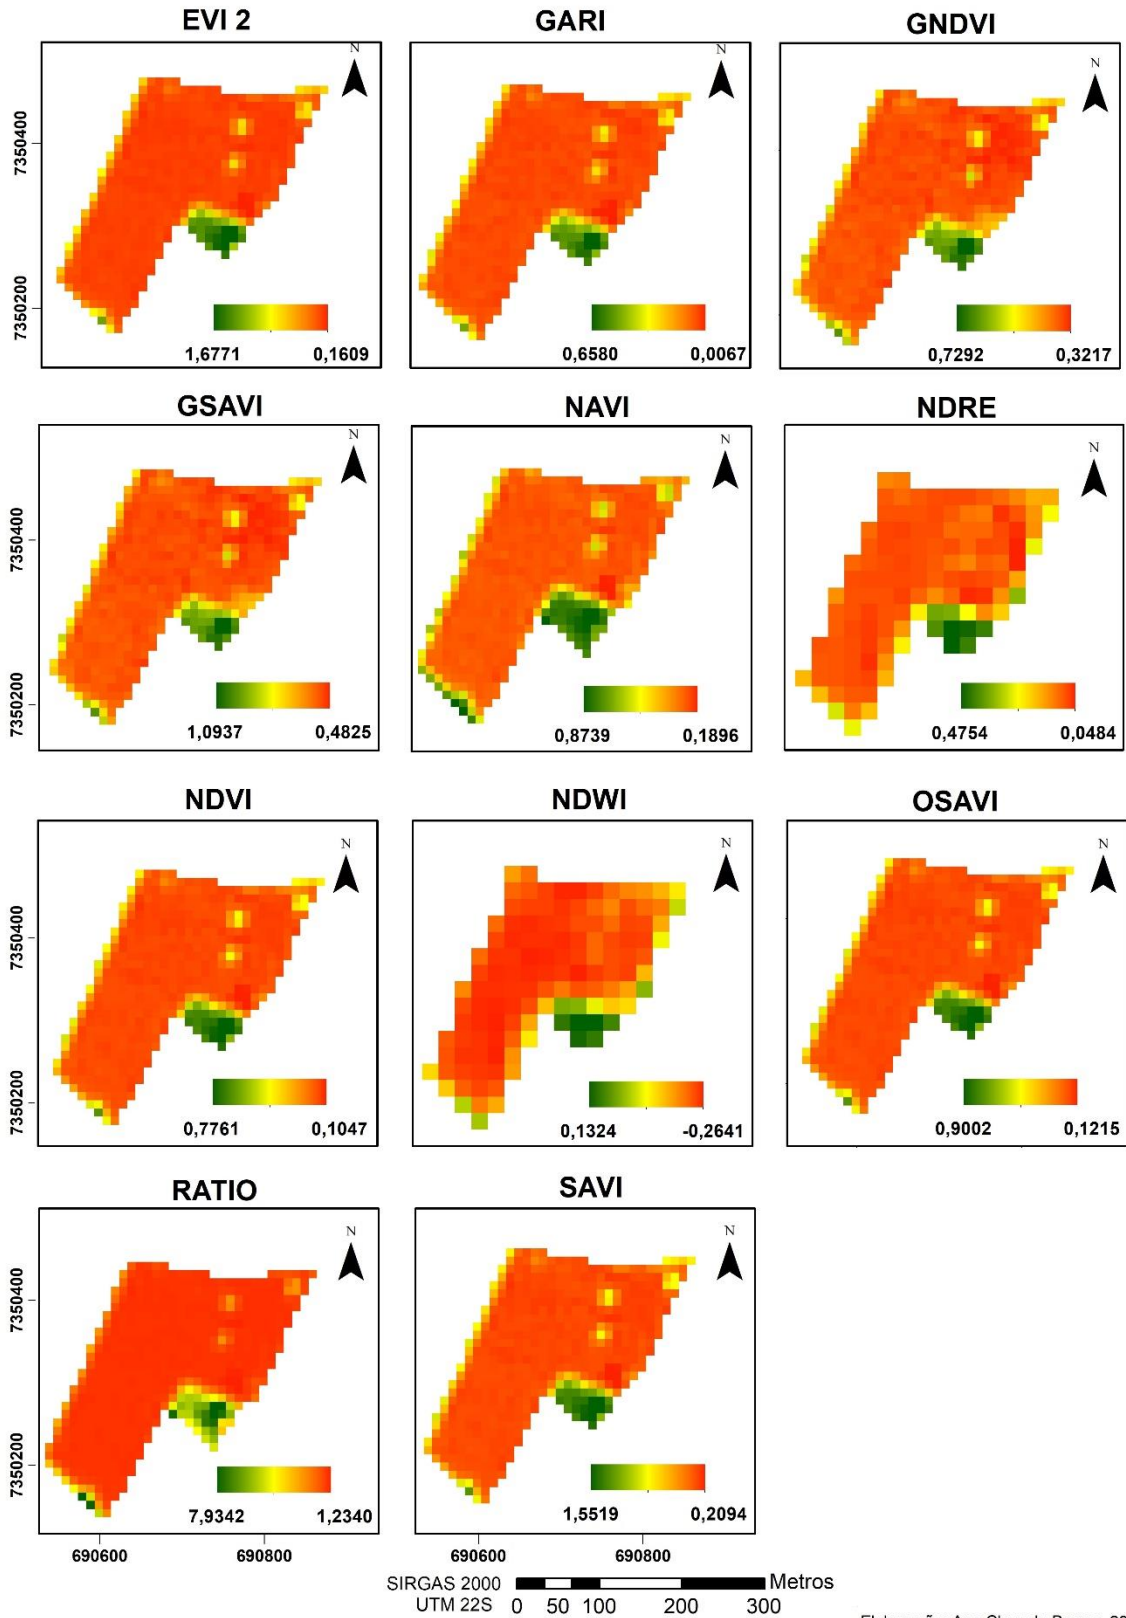


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

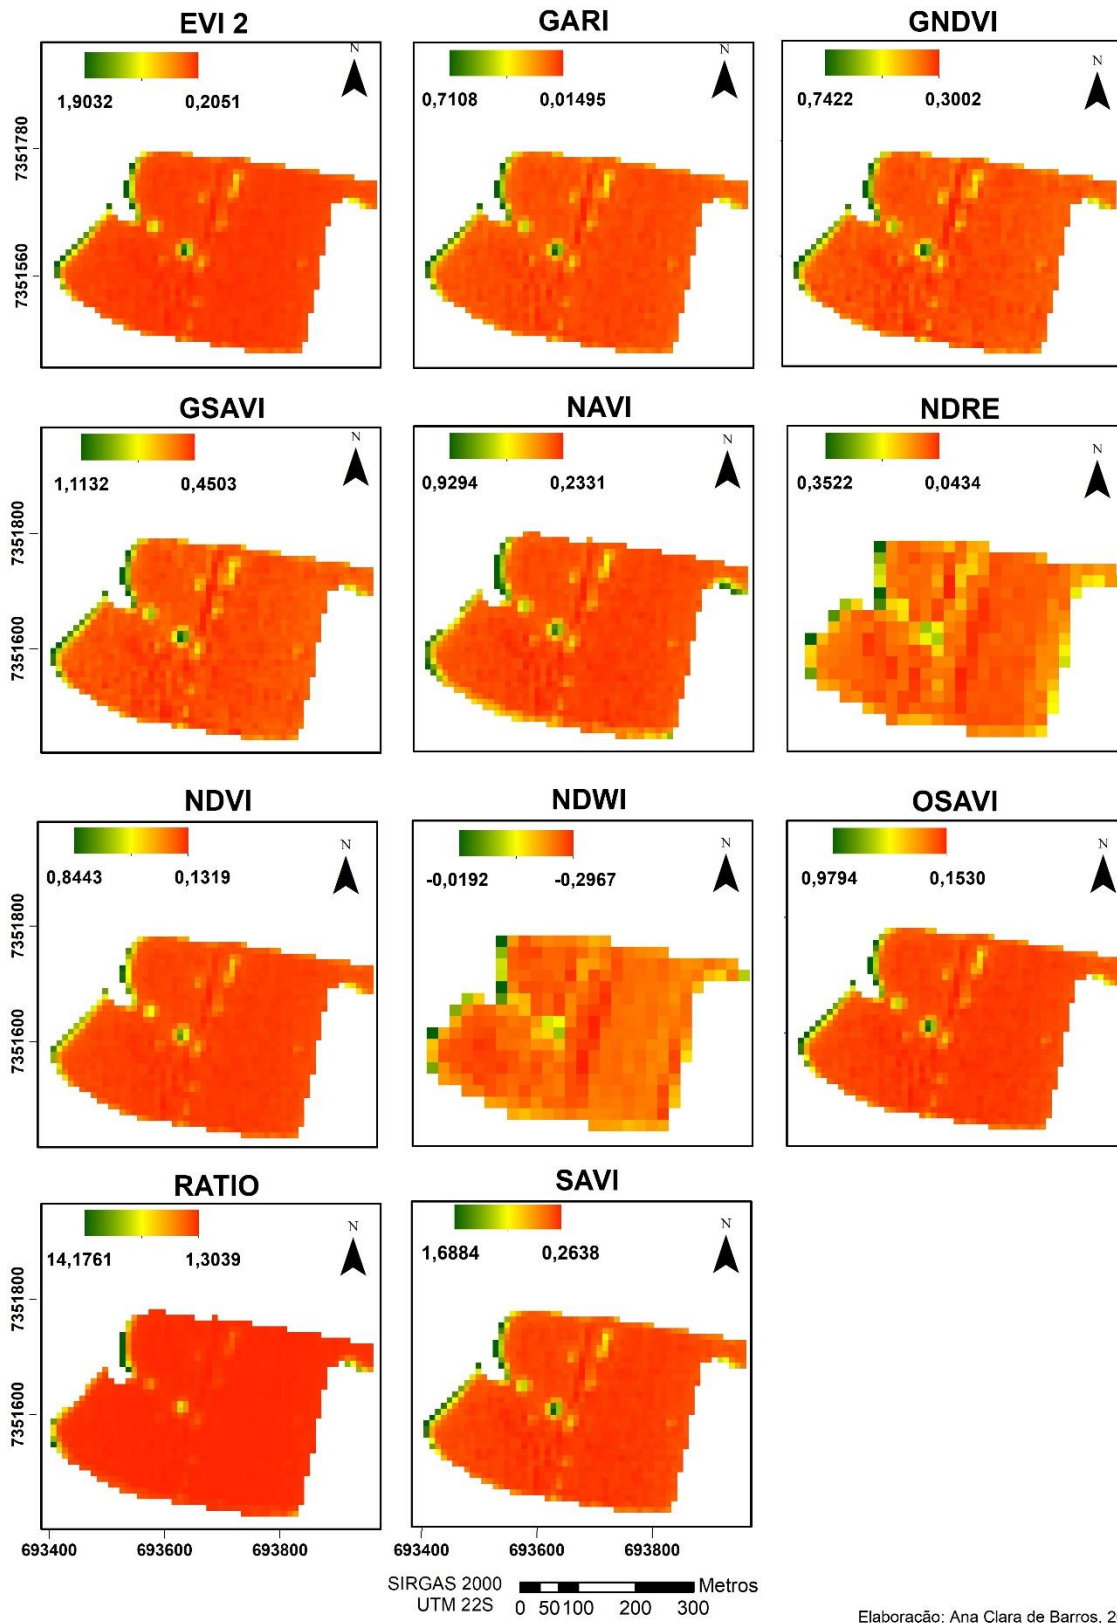
APÊNDICE E - Índices calculados para o talhão 5 do mês de outubro de 2019

TALHÃO 5 - OUTUBRO 2019



APÊNDICE F - Índices calculados para o talhão 6 do mês de outubro de 2019

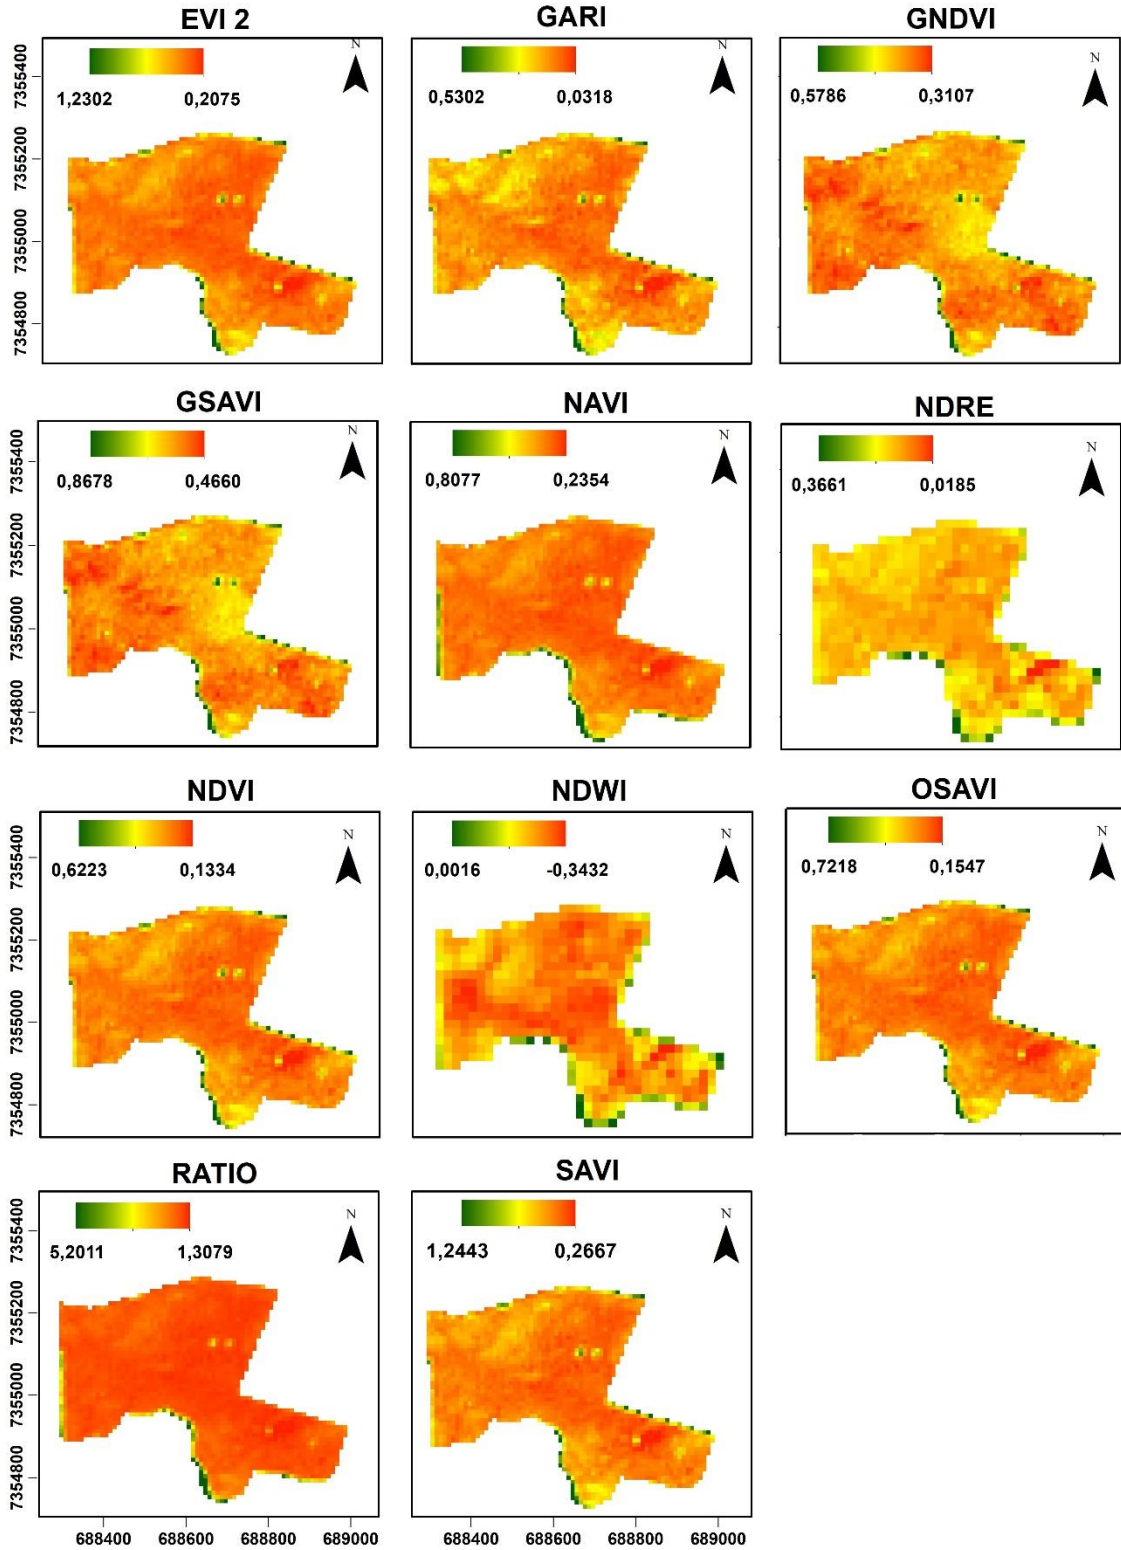
TALHÃO 6 - OUTUBRO 2019



Elaboração: Ana Clara de Barros, 2021.

APÊNDICE G - Índices calculados para o talhão 7 do mês de outubro de 2019

TALHÃO 7 - OUTUBRO 2019

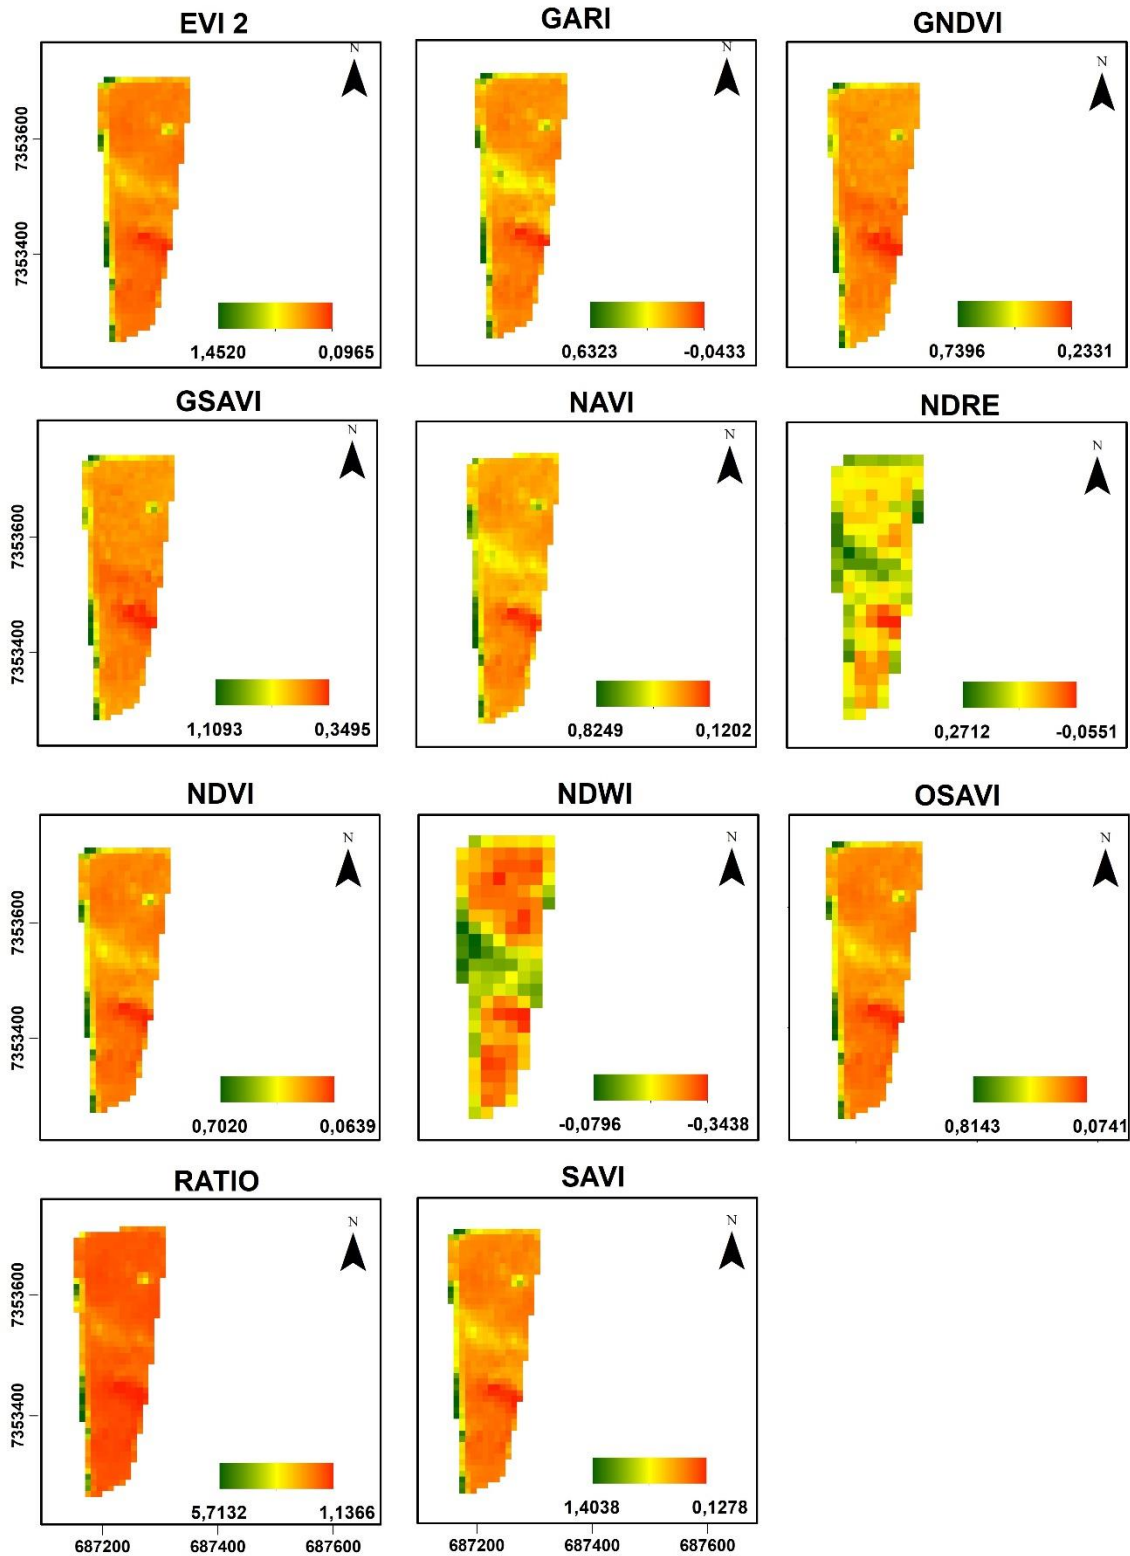


SIRGAS 2000 UTM 22S 0 100 200 400 600 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE H - Índices calculados para o talhão 8 do mês de outubro de 2019

TALHÃO 8 - OUTUBRO 2019

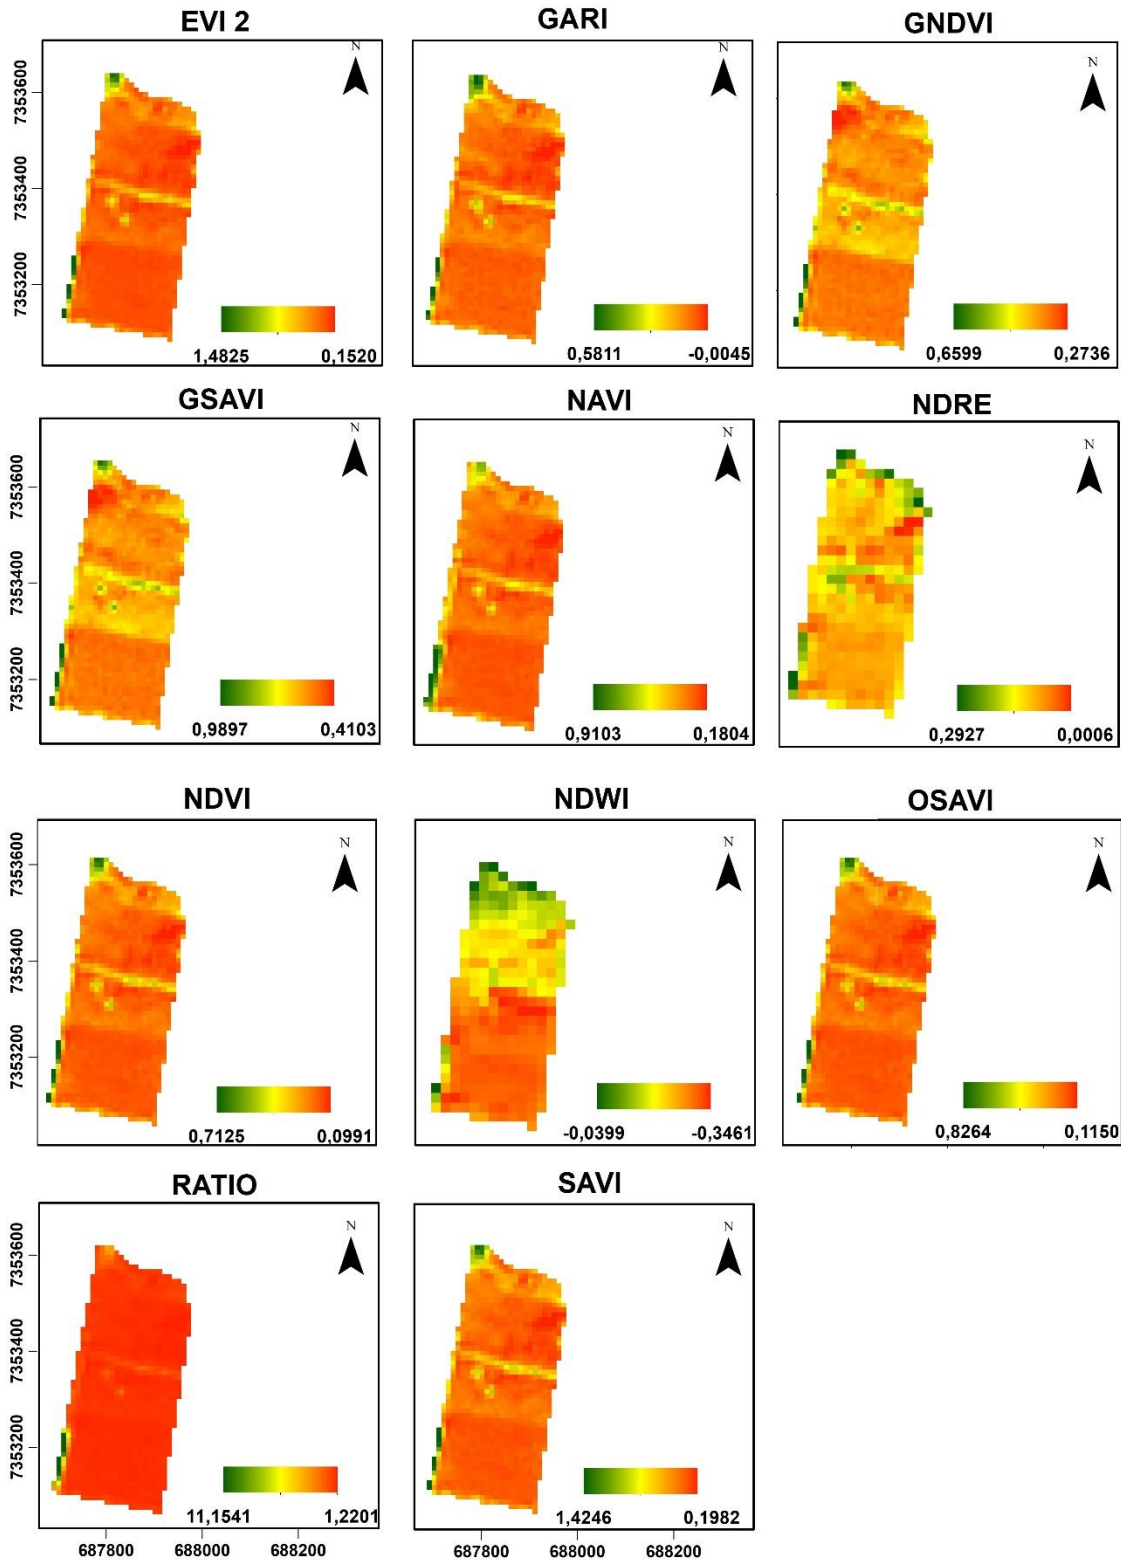


SIRGAS 2000 UTM 22S 0 65 130 260 390 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE I - Índices calculados para o talhão 9 do mês de outubro de 2019

TALHÃO 9 - OUTUBRO 2019

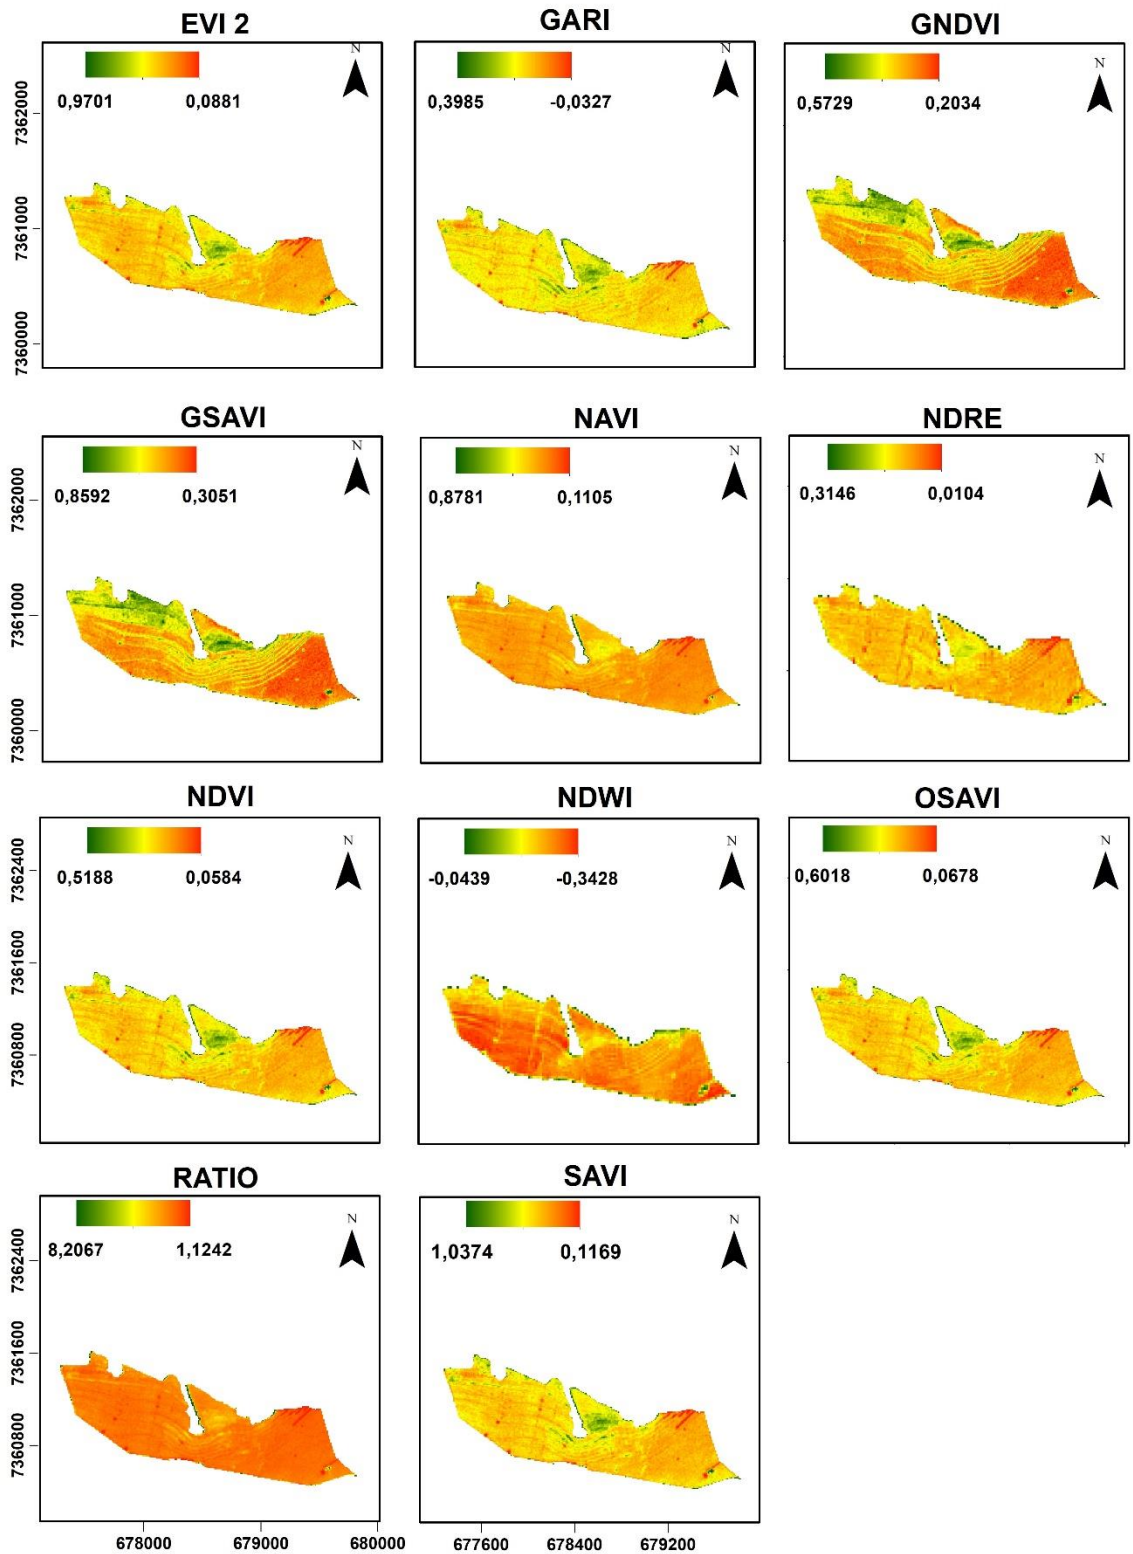


SIRGAS 2000 UTM 22S 0 75 150 300 450 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE J - Índices calculados para o talhão 10 do mês de outubro de 2019

TALHÃO 10 - OUTUBRO 2019

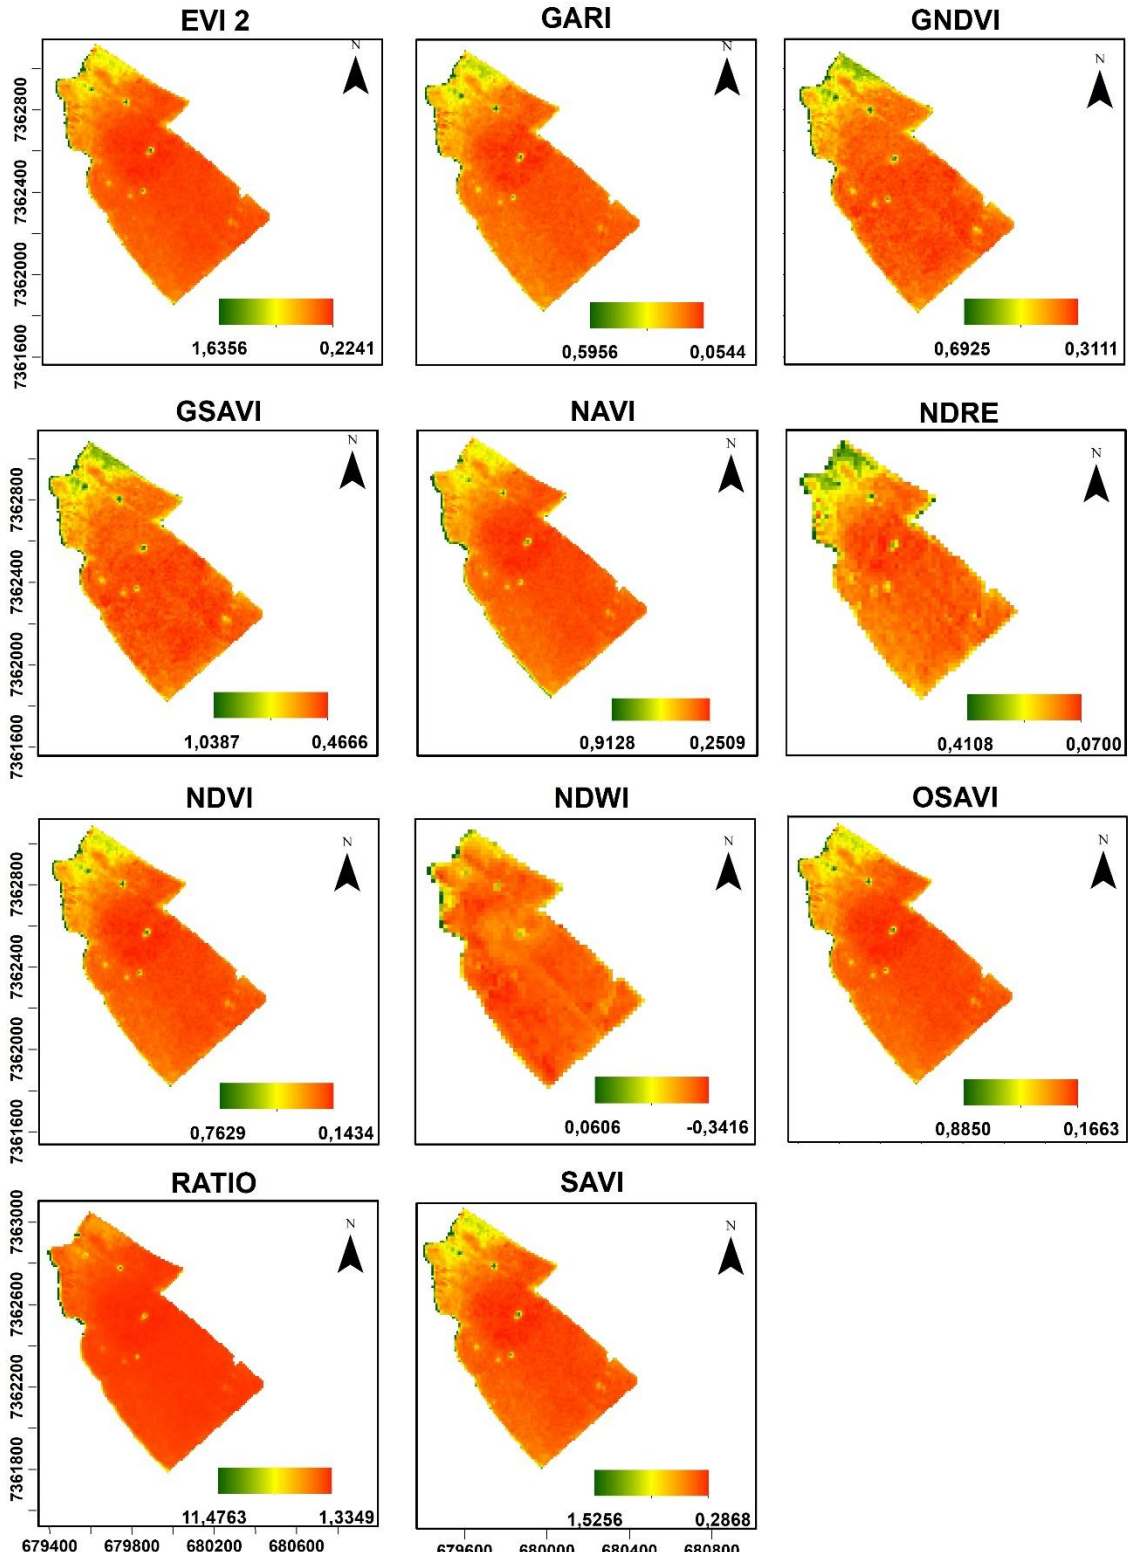


SIRGAS 2000 UTM 22S 0 300600 1.200 1.800 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE K - Índices calculados para o talhão 11 do mês de outubro de 2019

TALHÃO 11 - OUTUBRO 2019

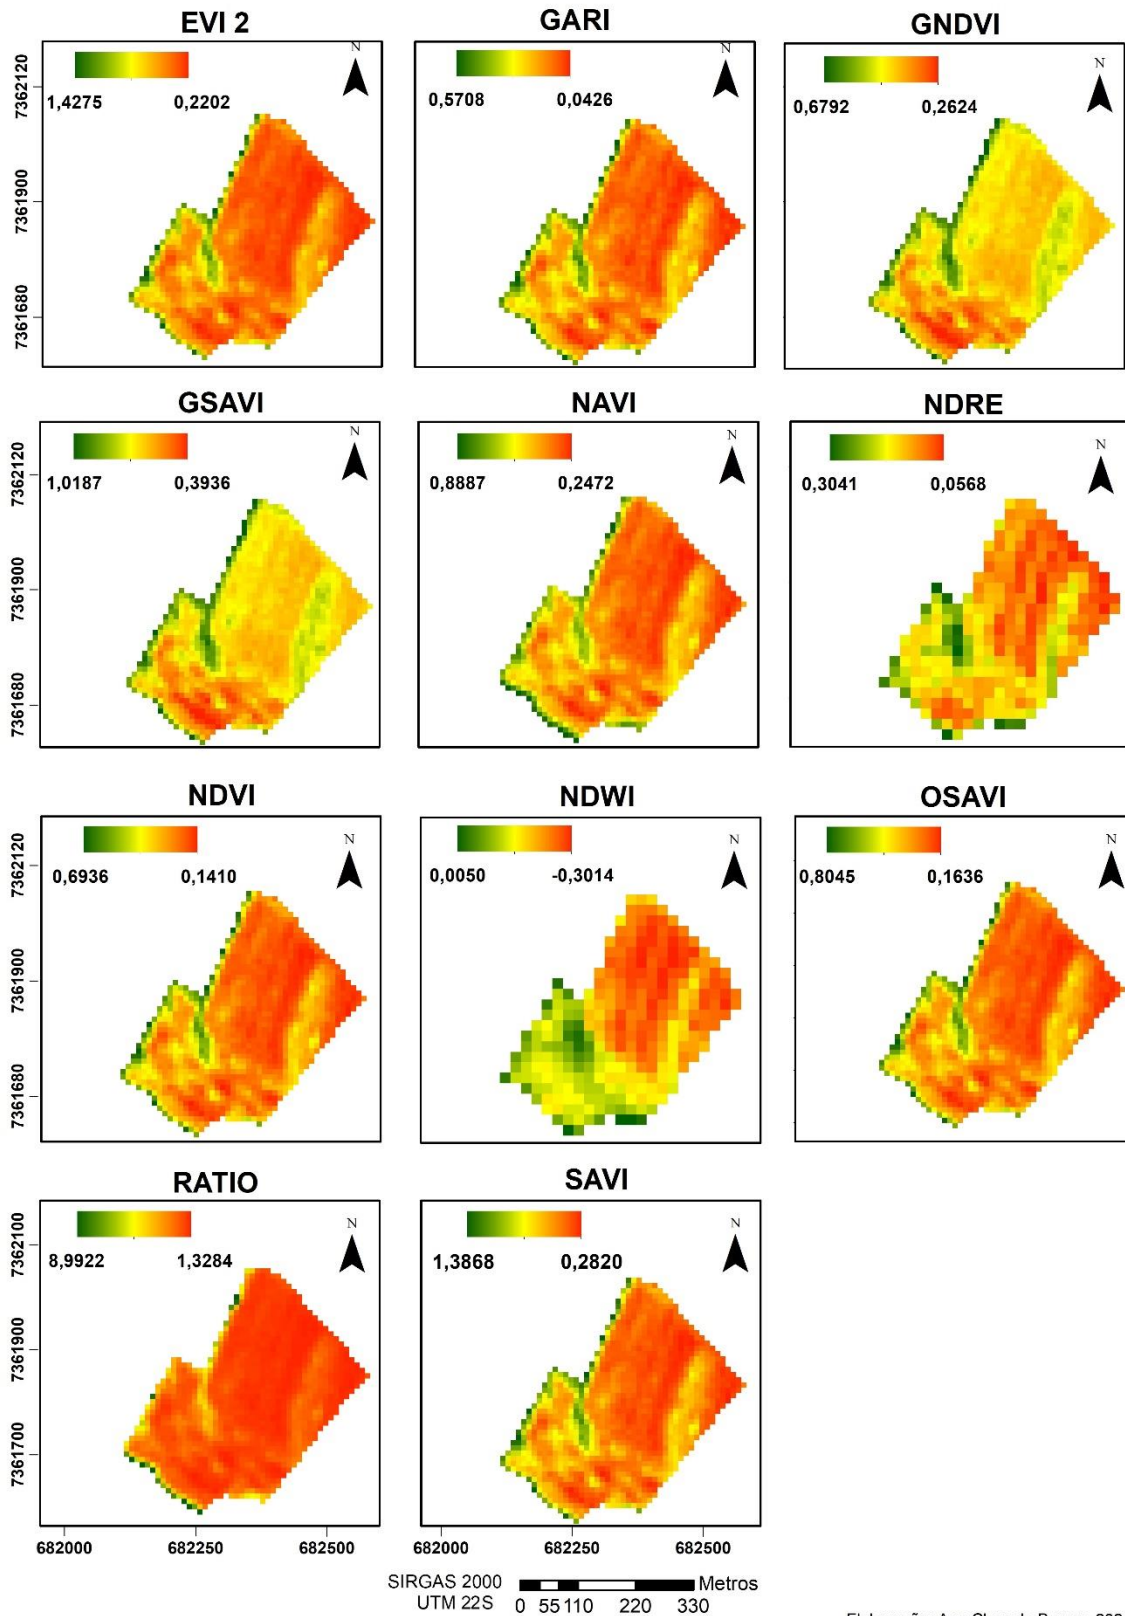


SIRGAS 2000 UTM 22S 0 205 410 820 1.230 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE L - Índices calculados para o talhão 12 do mês de outubro de 2019

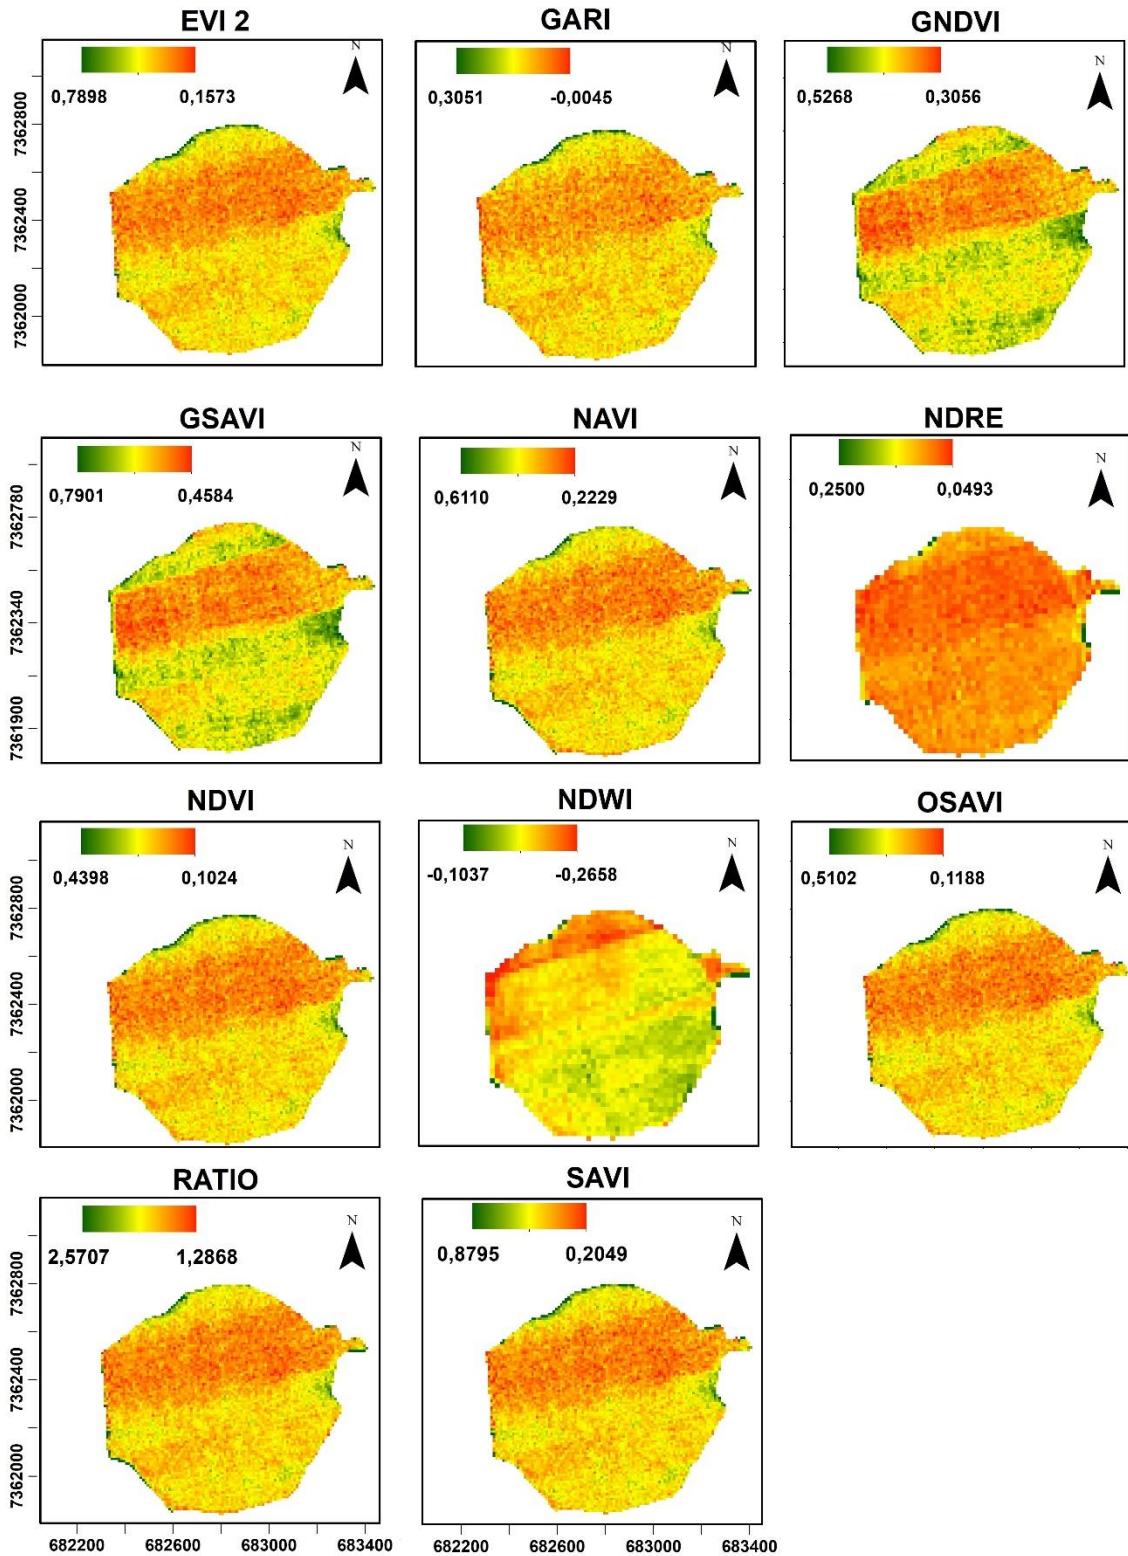
TALHÃO 12 - OUTUBRO 2019



Elaboração: Ana Clara de Barros, 2021.

APÊNDICE M - Índices calculados para o talhão 13 do mês de outubro de 2019

TALHÃO 13 - OUTUBRO 2019

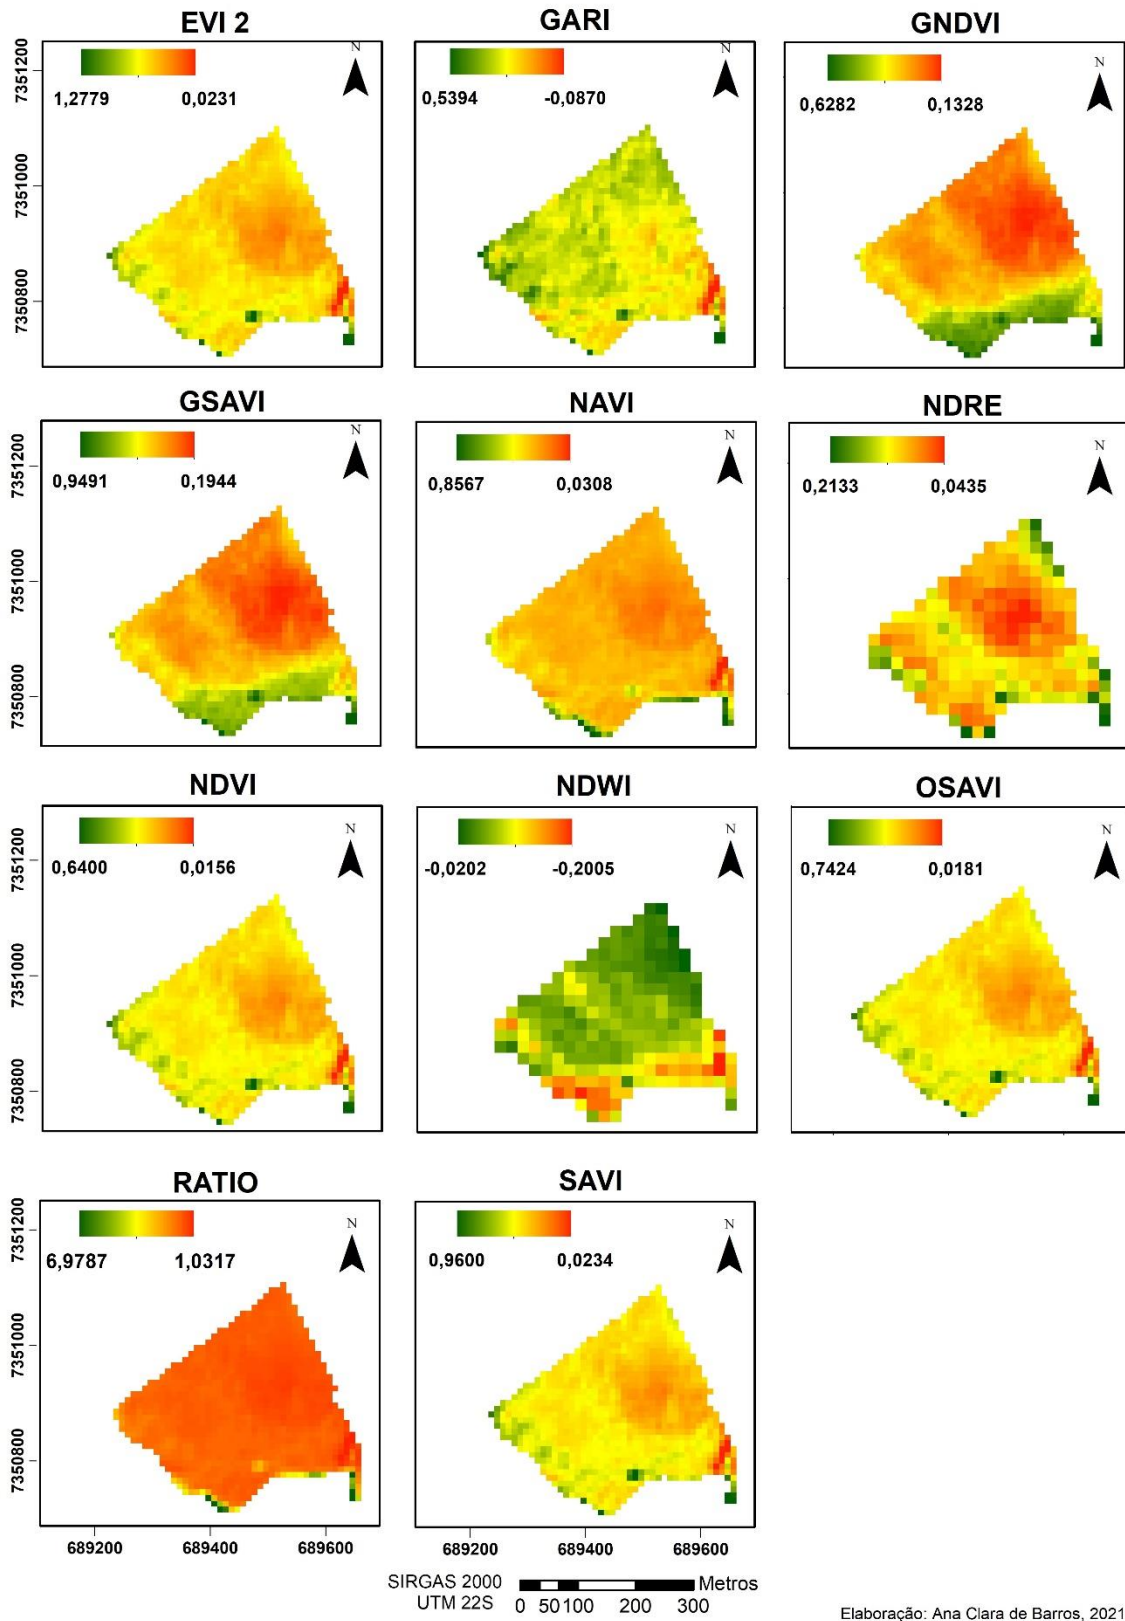


SIRGAS 2000 UTM 22S 0 180 360 720 1.080 Metros

Elaboração: Ana Clara de Barros, 2021.

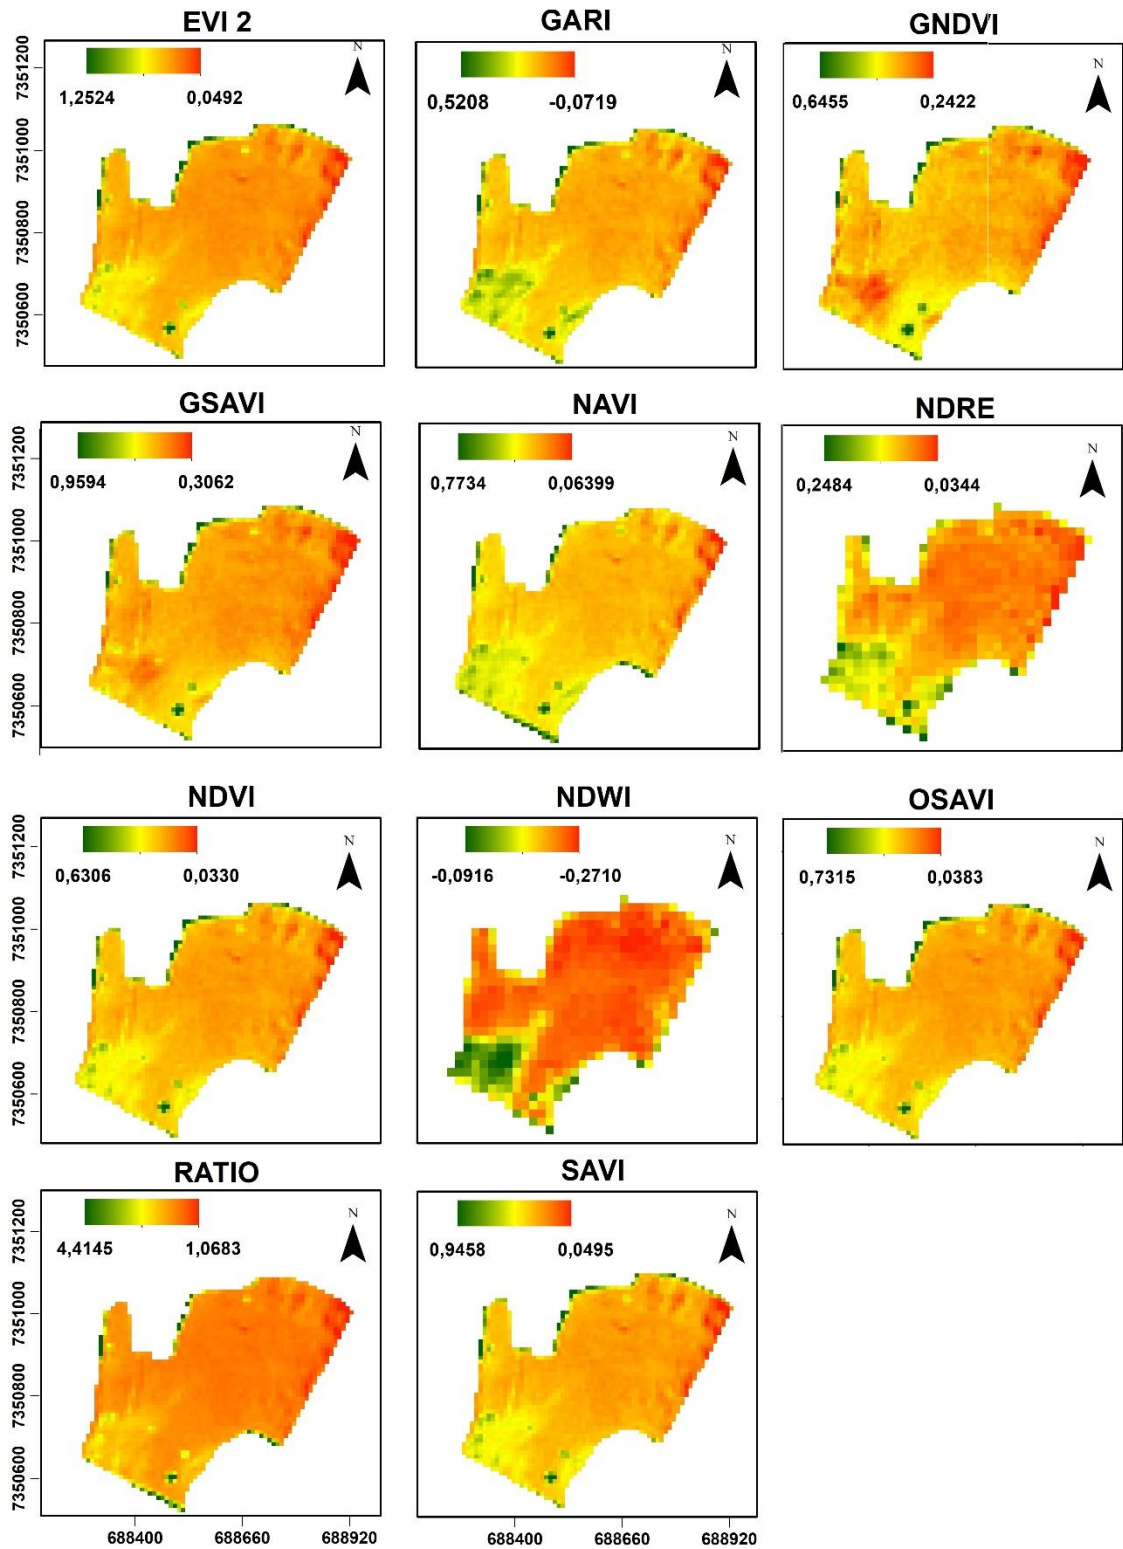
APÊNDICE N - Índices calculados para o talhão 1 do mês de novembro de 2019

TALHÃO 1 - NOVEMBRO 2019



APÊNDICE O - Índices calculados para o talhão 2 do mês de novembro de 2019

TALHÃO 2 - NOVEMBRO 2019

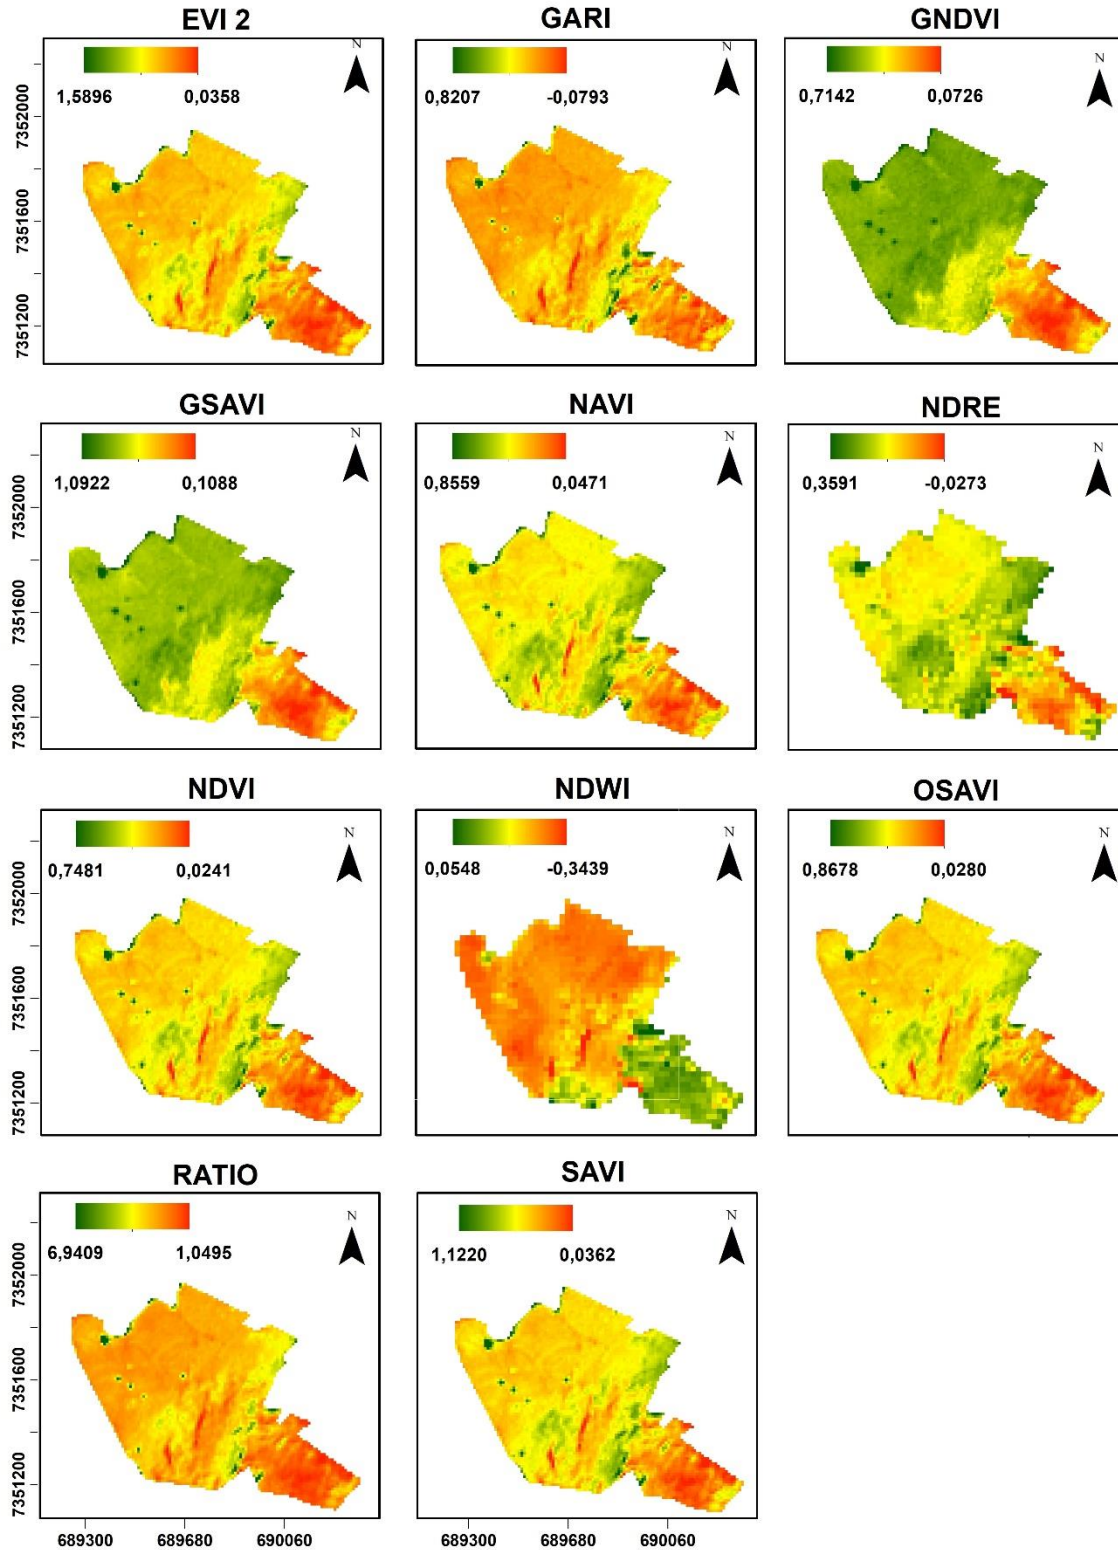


SIRGAS 2000 UTM 22S 0 80 160 320 480 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE P - Índices calculados para o talhão 3 do mês de novembro de 2019

TALHÃO 3 - NOVEMBRO 2019

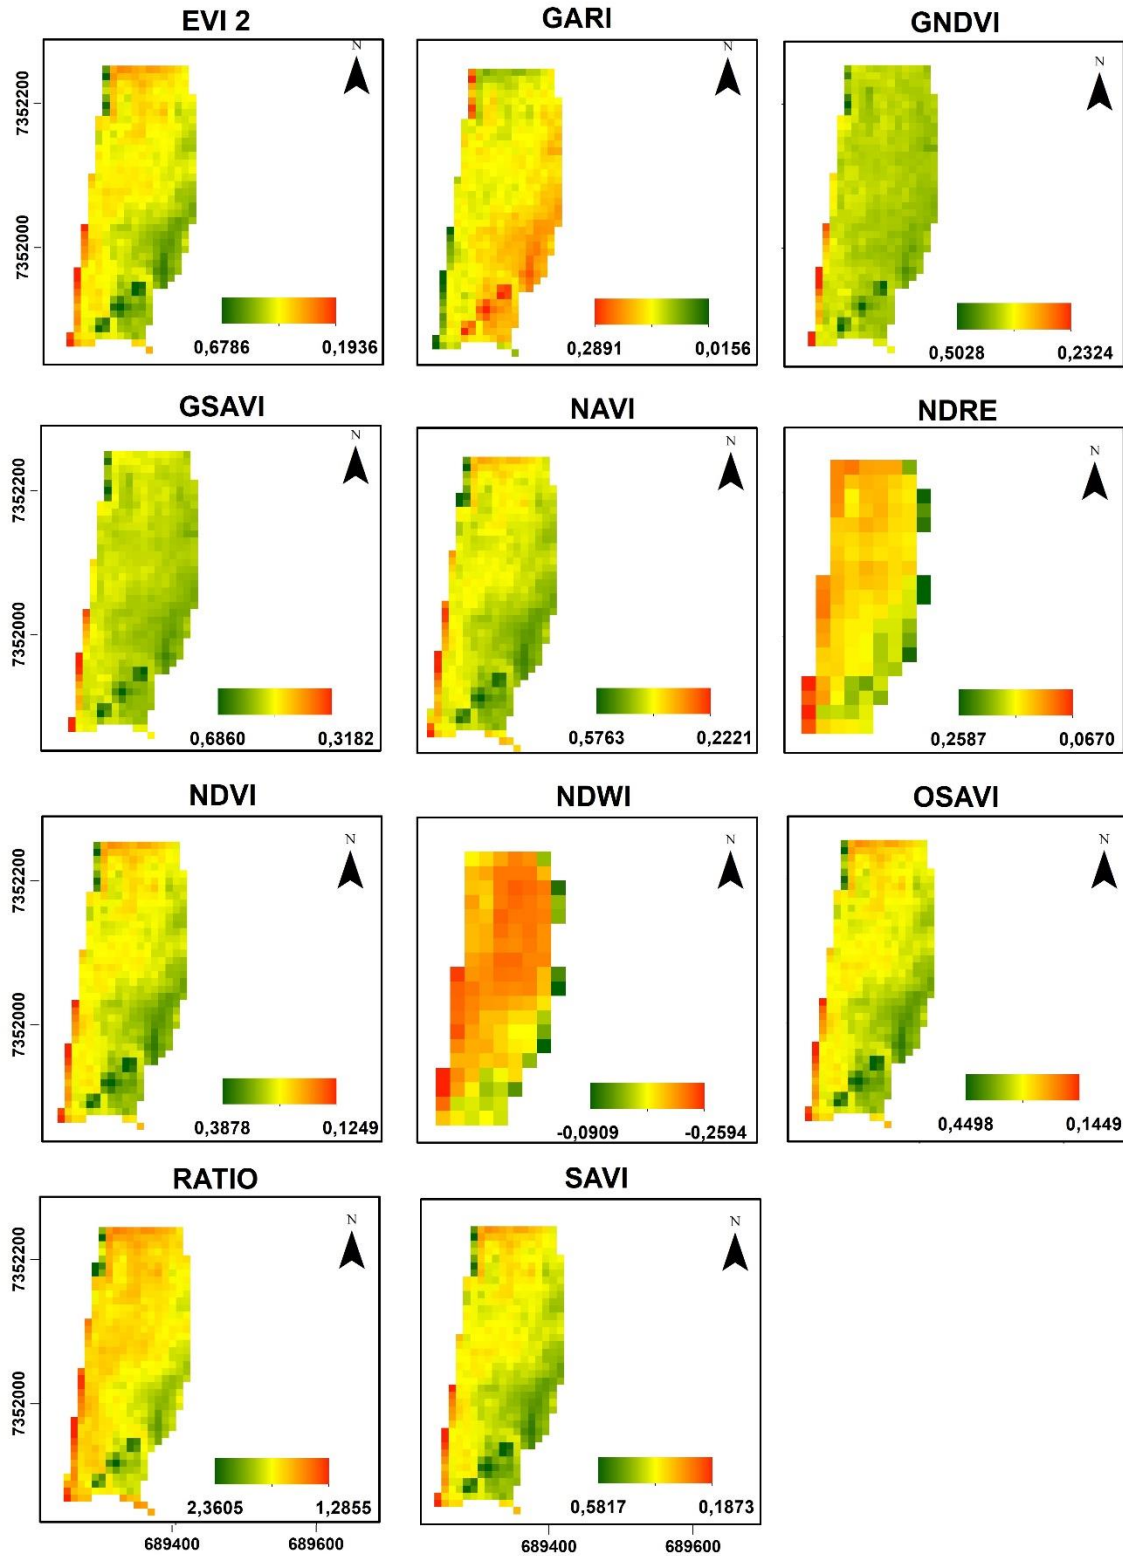


SIRGAS 2000 UTM 22S 0 150 300 600 900 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE Q - Índices calculados para o talhão 4 do mês de novembro de 2019

TALHÃO 4 - NOVEMBRO 2019

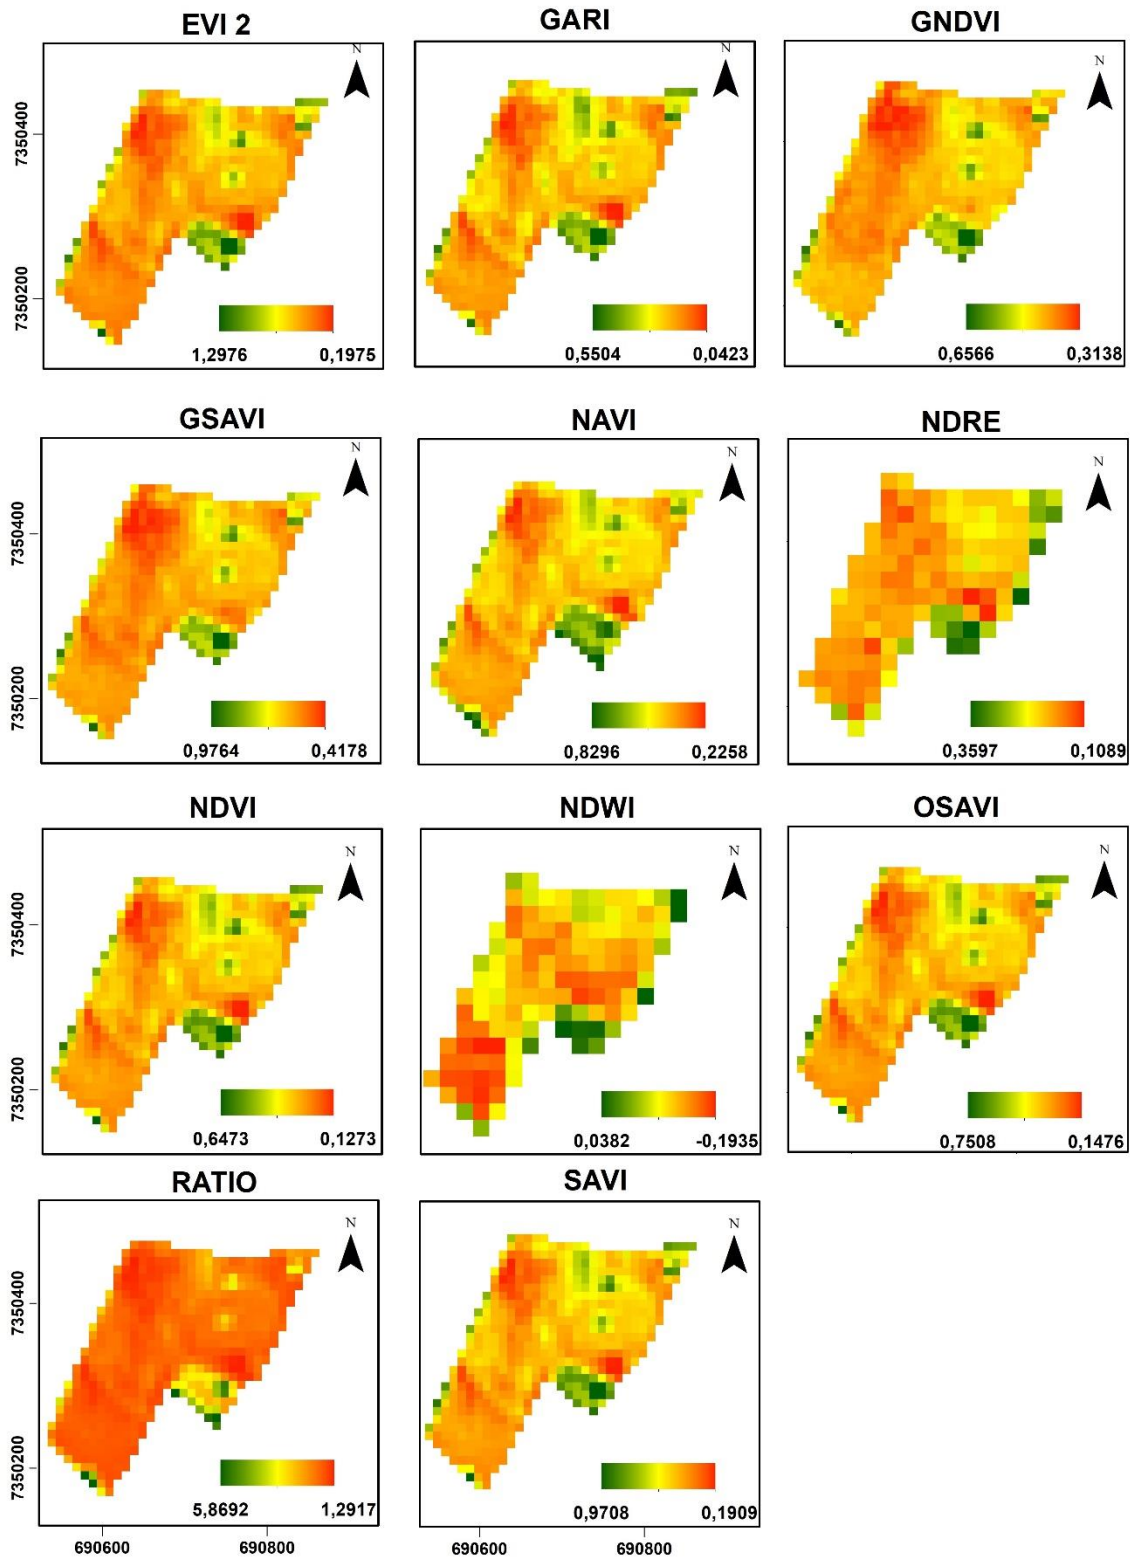


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE R - Índices calculados para o talhão 5 do mês de novembro de 2019

TALHÃO 5 - NOVEMBRO 2019

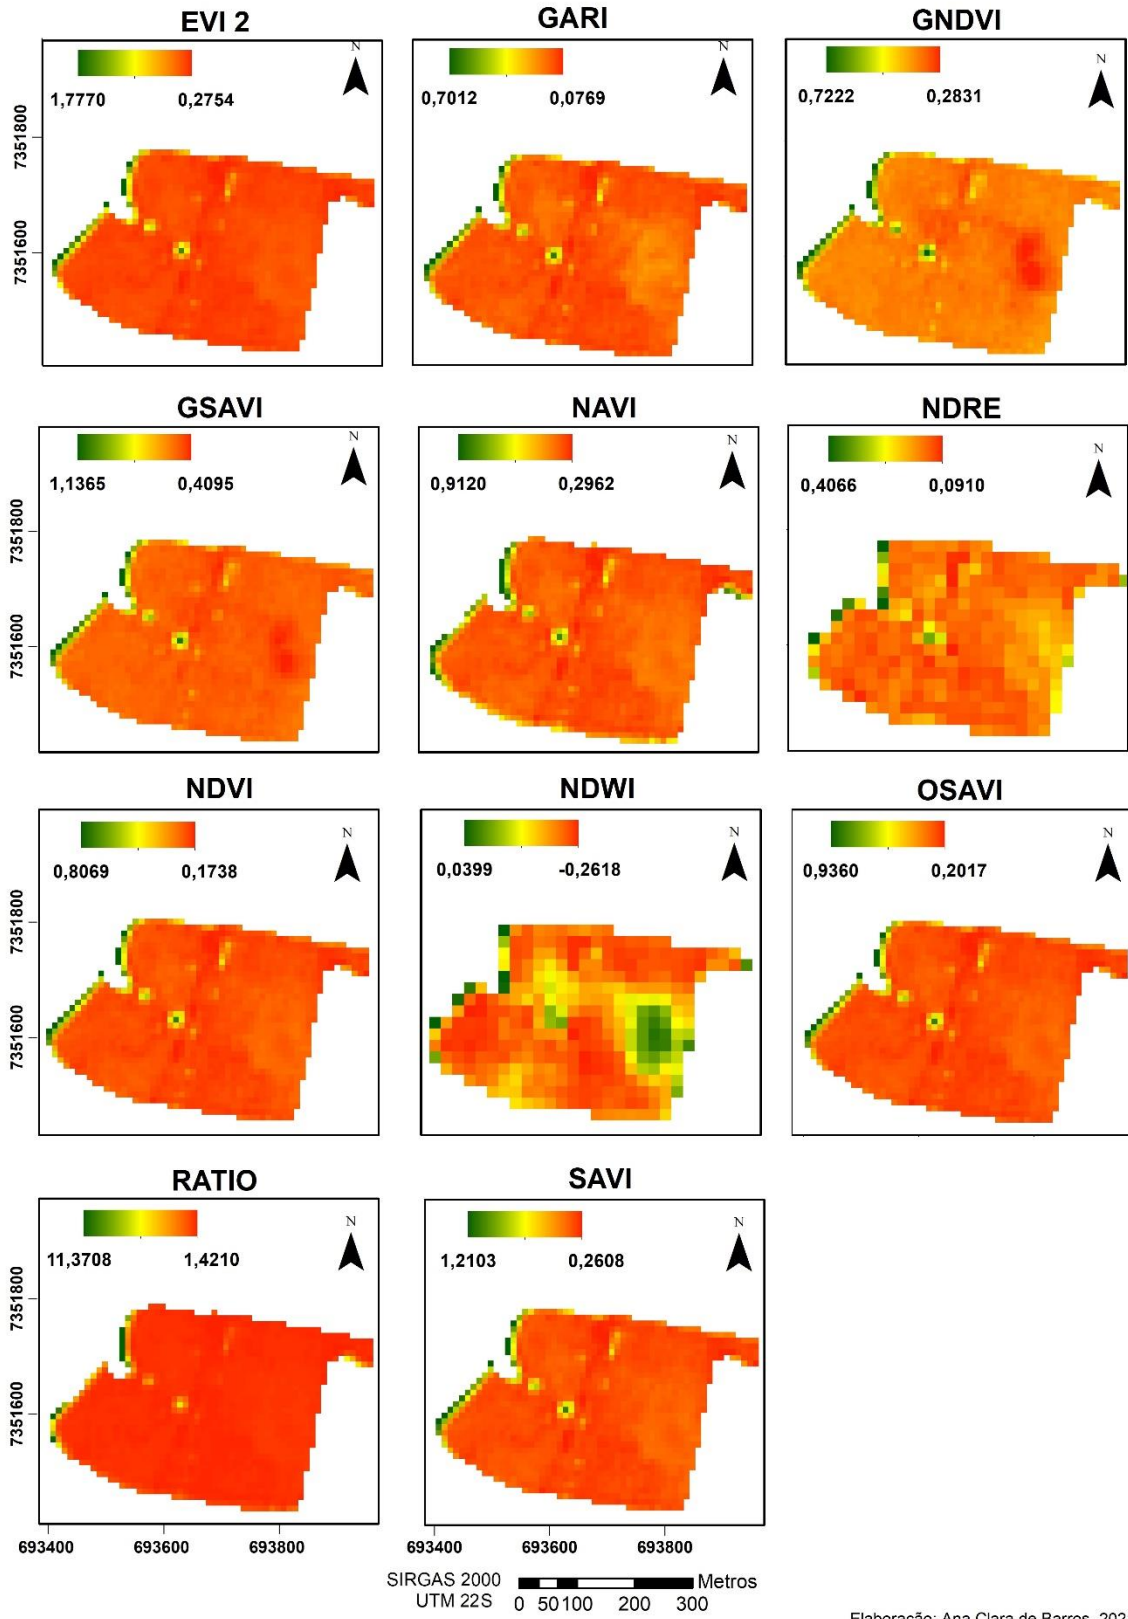


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE S - Índices calculados para o talhão 6 do mês de novembro de 2019

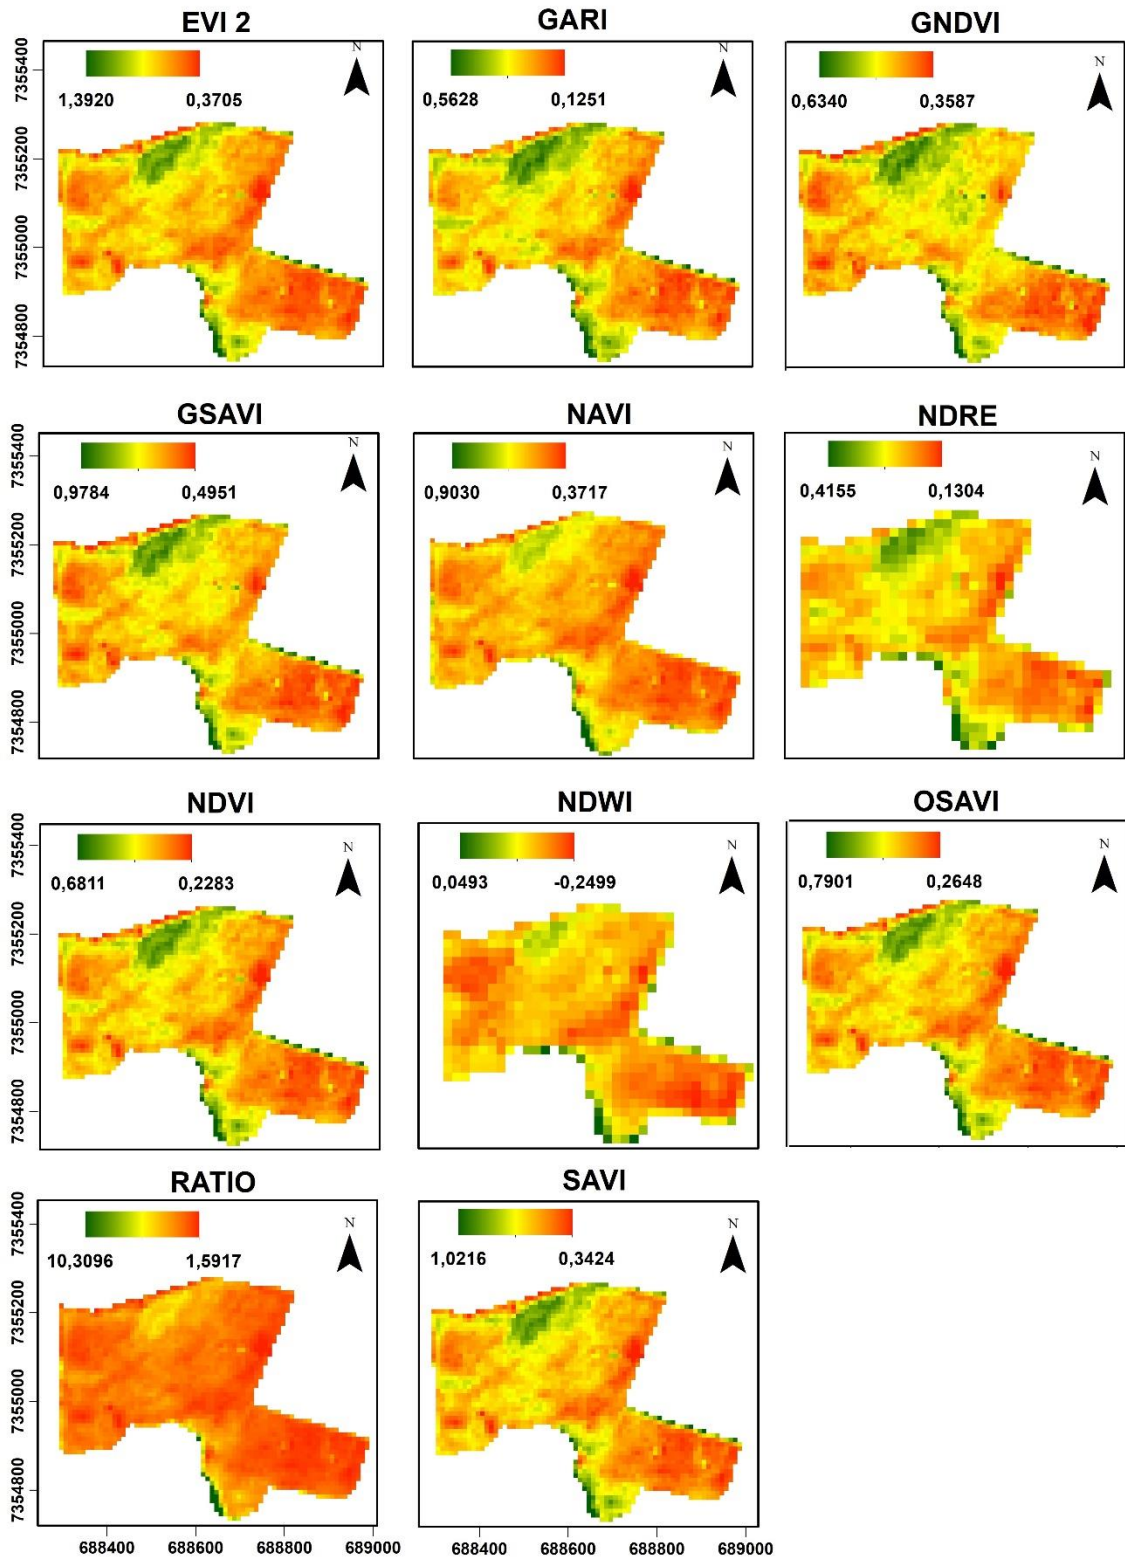
TALHÃO 6 - NOVEMBRO 2019



Elaboração: Ana Clara de Barros, 2021.

APÊNDICE T - Índices calculados para o talhão 7 do mês de novembro de 2019

TALHÃO 7 - NOVEMBRO 2019

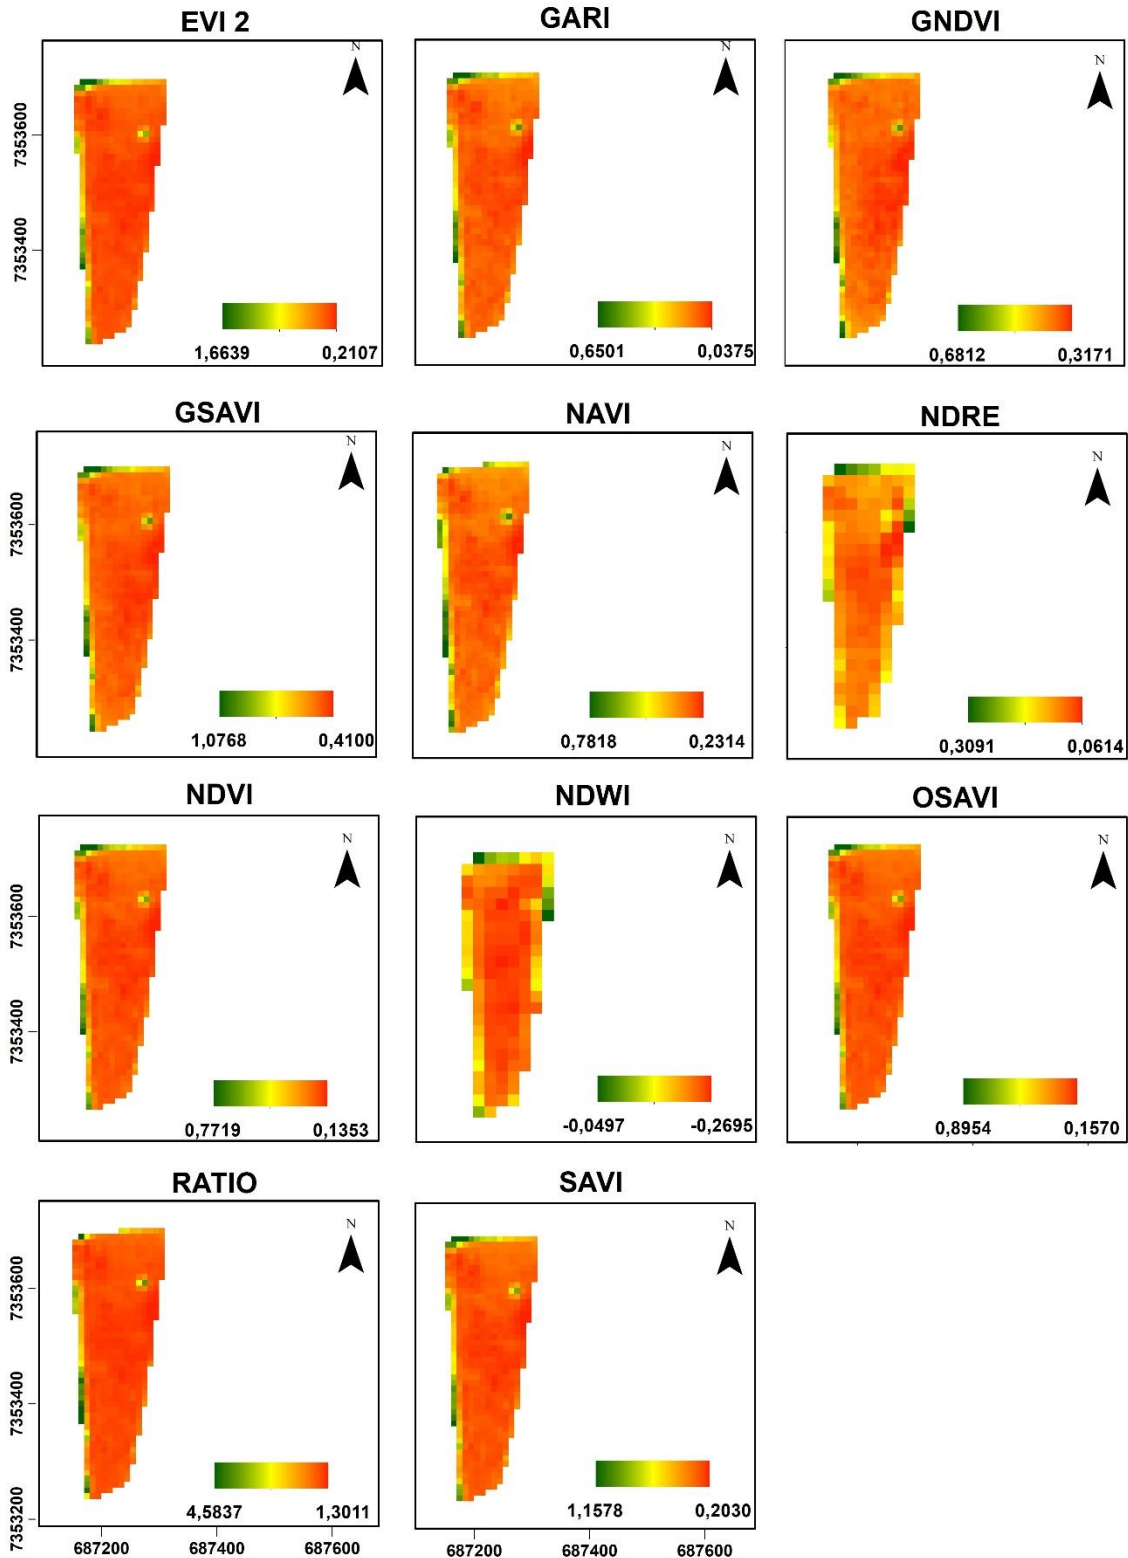


SIRGAS 2000 UTM 22S 0 100 200 400 600 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE U - Índices calculados para o talhão 8 do mês de novembro de 2019

TALHÃO 8 - NOVEMBRO 2019

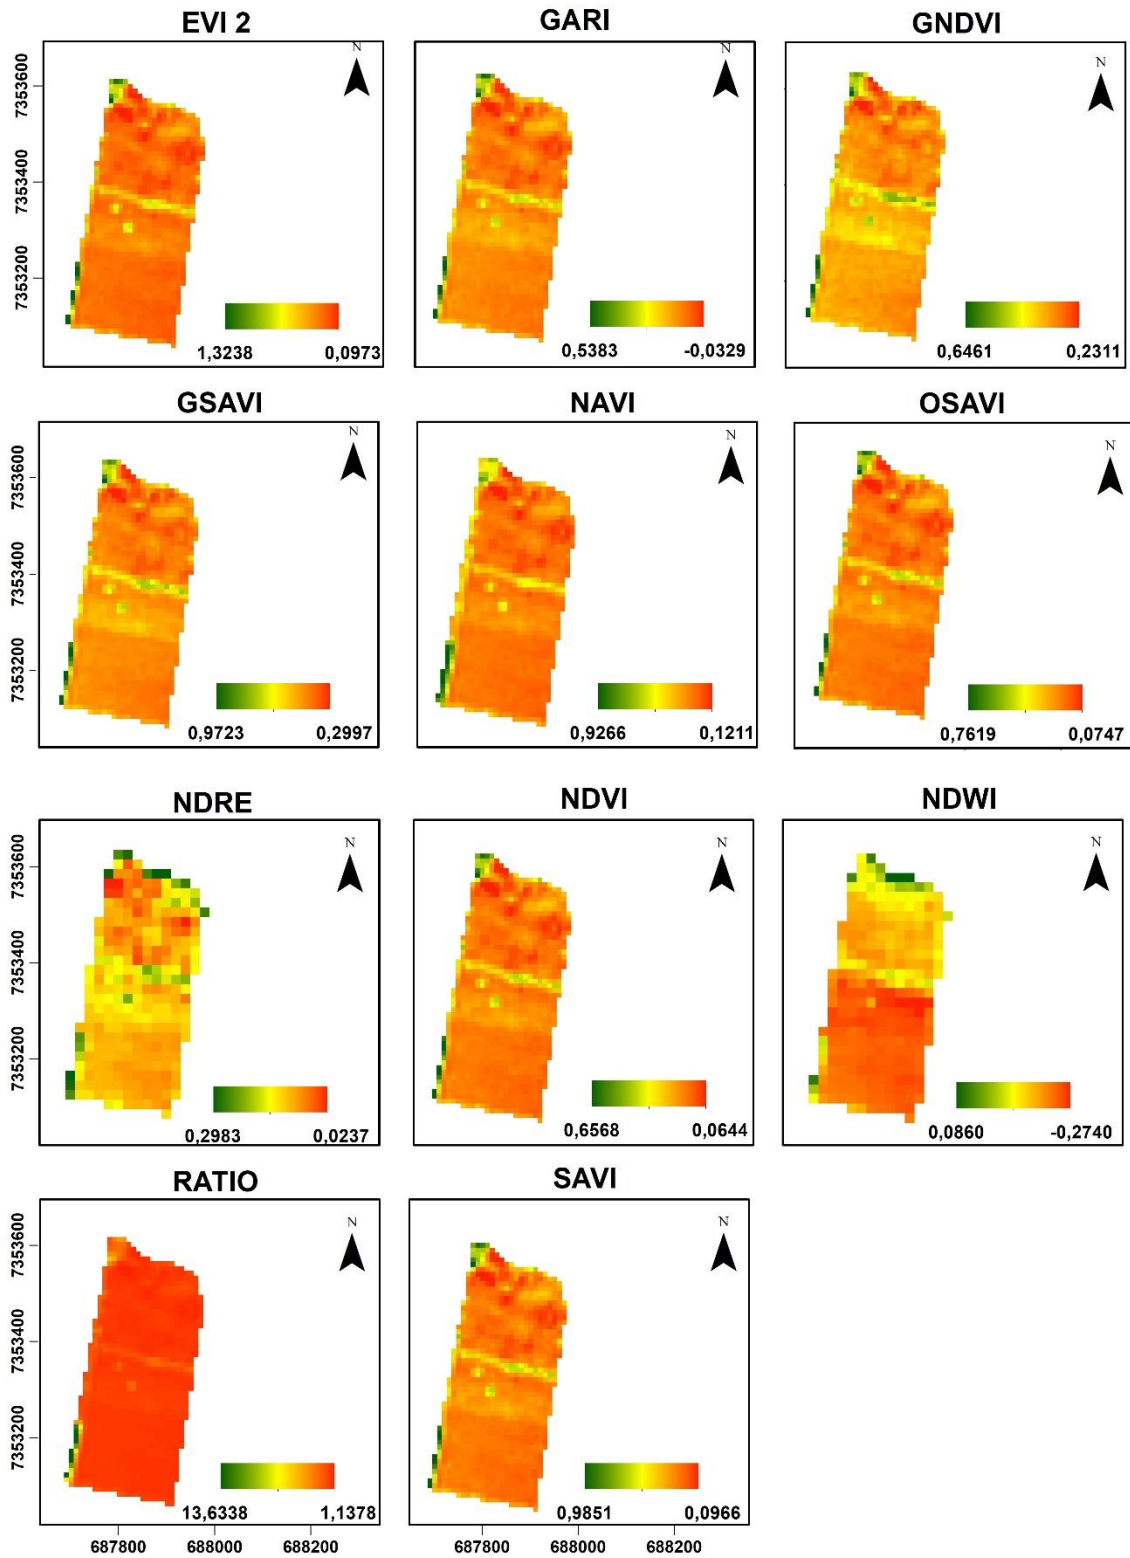


SIRGAS 2000 UTM 22S 0 65 130 260 390 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE V - Índices calculados para o talhão 9 do mês de novembro de 2019

TALHÃO 9 - NOVEMBRO 2019

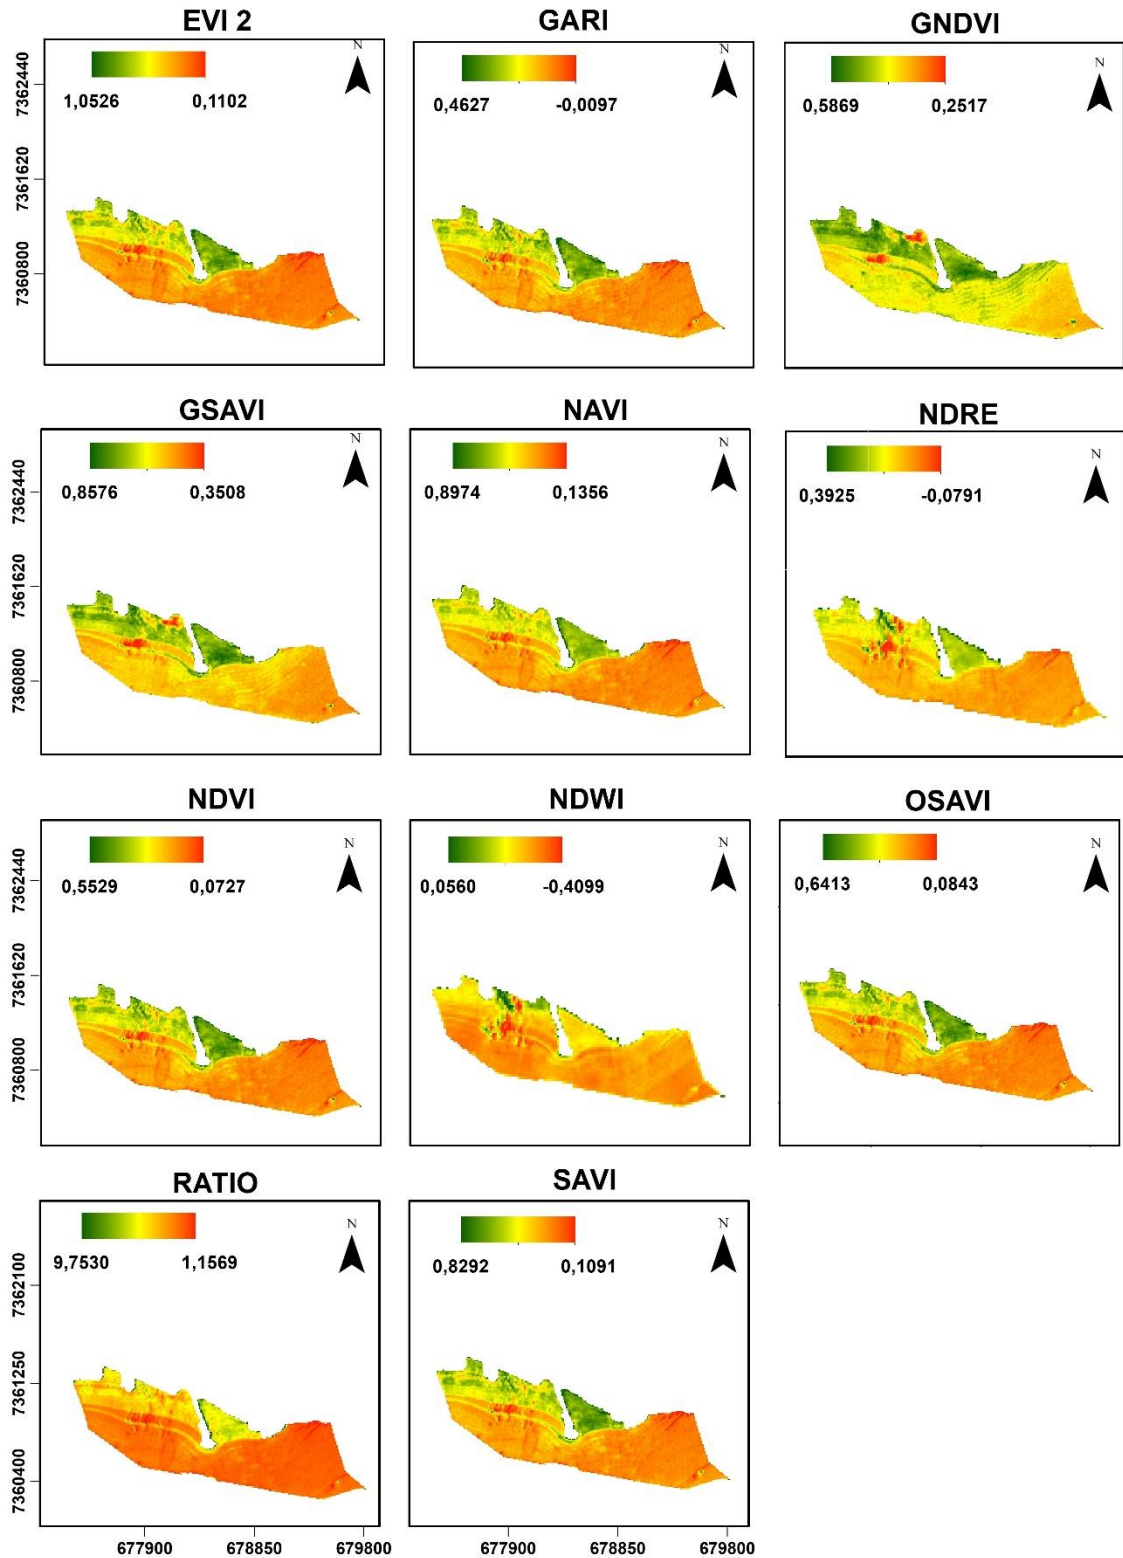


SIRGAS 2000 UTM 22S 0 75 150 300 450 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE W - Índices calculados para o talhão 10 do mês de novembro de 2019

TALHÃO 10 - NOVEMBRO 2019

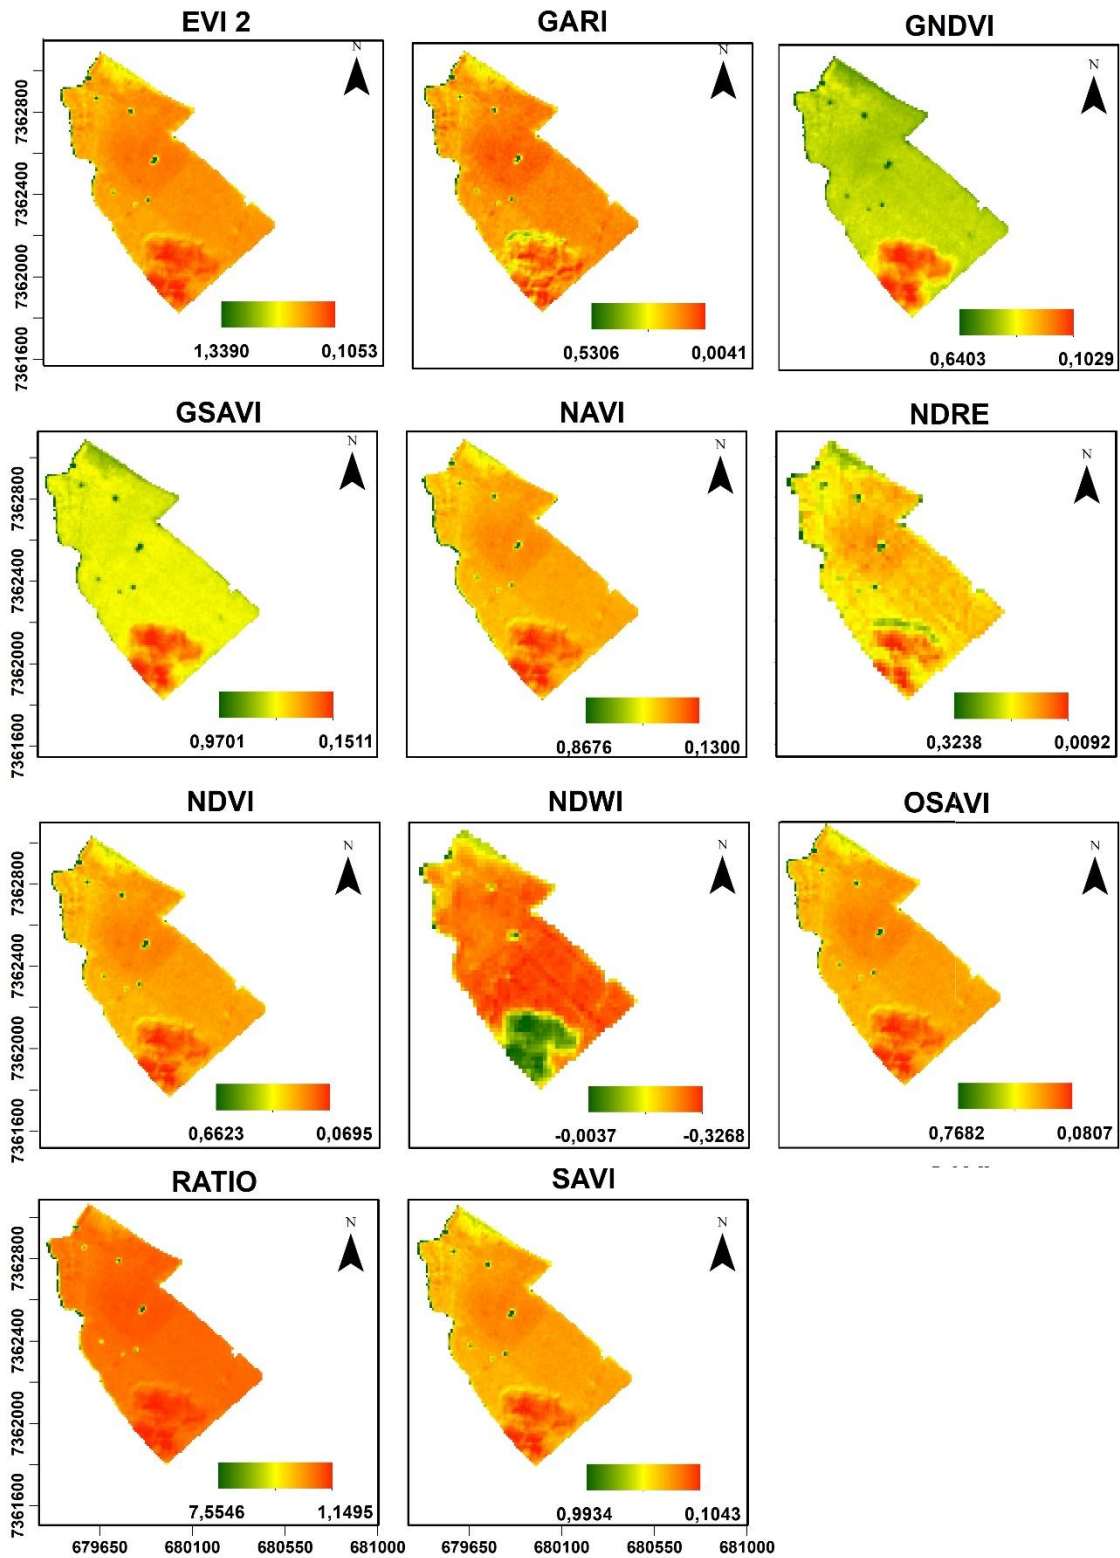


SIRGAS 2000 UTM 22S 0 300600 1.200 1.800 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE X - Índices calculados para o talhão 11 do mês de novembro de 2019

TALHÃO 11 - NOVEMBRO 2019

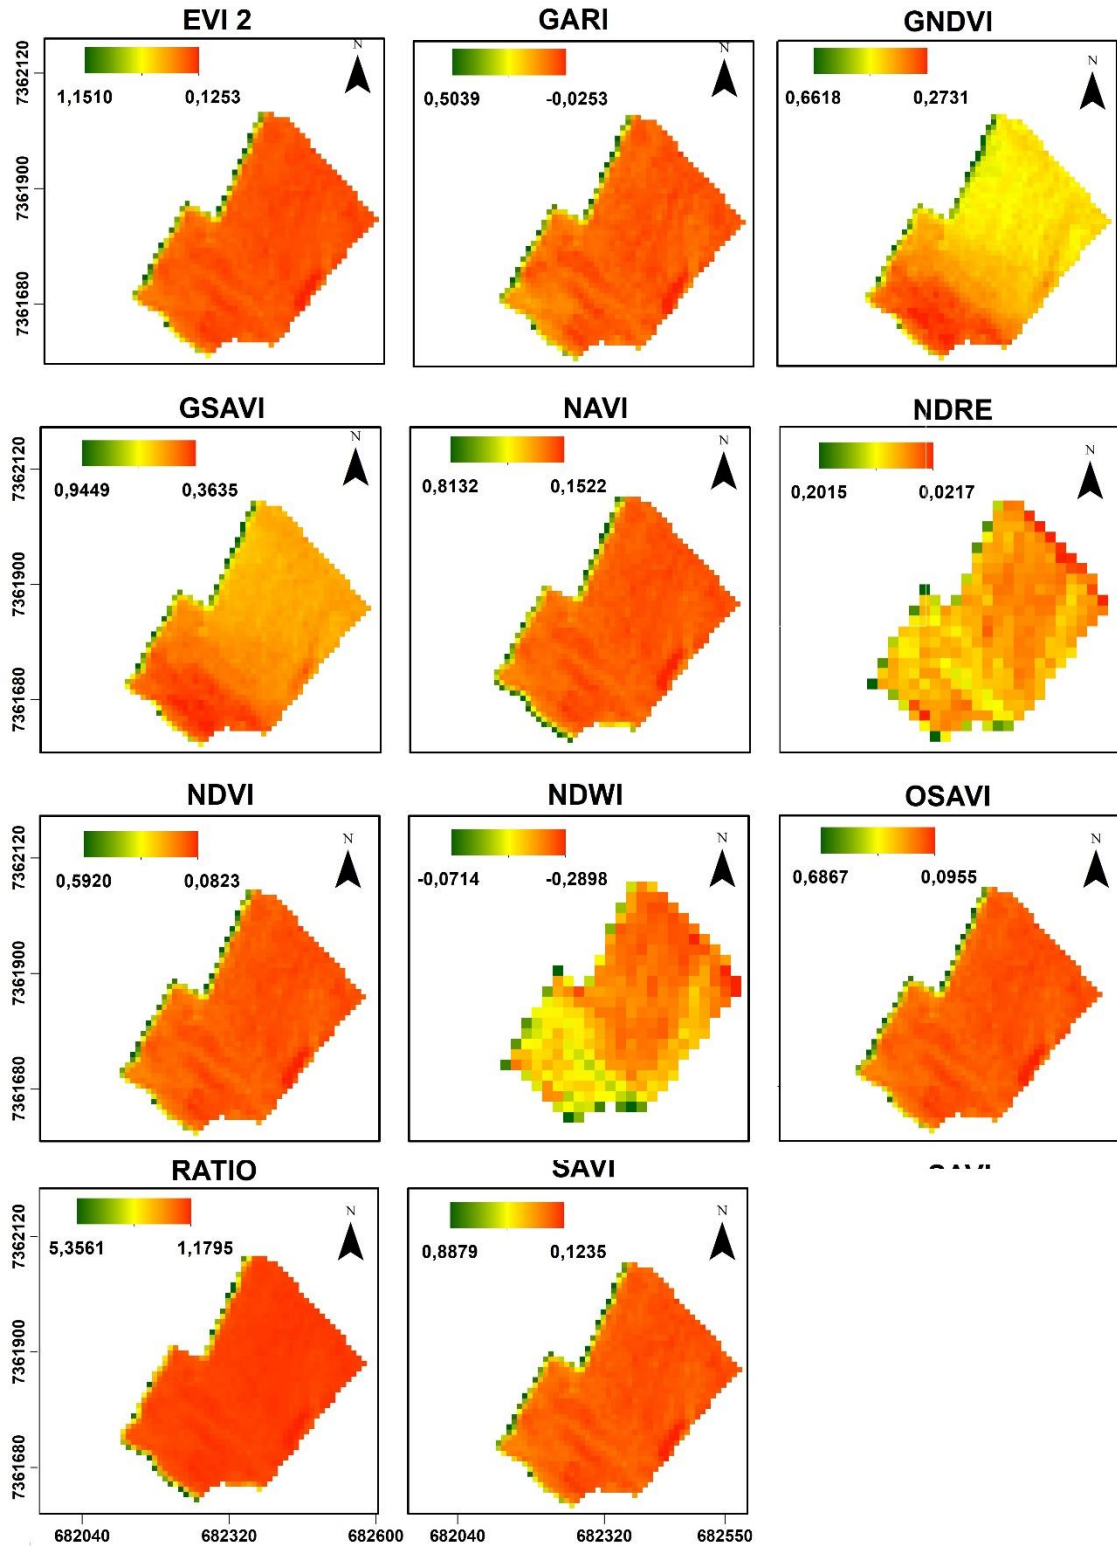


SIRGAS 2000 UTM 22S 0 205 410 820 1.230 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE Y - Índices calculados para o talhão 12 do mês de novembro de 2019

TALHÃO 12 - NOVEMBRO 2019

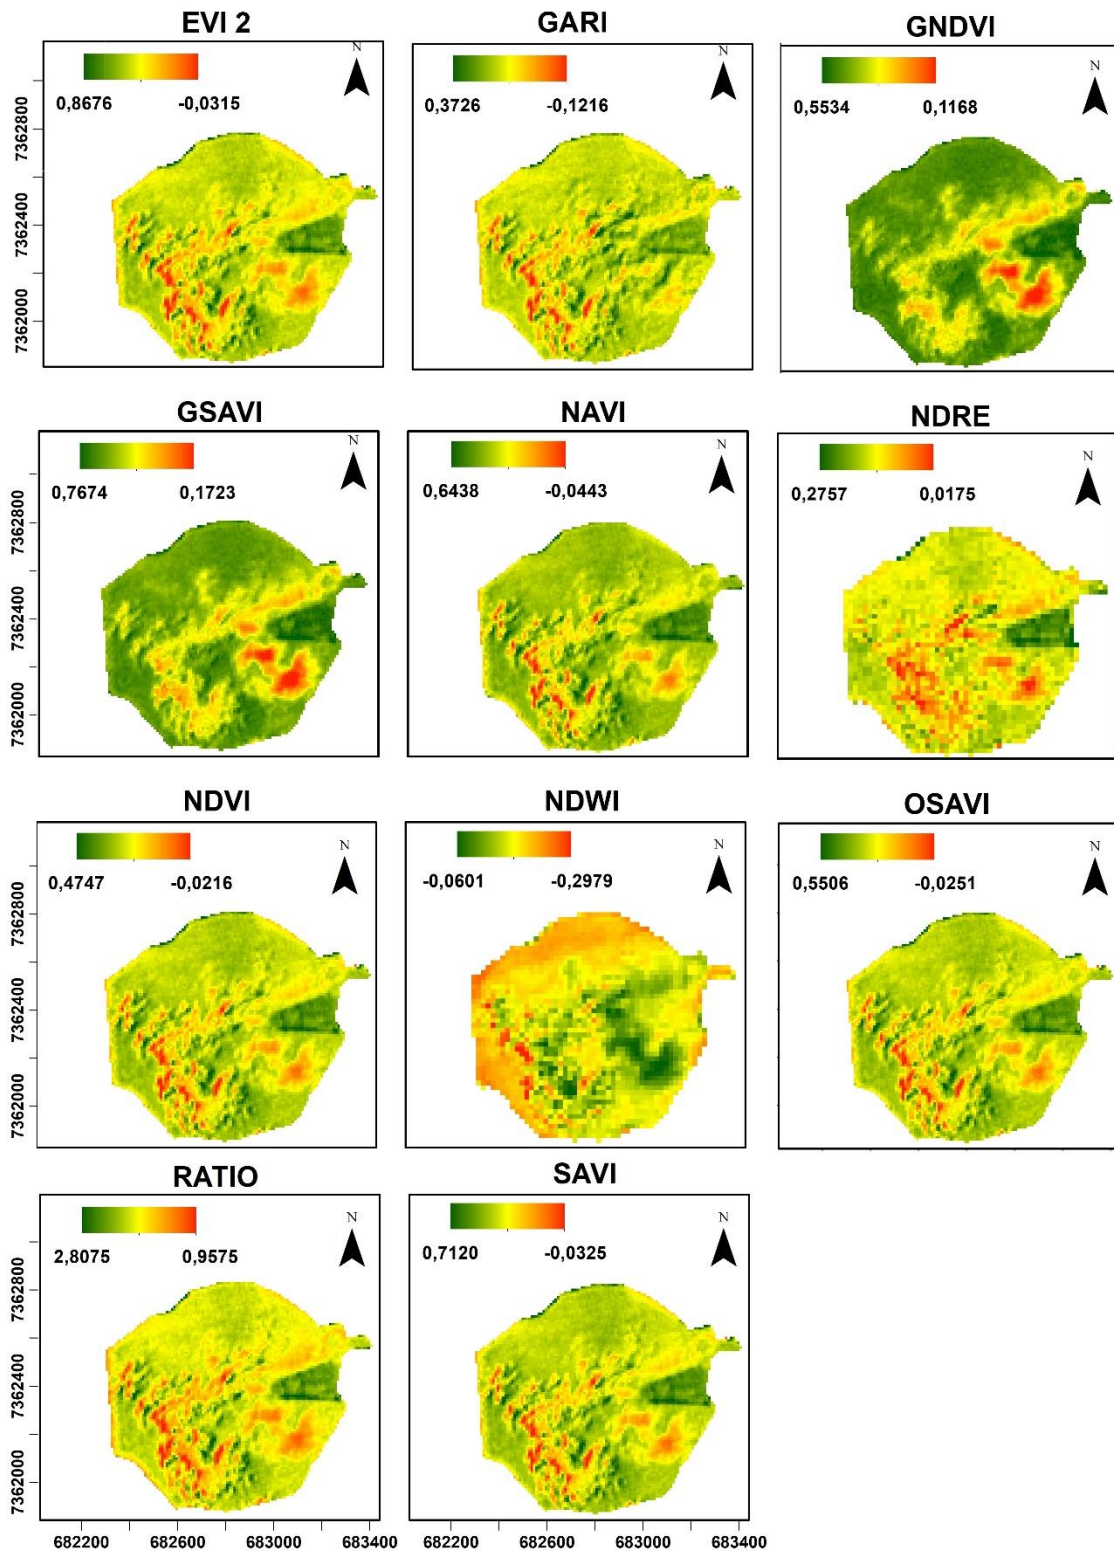


SIRGAS 2000 UTM 22S 0 55 110 220 330 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE Z - Índices calculados para o talhão 13 do mês de novembro de 2019

TALHÃO 13 - NOVEMBRO 2019

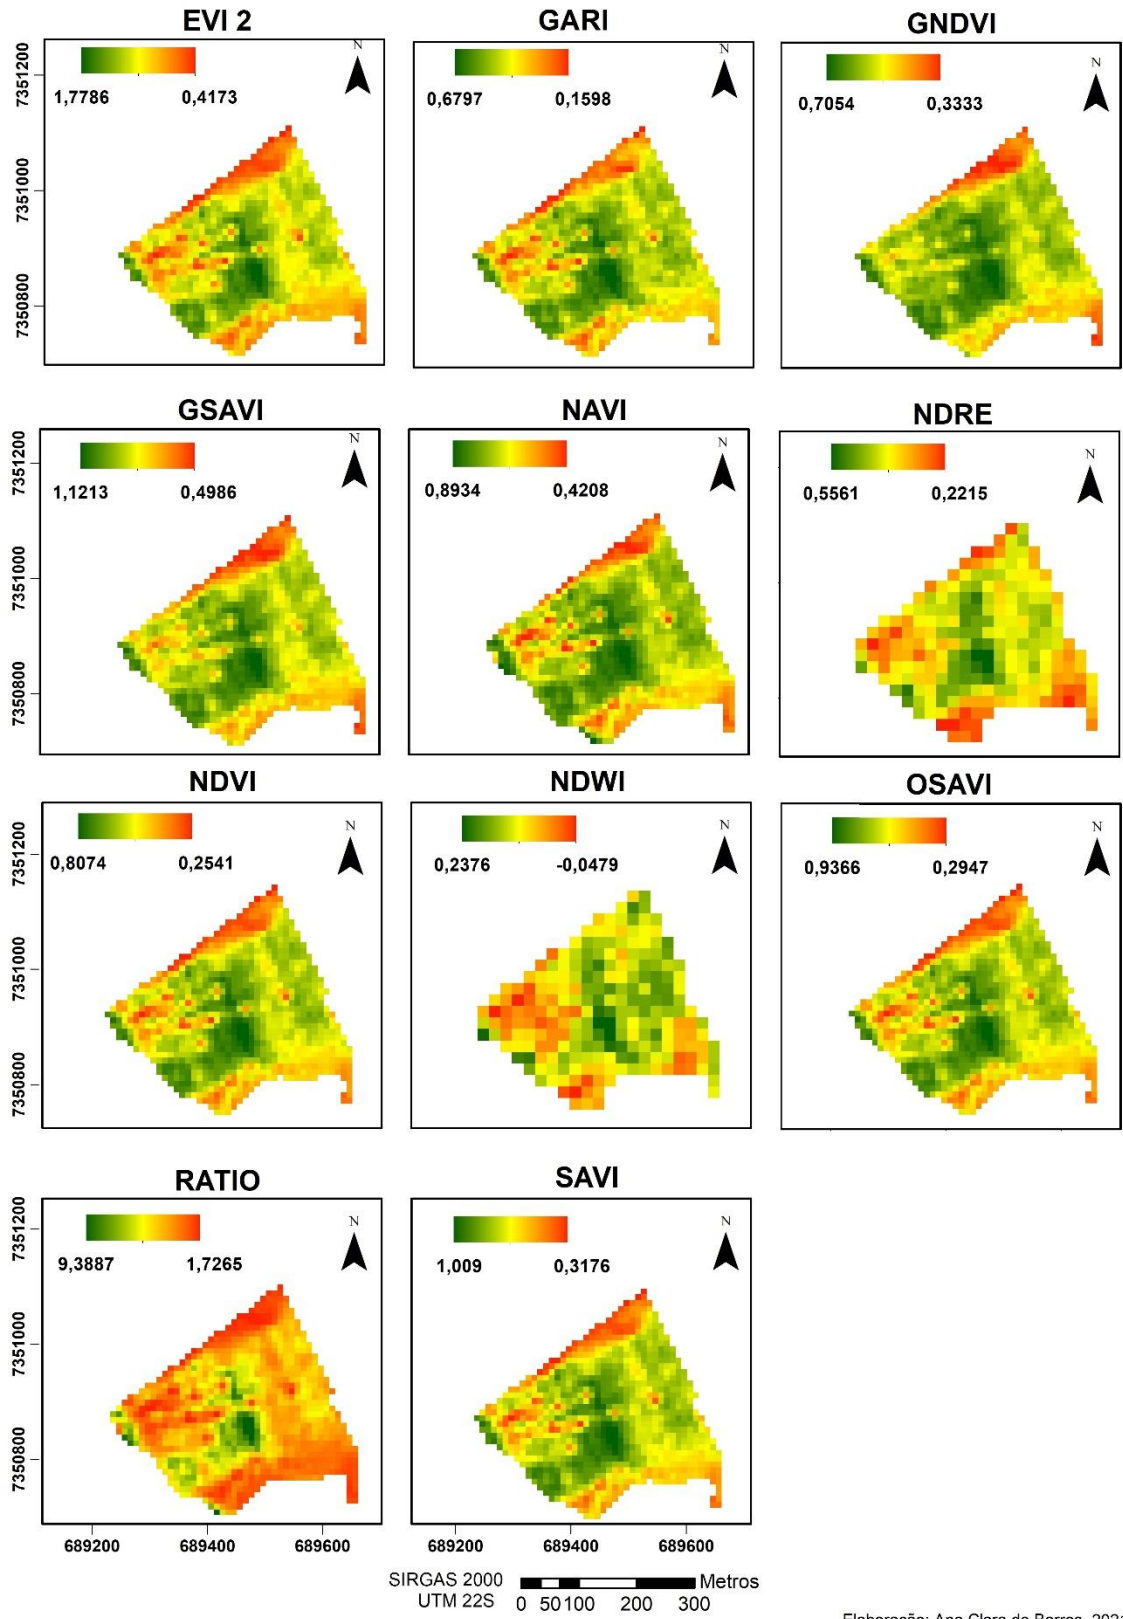


SIRGAS 2000 UTM 22S 0 180 360 720 1.080 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AA - Índices calculados para o talhão 1 do mês de dezembro de 2019

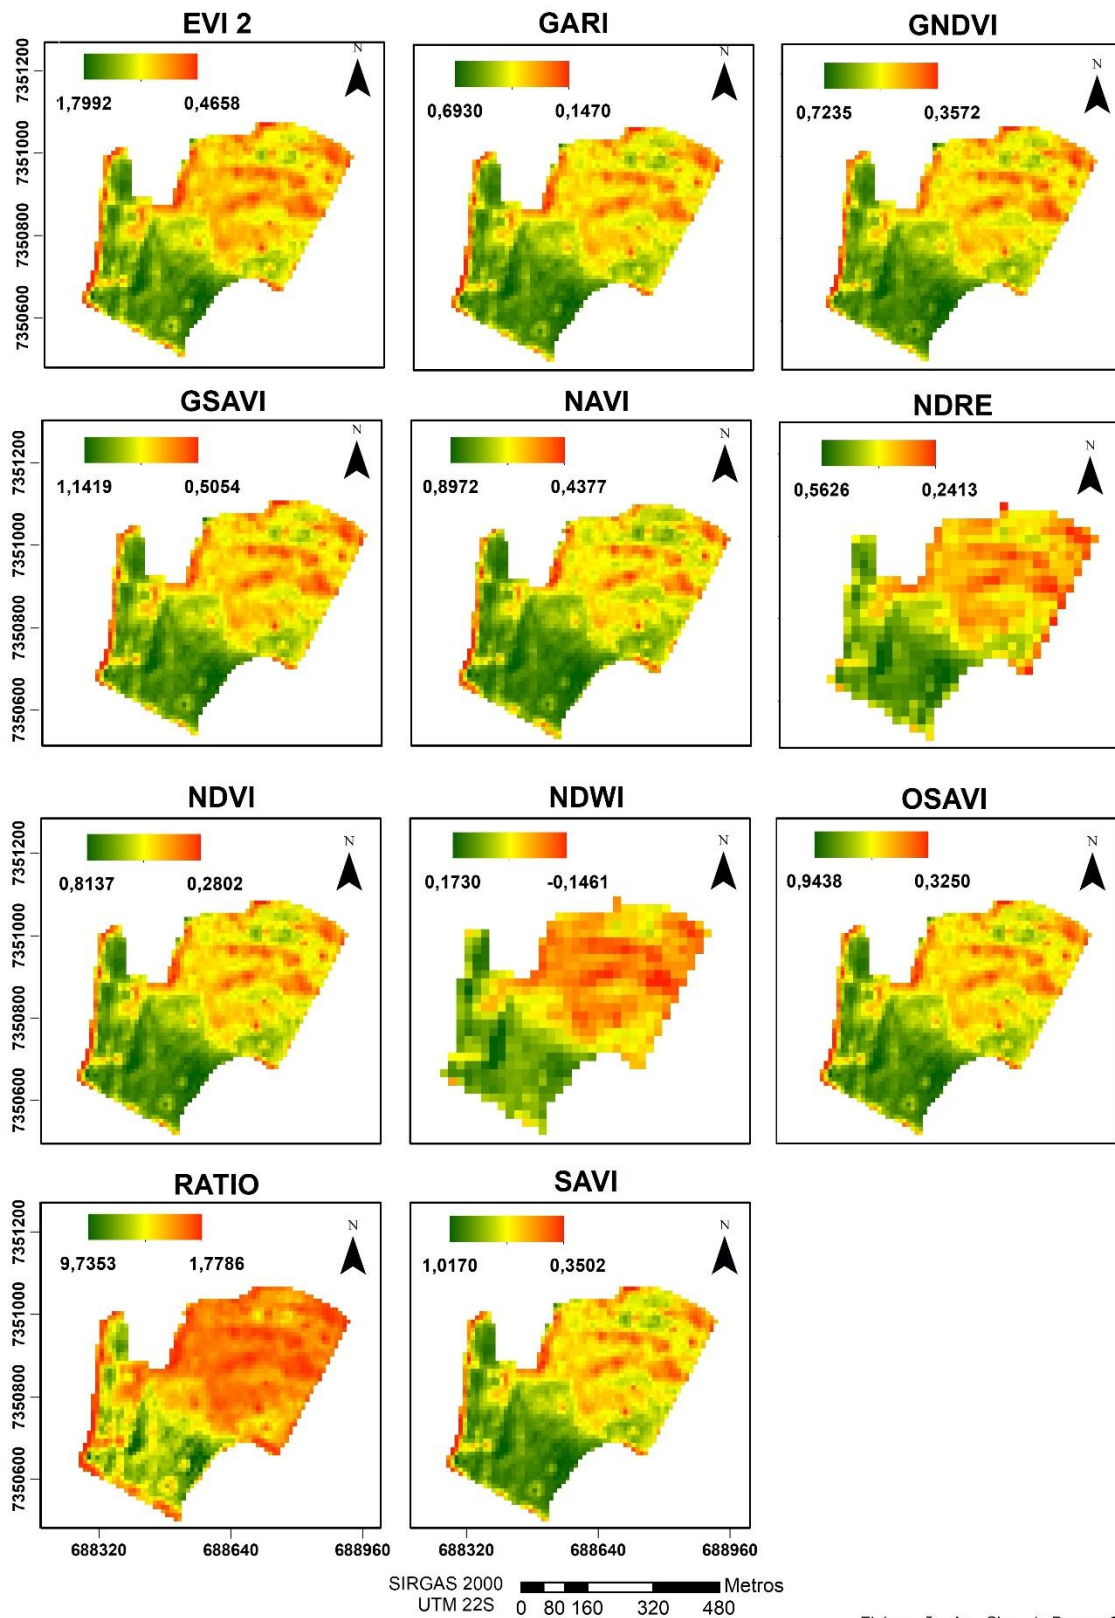
TALHÃO 1 - DEZEMBRO 2019



Elaboração: Ana Clara de Barros, 2021.

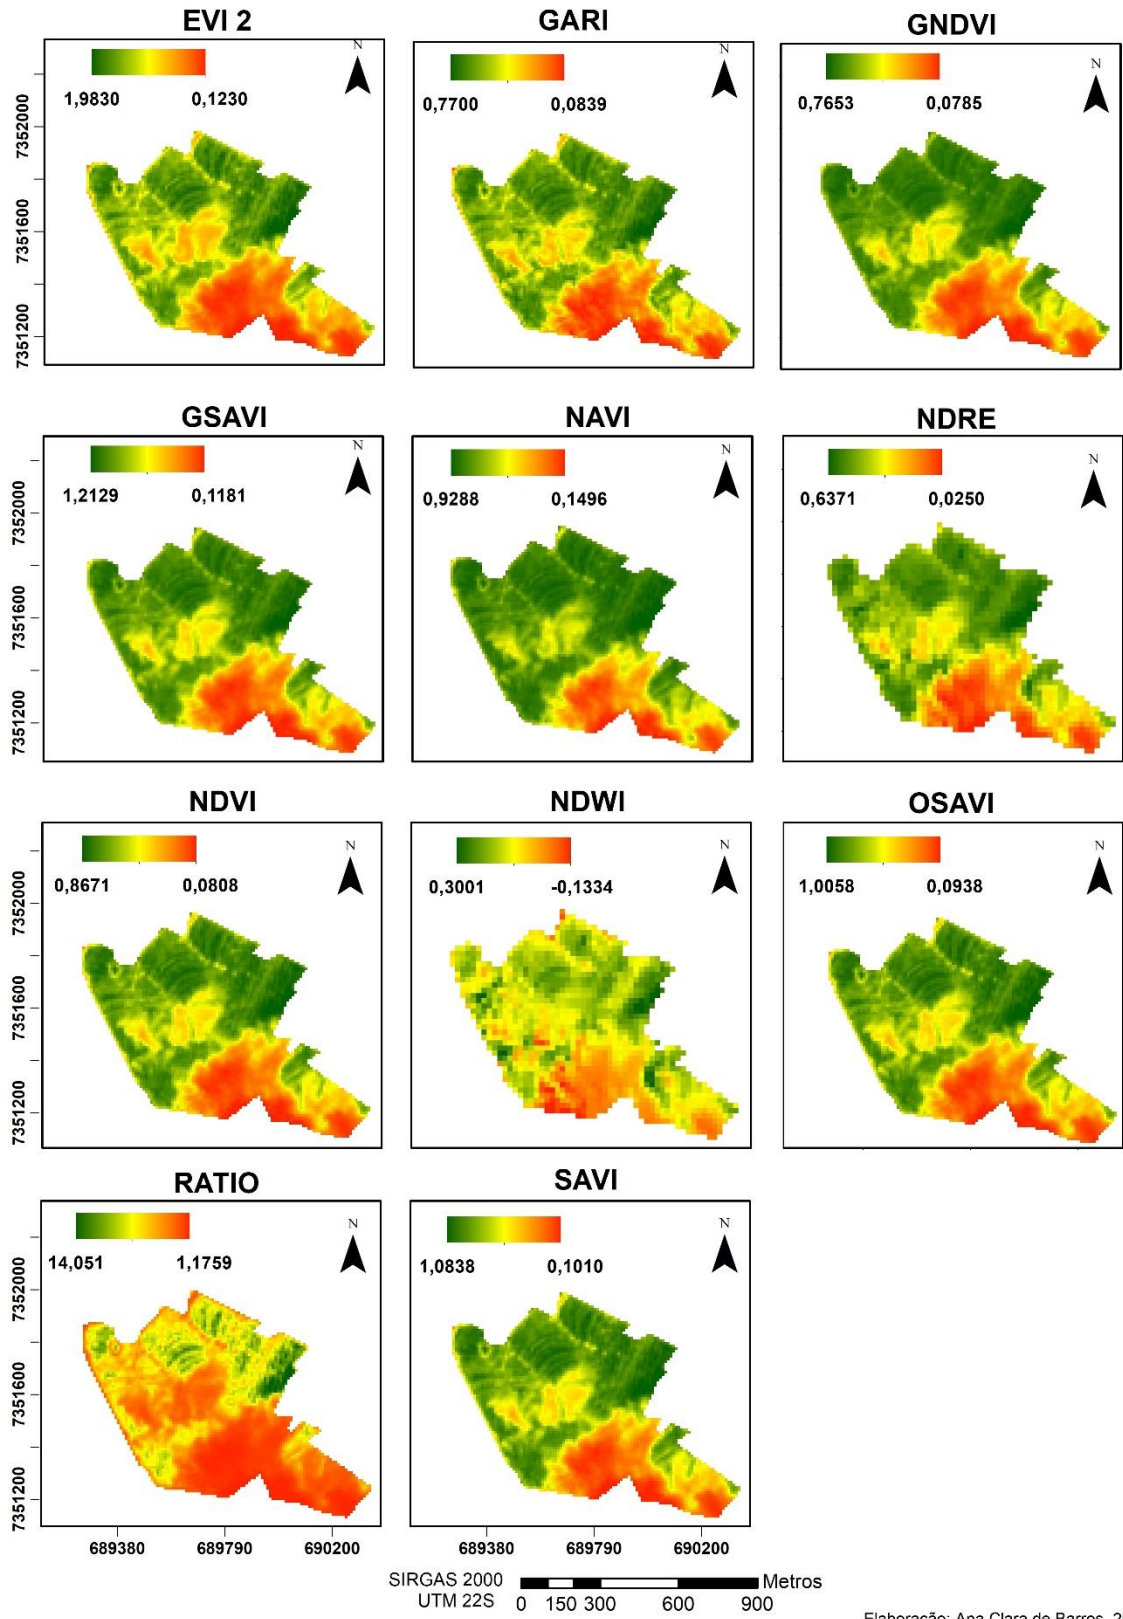
APÊNDICE AB - Índices calculados para o talhão 2 do mês de dezembro de 2019

TALHÃO 2 - DEZEMBRO 2019



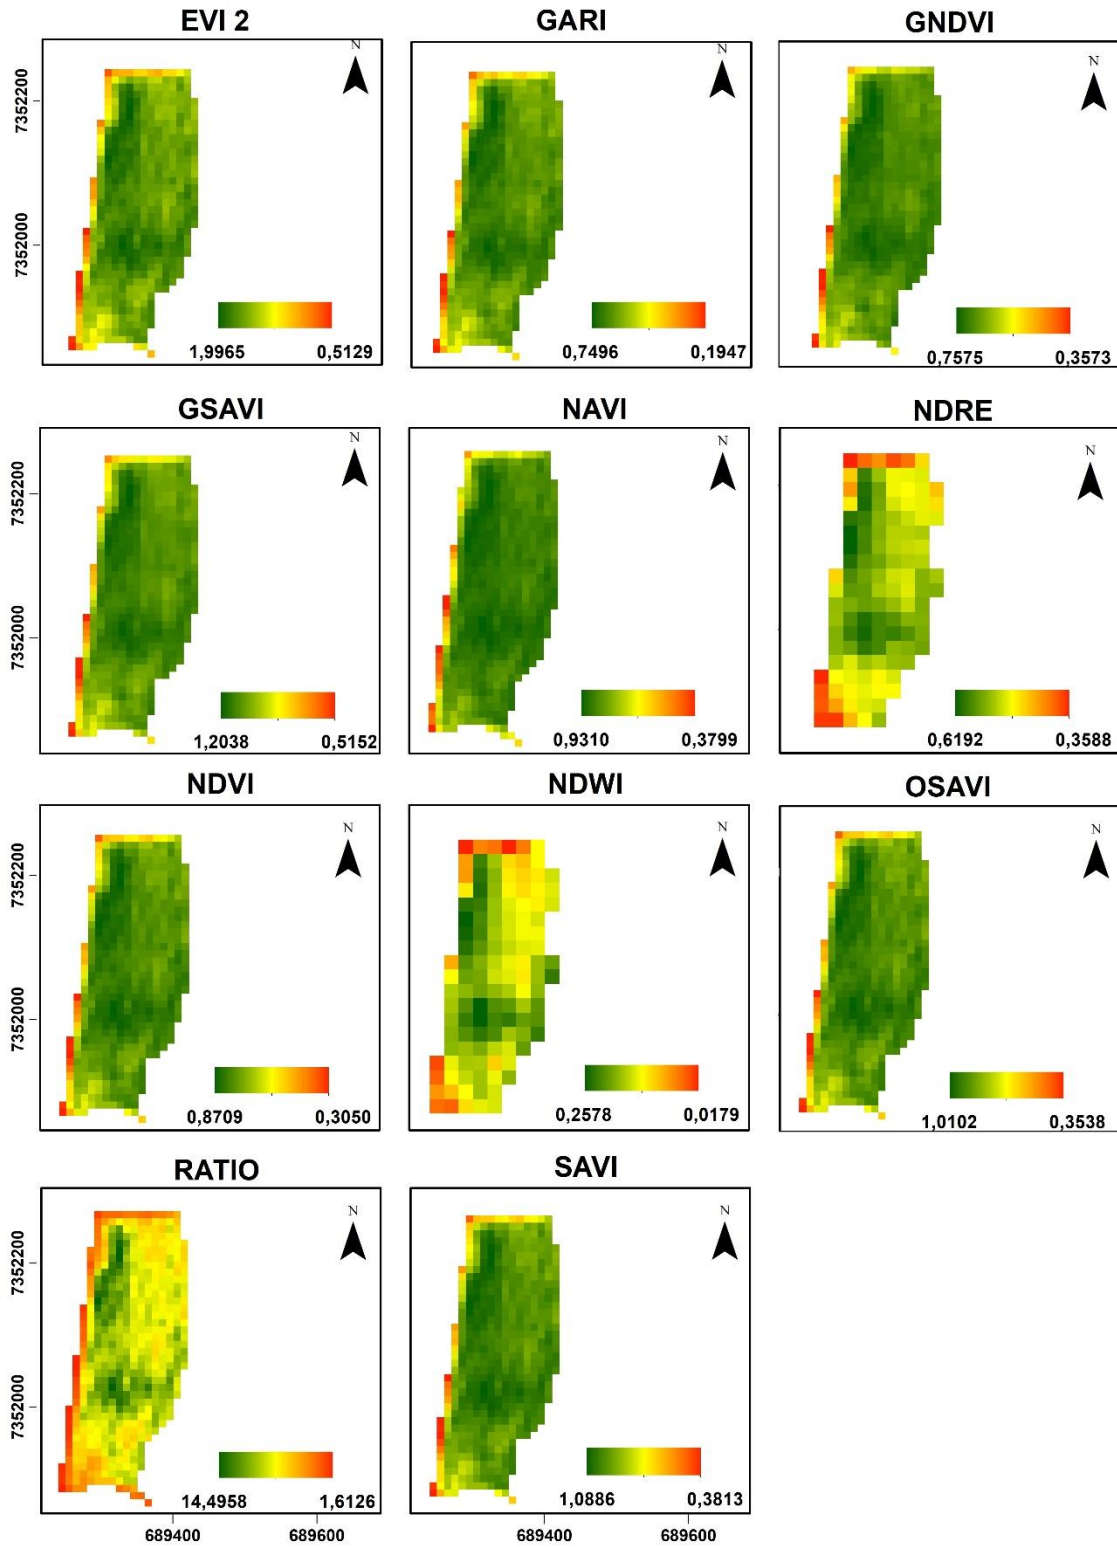
APÊNDICE AC - Índices calculados para o talhão 3 do mês de dezembro de 2019

TALHÃO 3 - DEZEMBRO 2019



APÊNDICE AD - Índices calculados para o talhão 4 do mês de dezembro de 2019

TALHÃO 4 - DEZEMBRO 2019

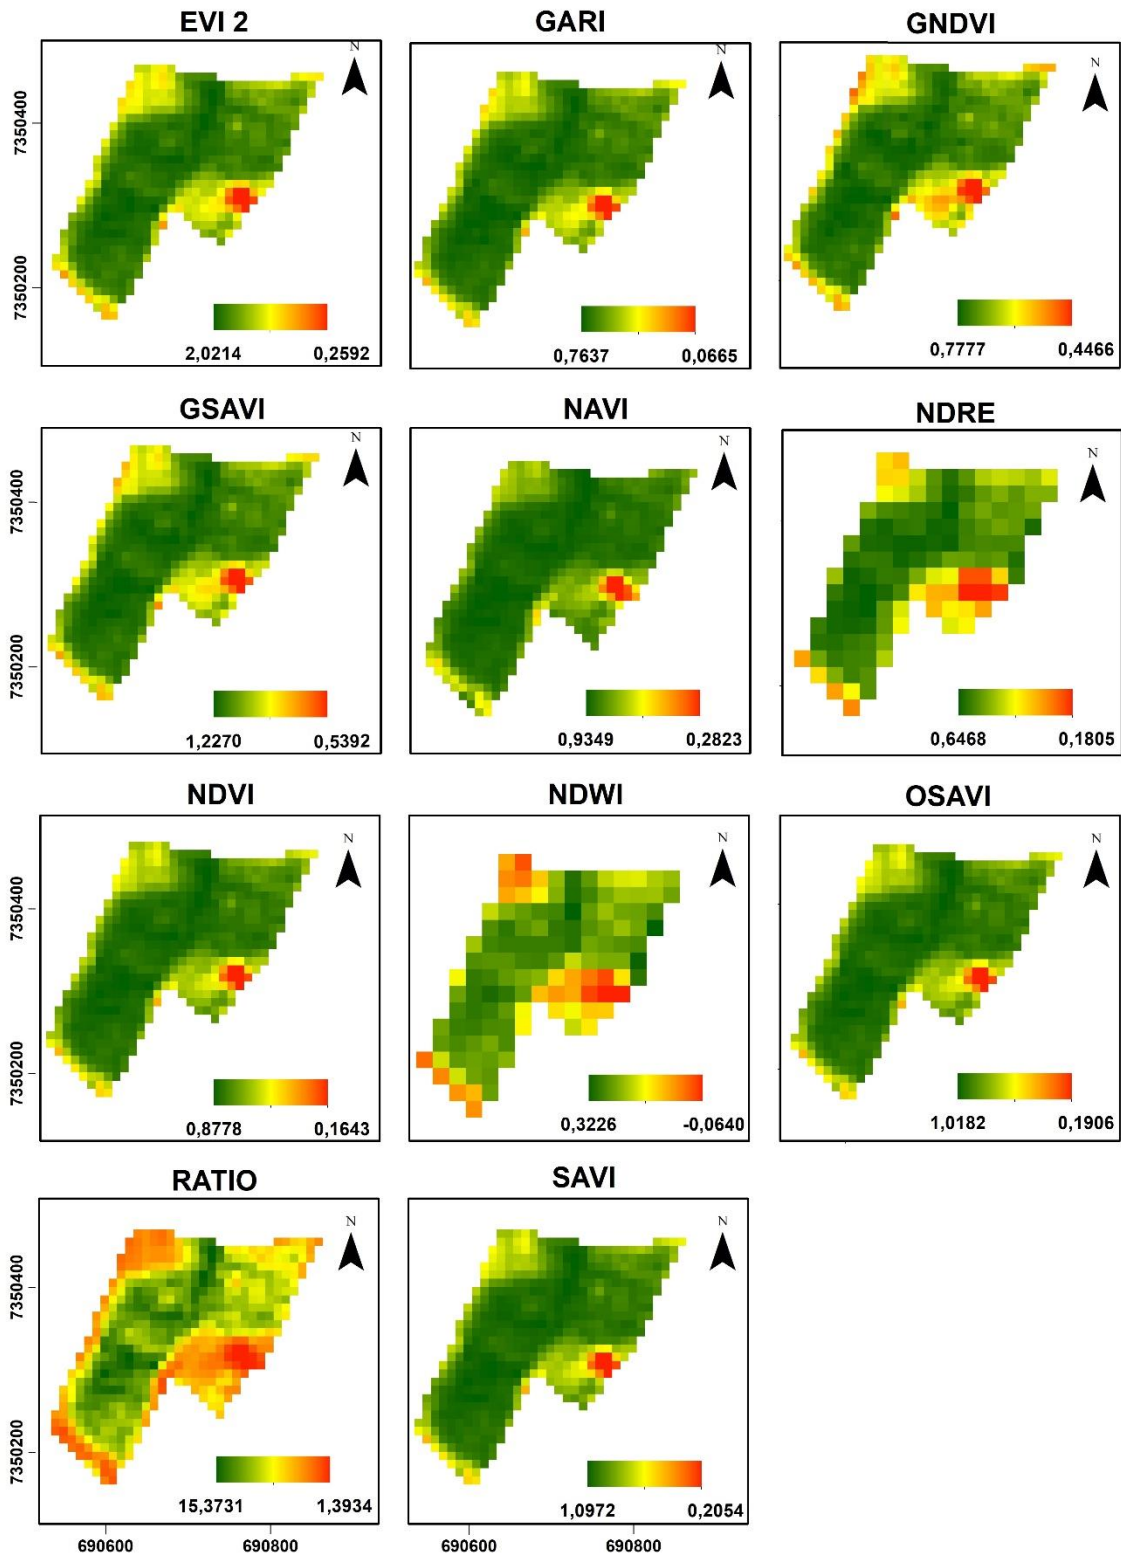


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AE - Índices calculados para o talhão 5 do mês de dezembro de 2019

TALHÃO 5 - DEZEMBRO 2019

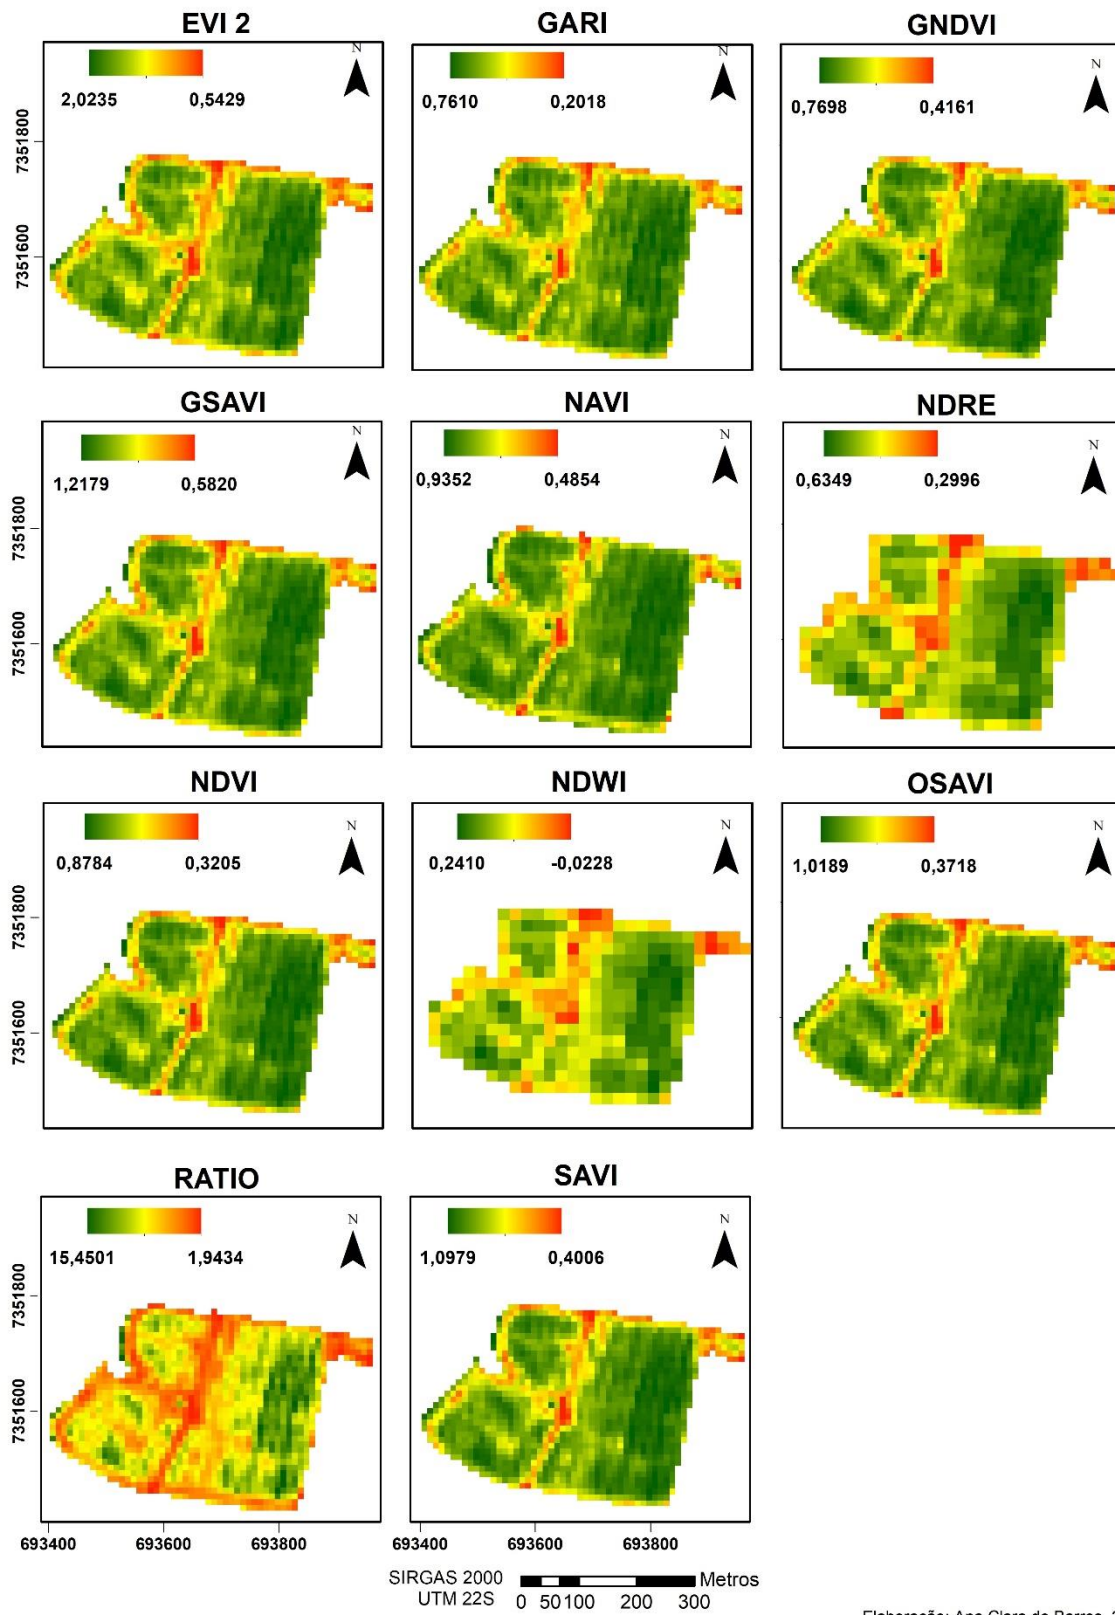


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AF - Índices calculados para o talhão 6 do mês de dezembro de 2019

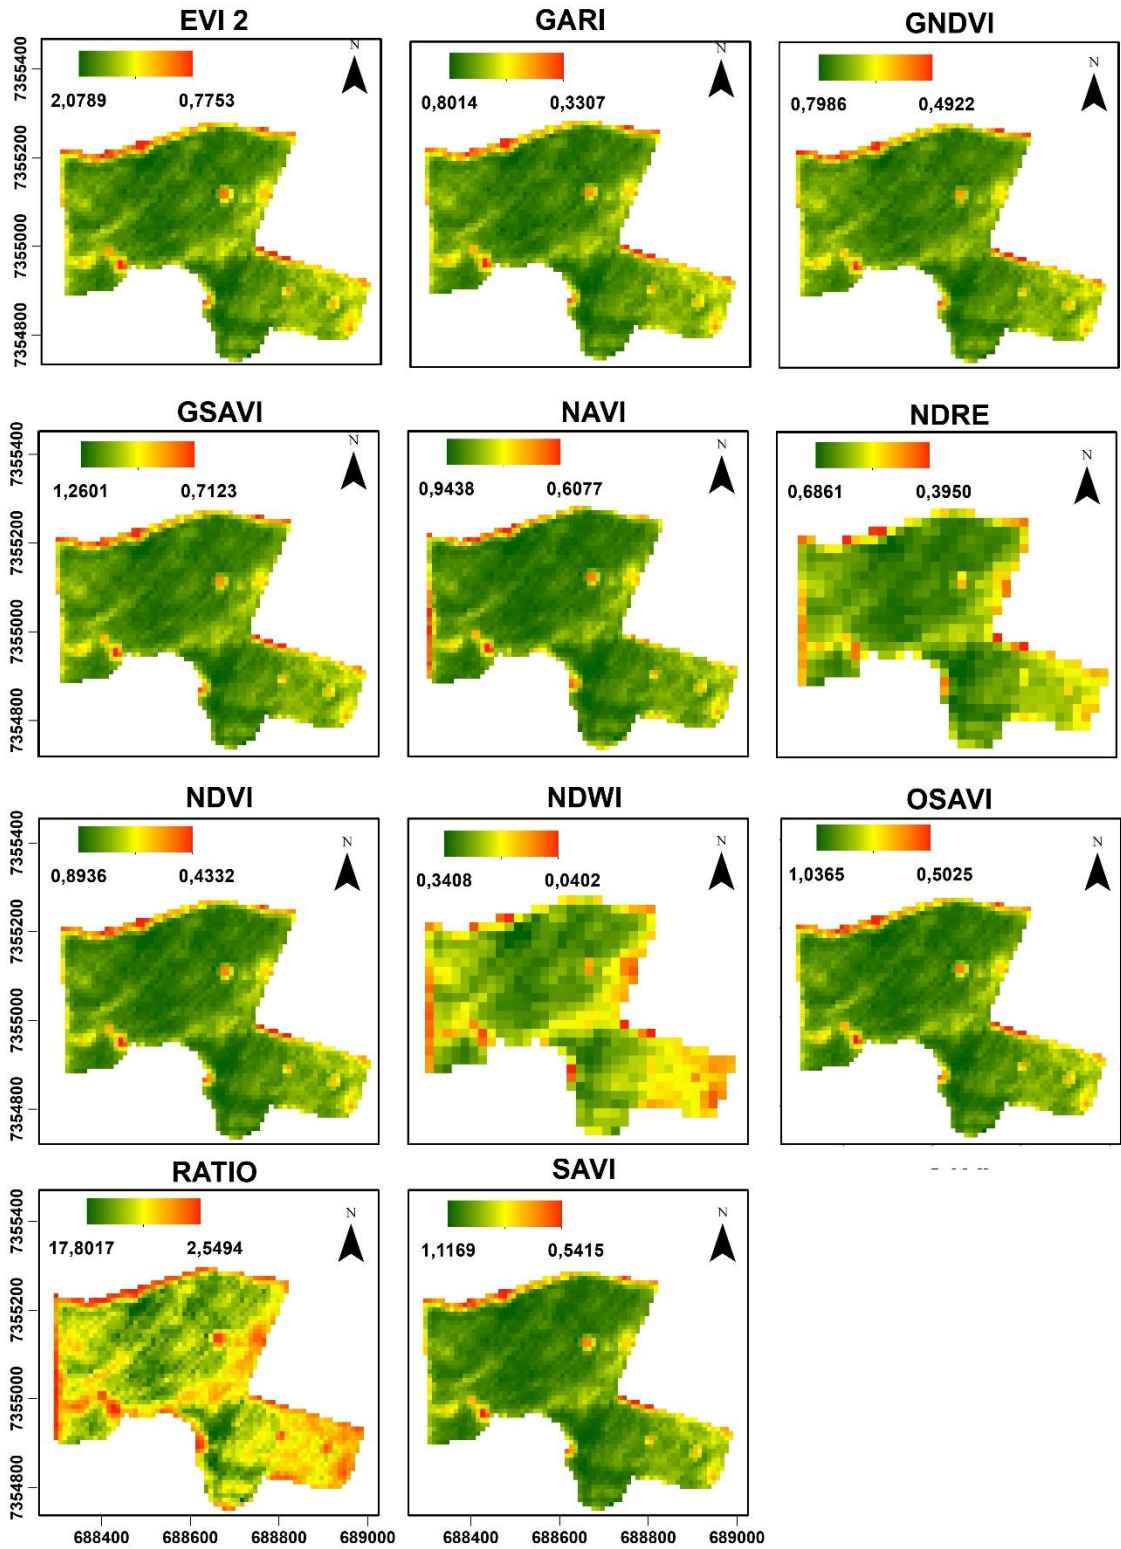
TALHÃO 6 - DEZEMBRO 2019



Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AG - Índices calculados para o talhão 7 do mês de dezembro de 2019

TALHÃO 7 - DEZEMBRO 2019

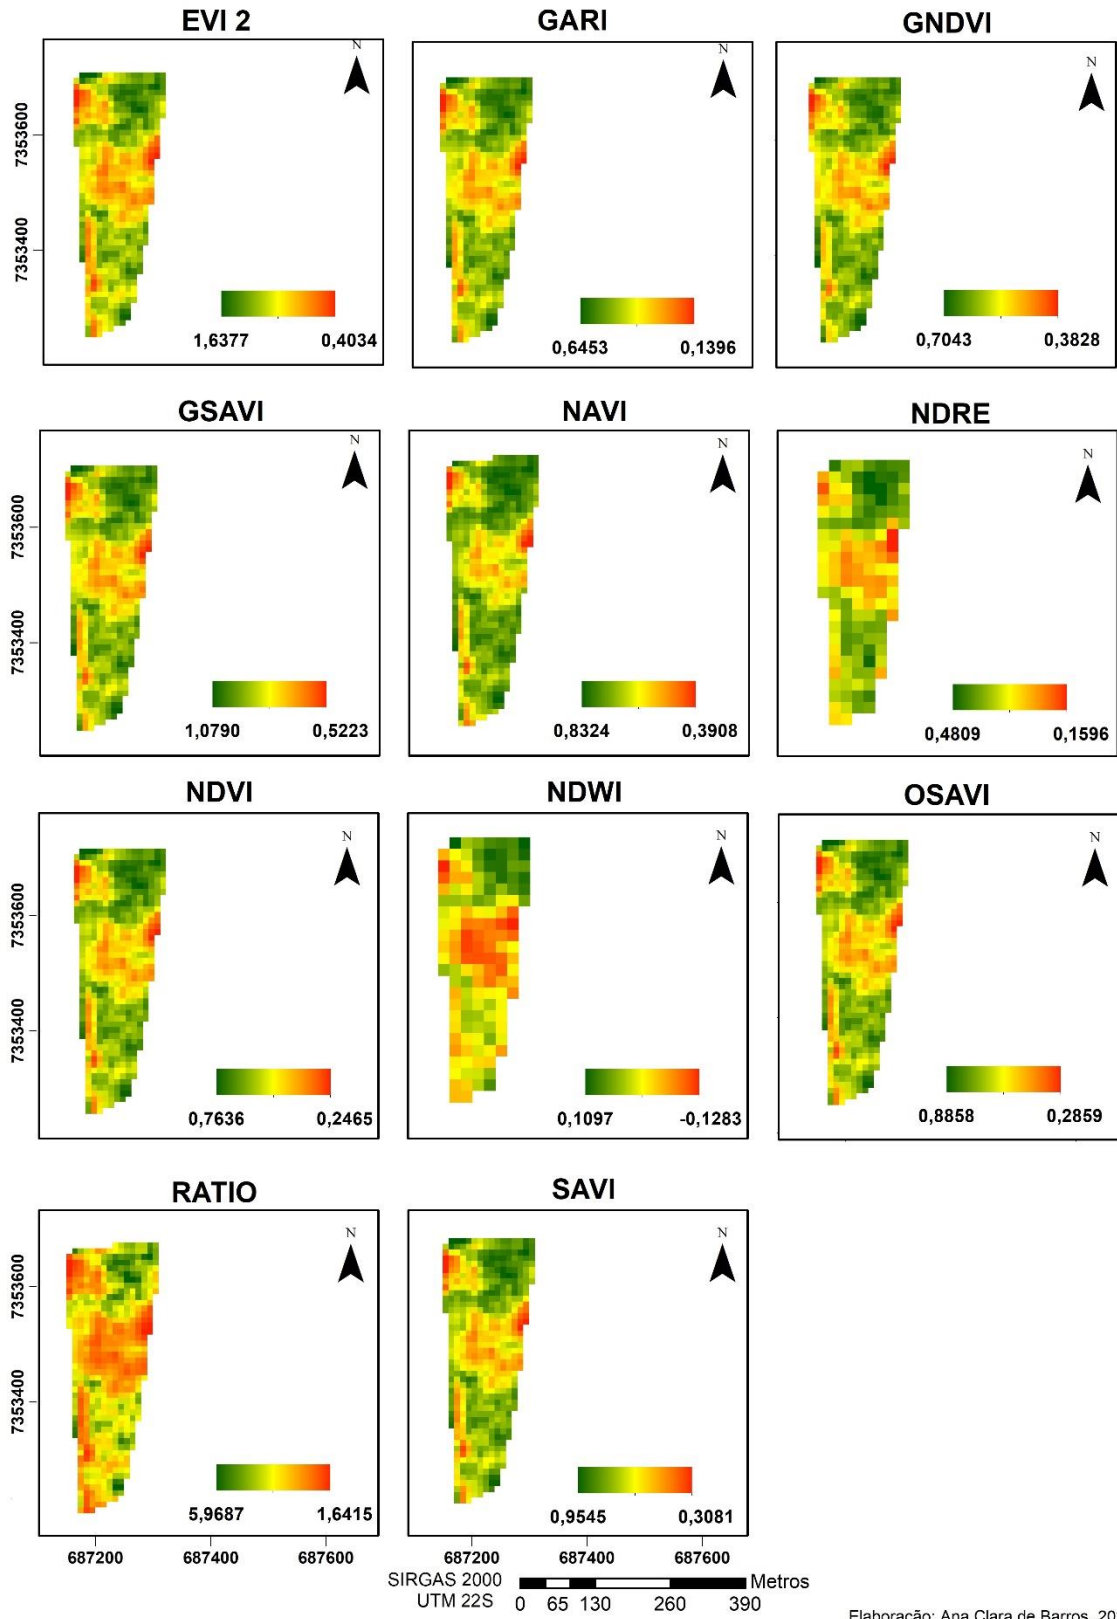


SIRGAS 2000 UTM 22S 0 100 200 400 600 Metros

Elaboração: Ana Clara de Barros, 2021.

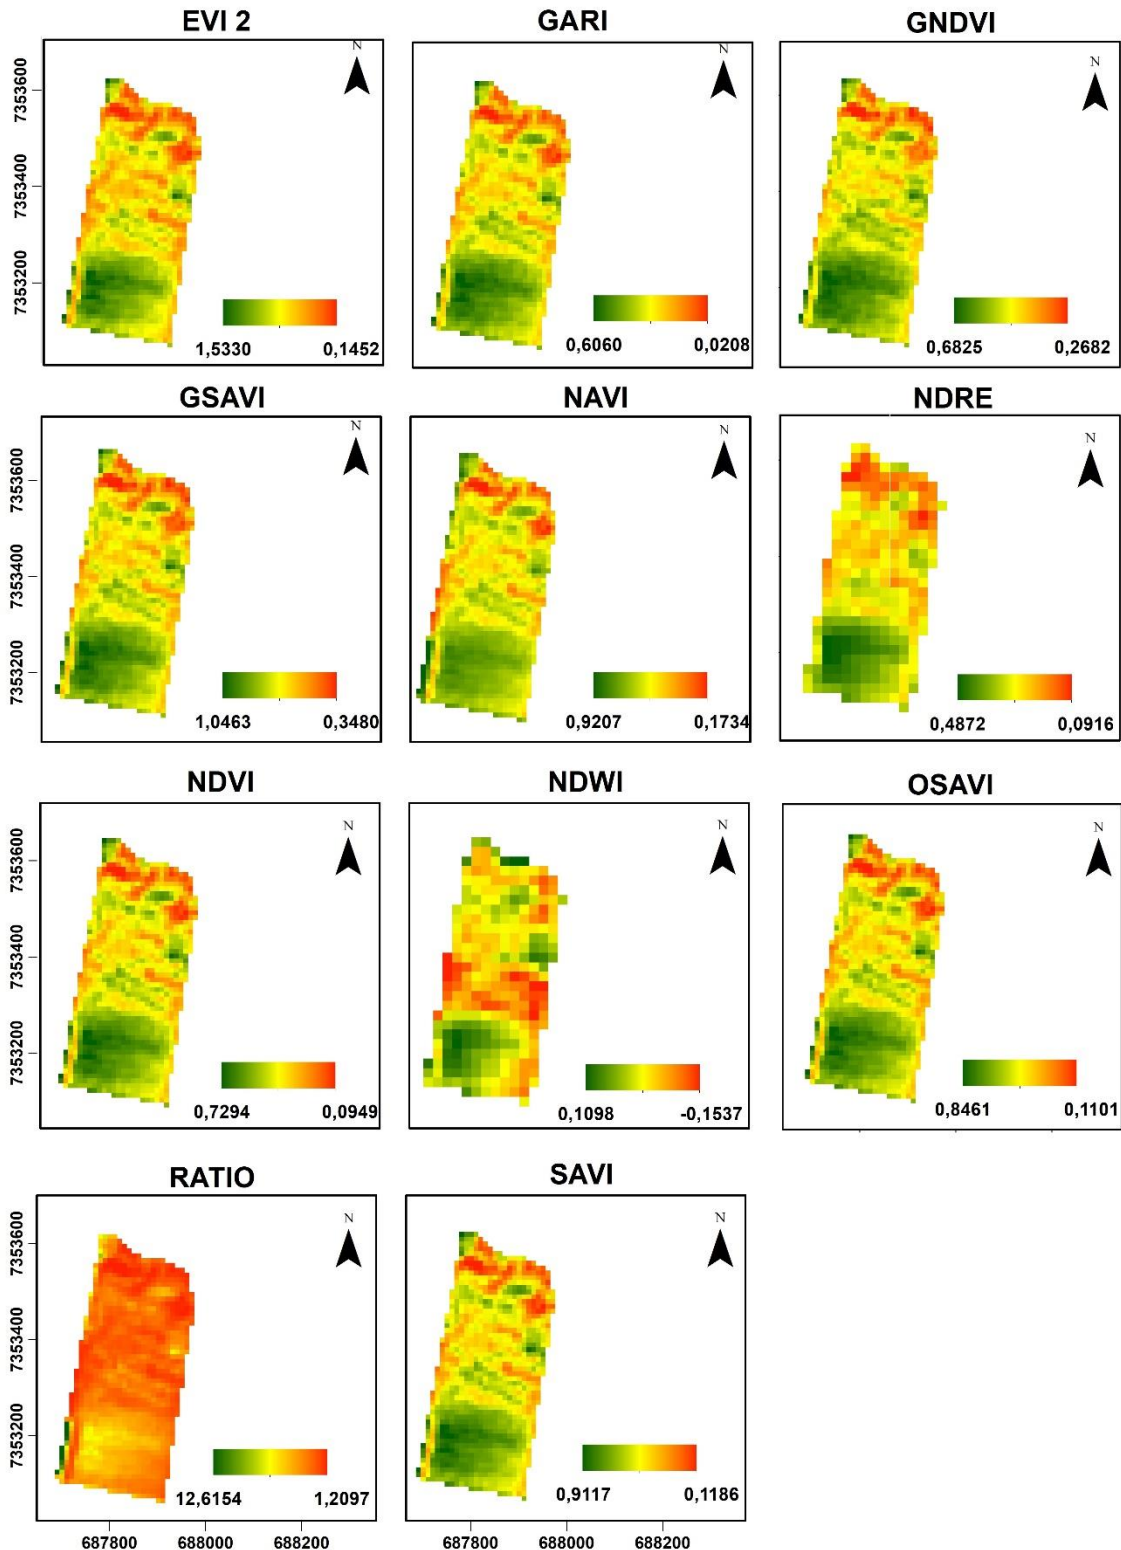
APÊNDICE AH - Índices calculados para o talhão 8 do mês de dezembro de 2019

TALHÃO 8 - DEZEMBRO 2019



APÊNDICE AI - Índices calculados para o talhão 9 do mês de dezembro de 2019

TALHÃO 9 - DEZEMBRO 2019

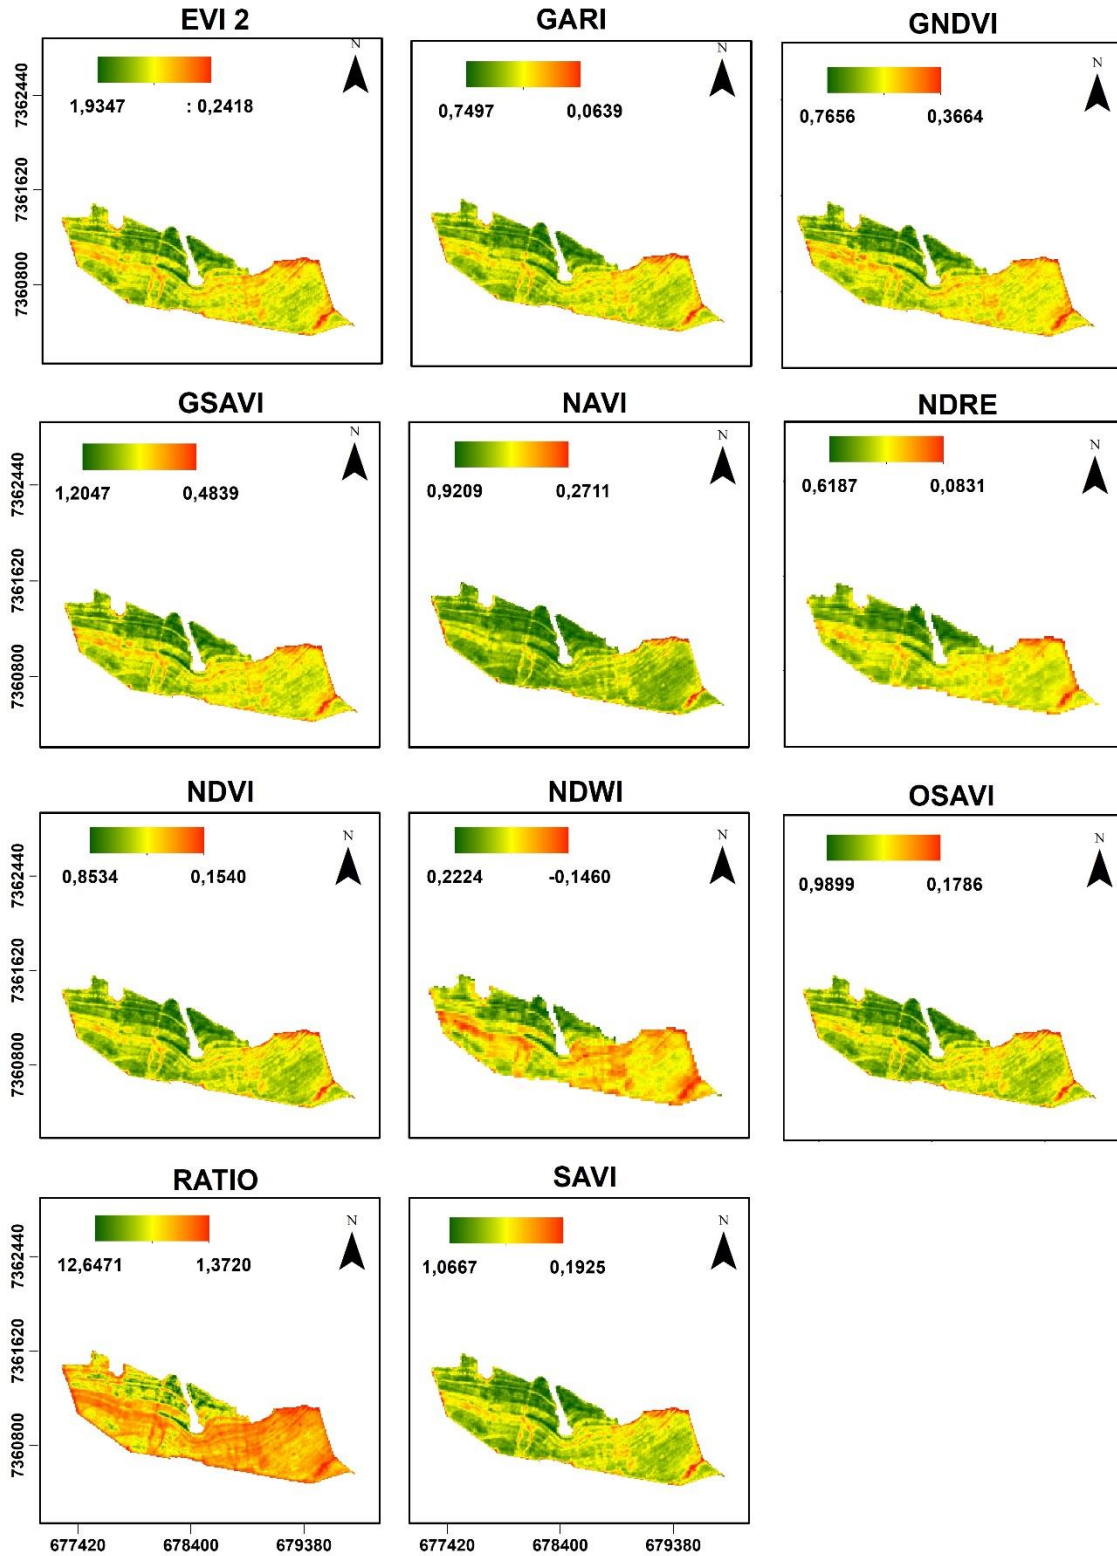


SIRGAS 2000 UTM 22S 0 75 150 300 450 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AJ - Índices calculados para o talhão 10 do mês de dezembro de 2019

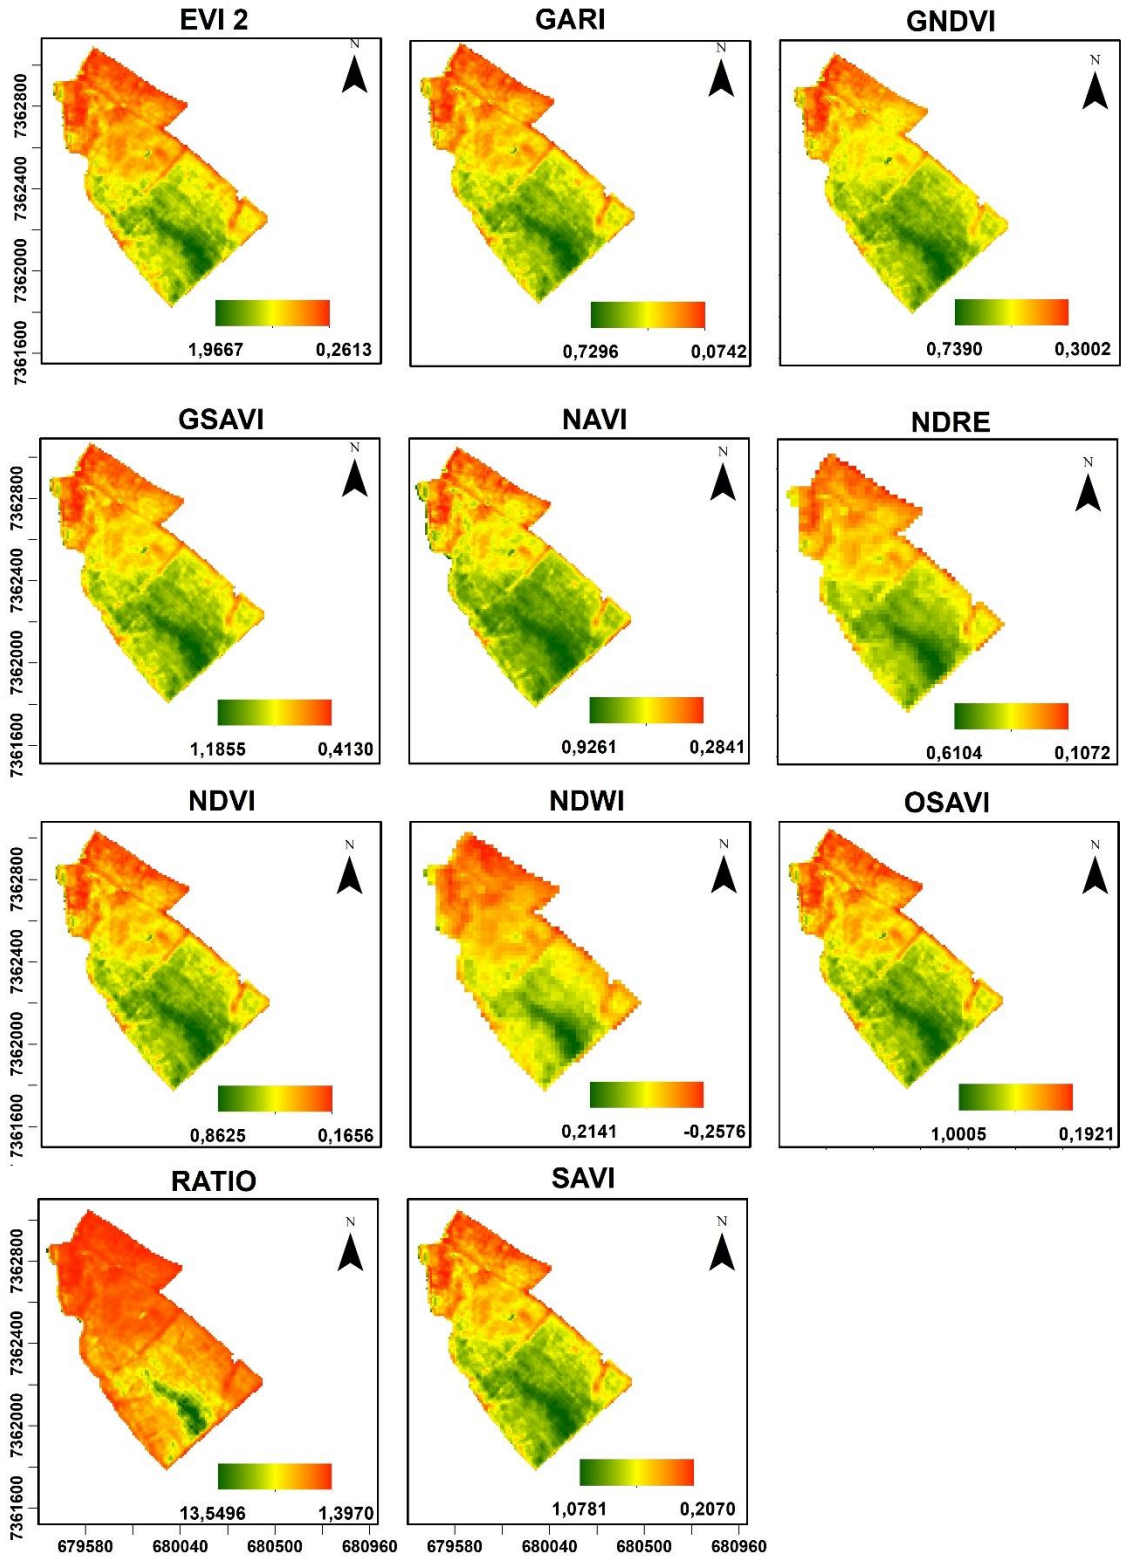
TALHÃO 10 - DEZEMBRO 2019



SIRGAS 2000 UTM 22S 0 300600 1.200 1.800 Metros

APÊNDICE AK - Índices calculados para o talhão 11 do mês de dezembro de 2019

TALHÃO 11 - DEZEMBRO 2019

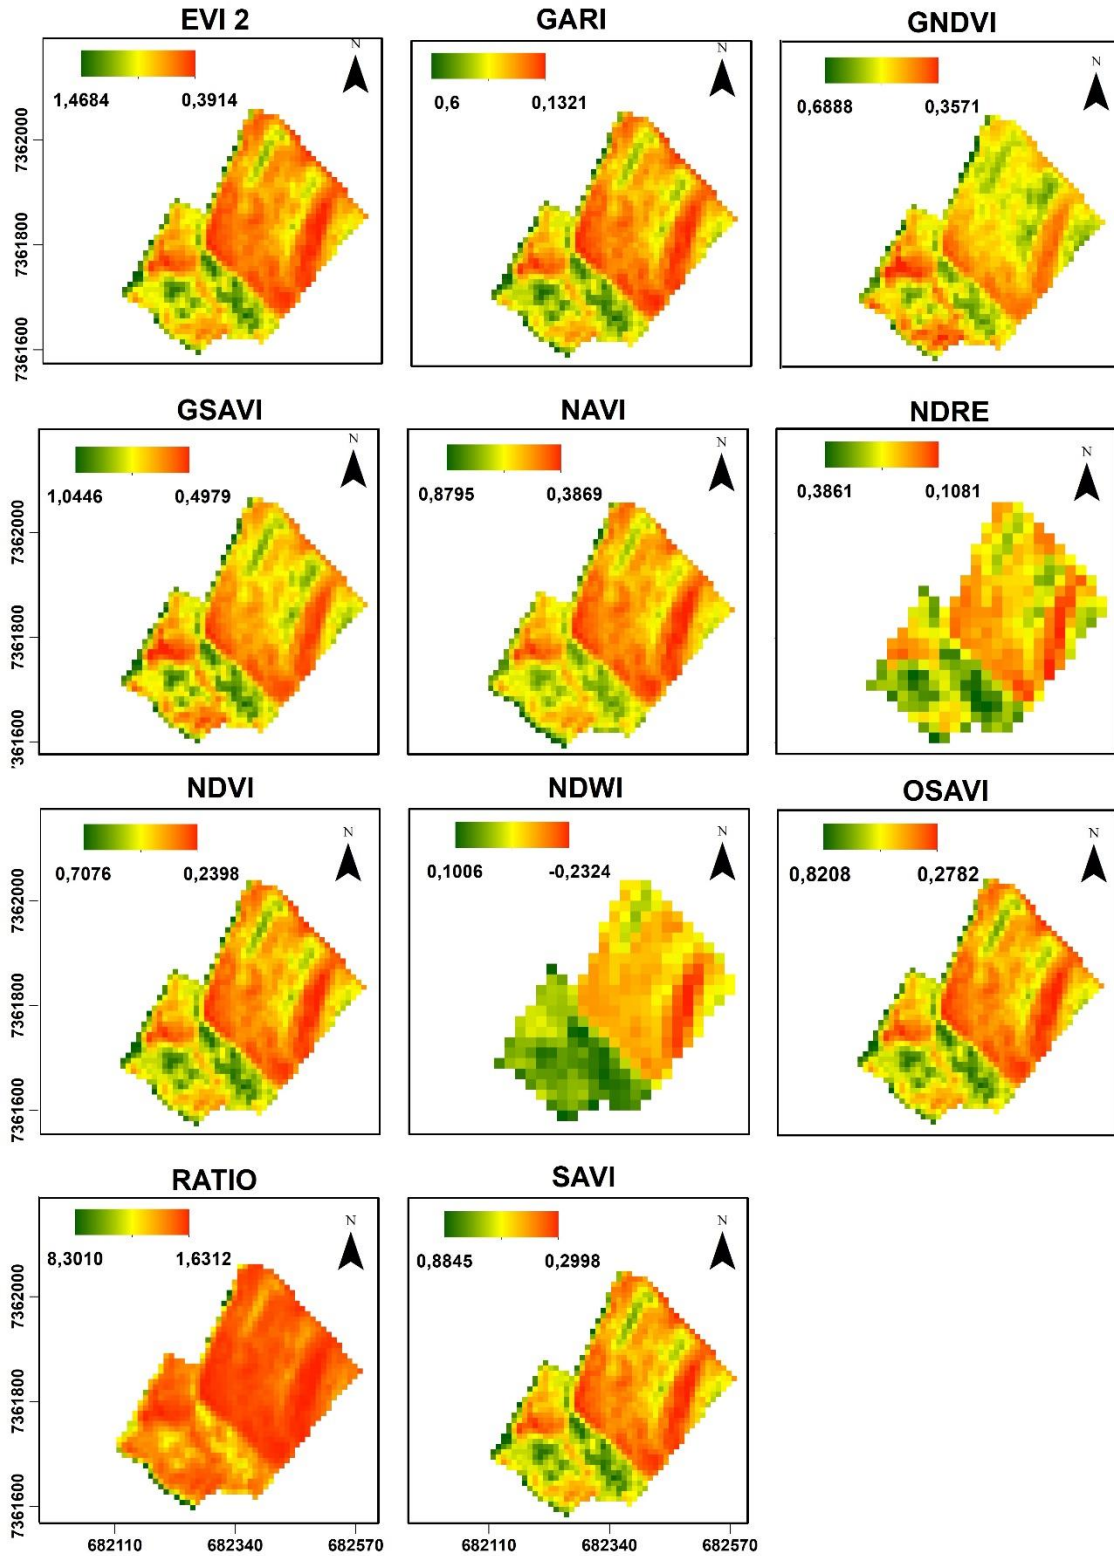


SIRGAS 2000 UTM 22S 0 205 410 820 1.230 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AL - Índices calculados para o talhão 12 do mês de dezembro de 2019

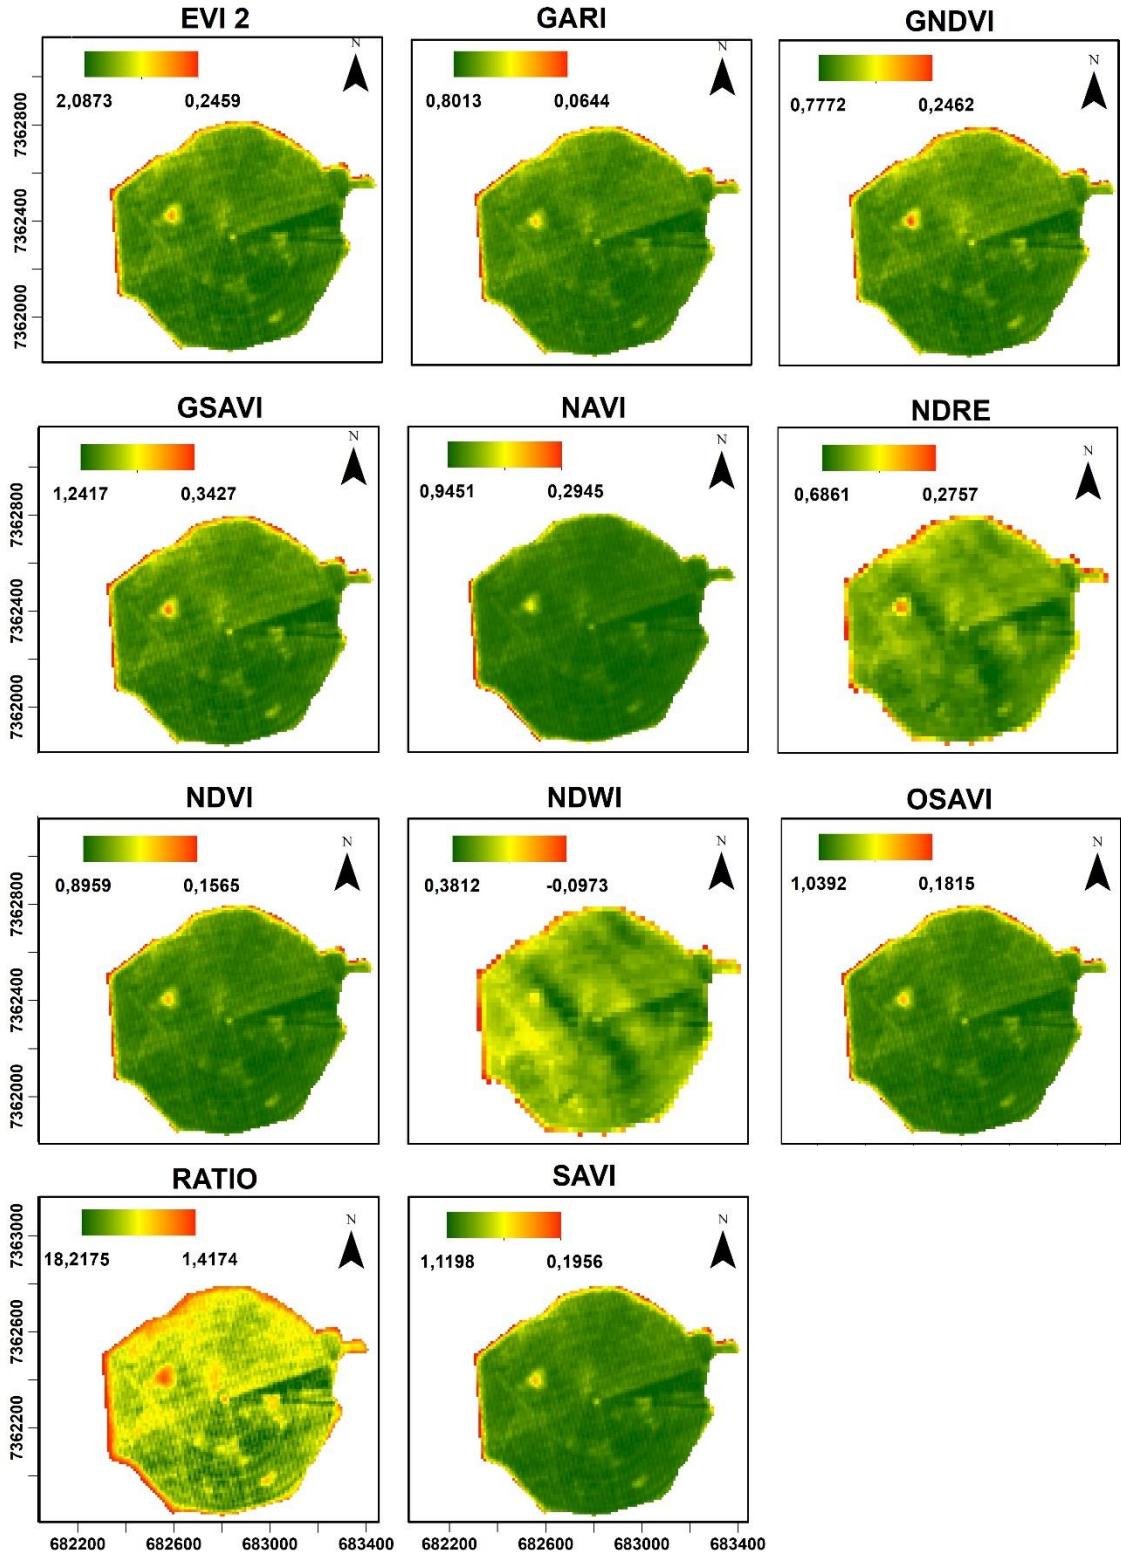
TALHÃO 12 - DEZEMBRO 2019



SIRGAS 2000 UTM 22S 0 55 110 220 330 Metros

APÊNDICE AM - Índices calculados para o talhão 13 do mês de dezembro de 2019

TALHÃO 13 - DEZEMBRO 2019

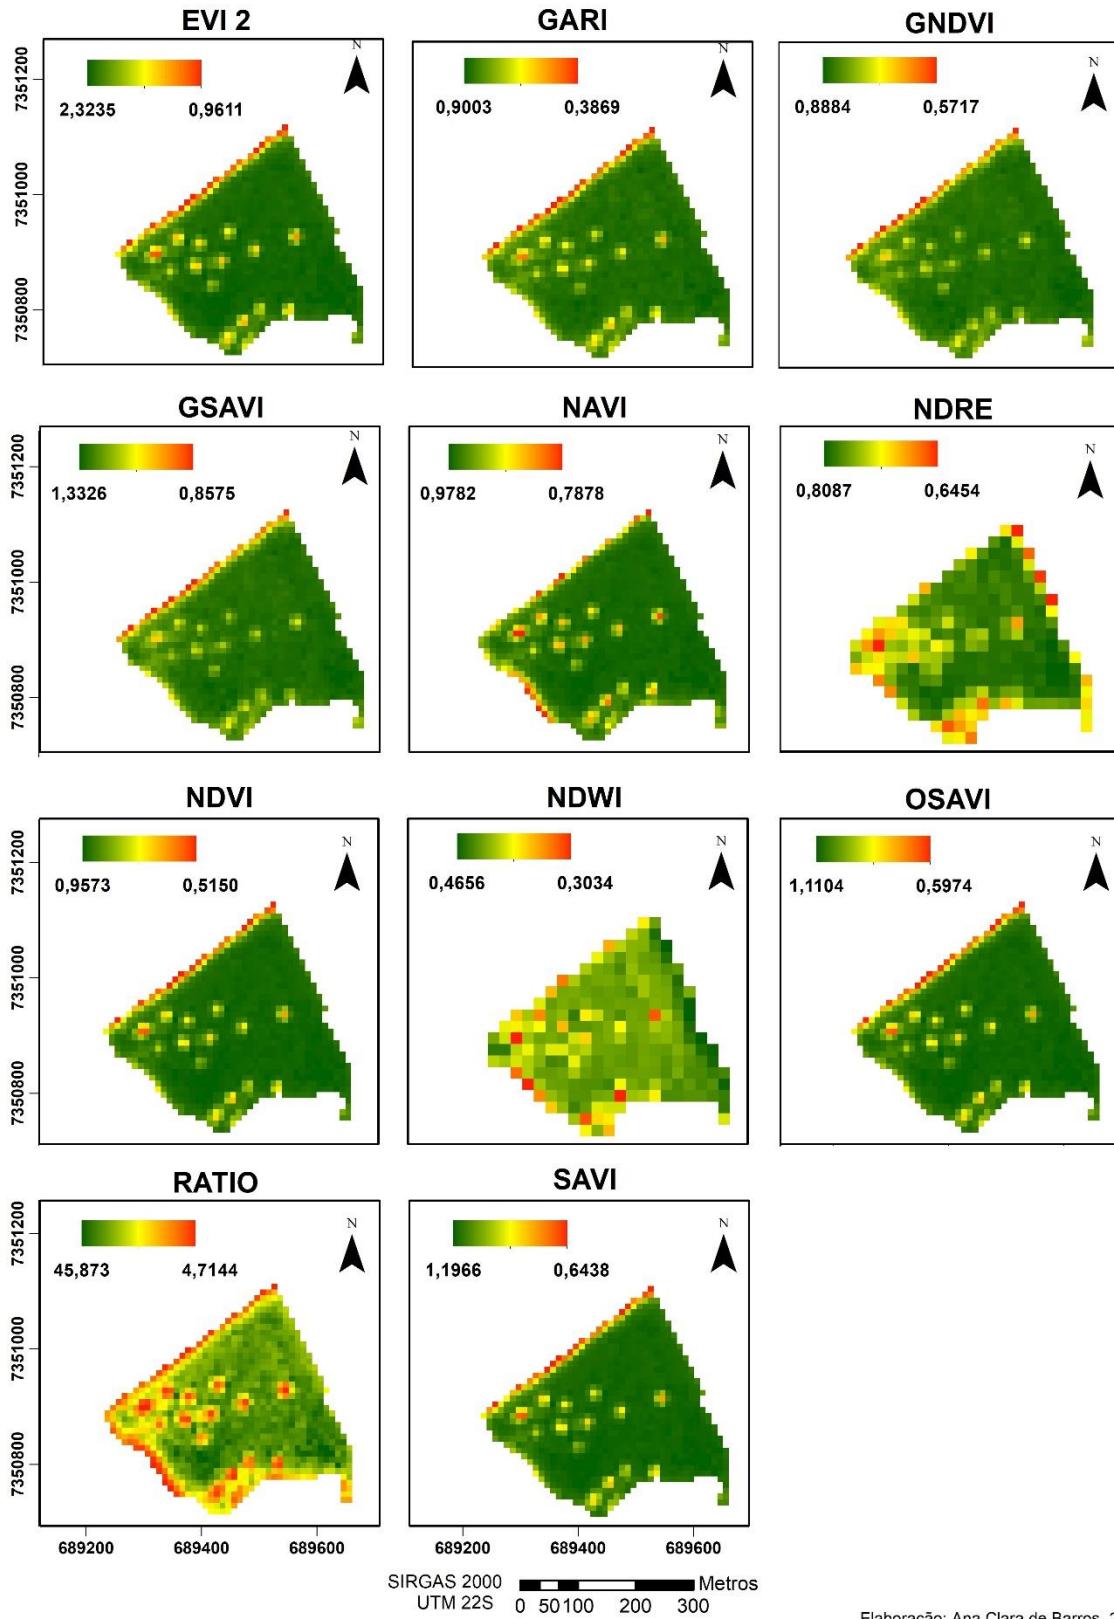


SIRGAS 2000 UTM 22S 0 180 360 720 1.080 Metros

Elaboração: Ana Clara de Barros, 2021.

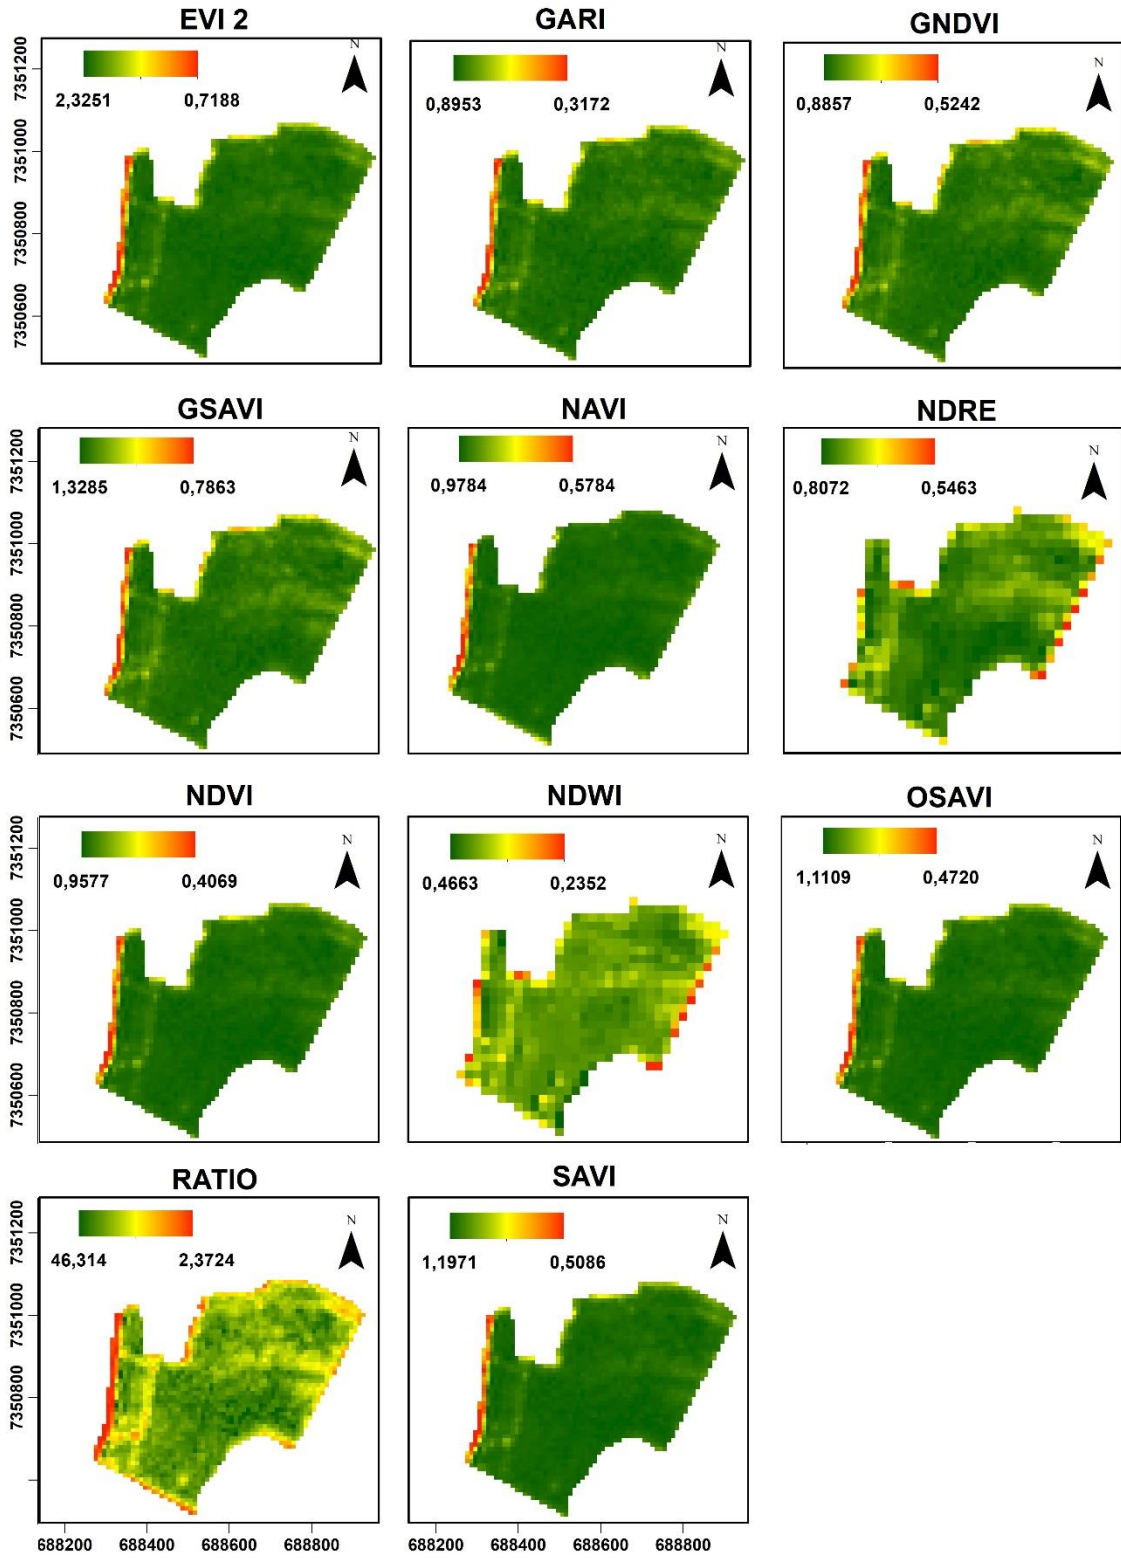
APÊNDICE AN - Índices calculados para o talhão 1 do mês de janeiro de 2020

TALHÃO 1 - JANEIRO 2020



APÊNDICE AO - Índices calculados para o talhão 2 do mês de janeiro de 2020

TALHÃO 2 - JANEIRO 2020

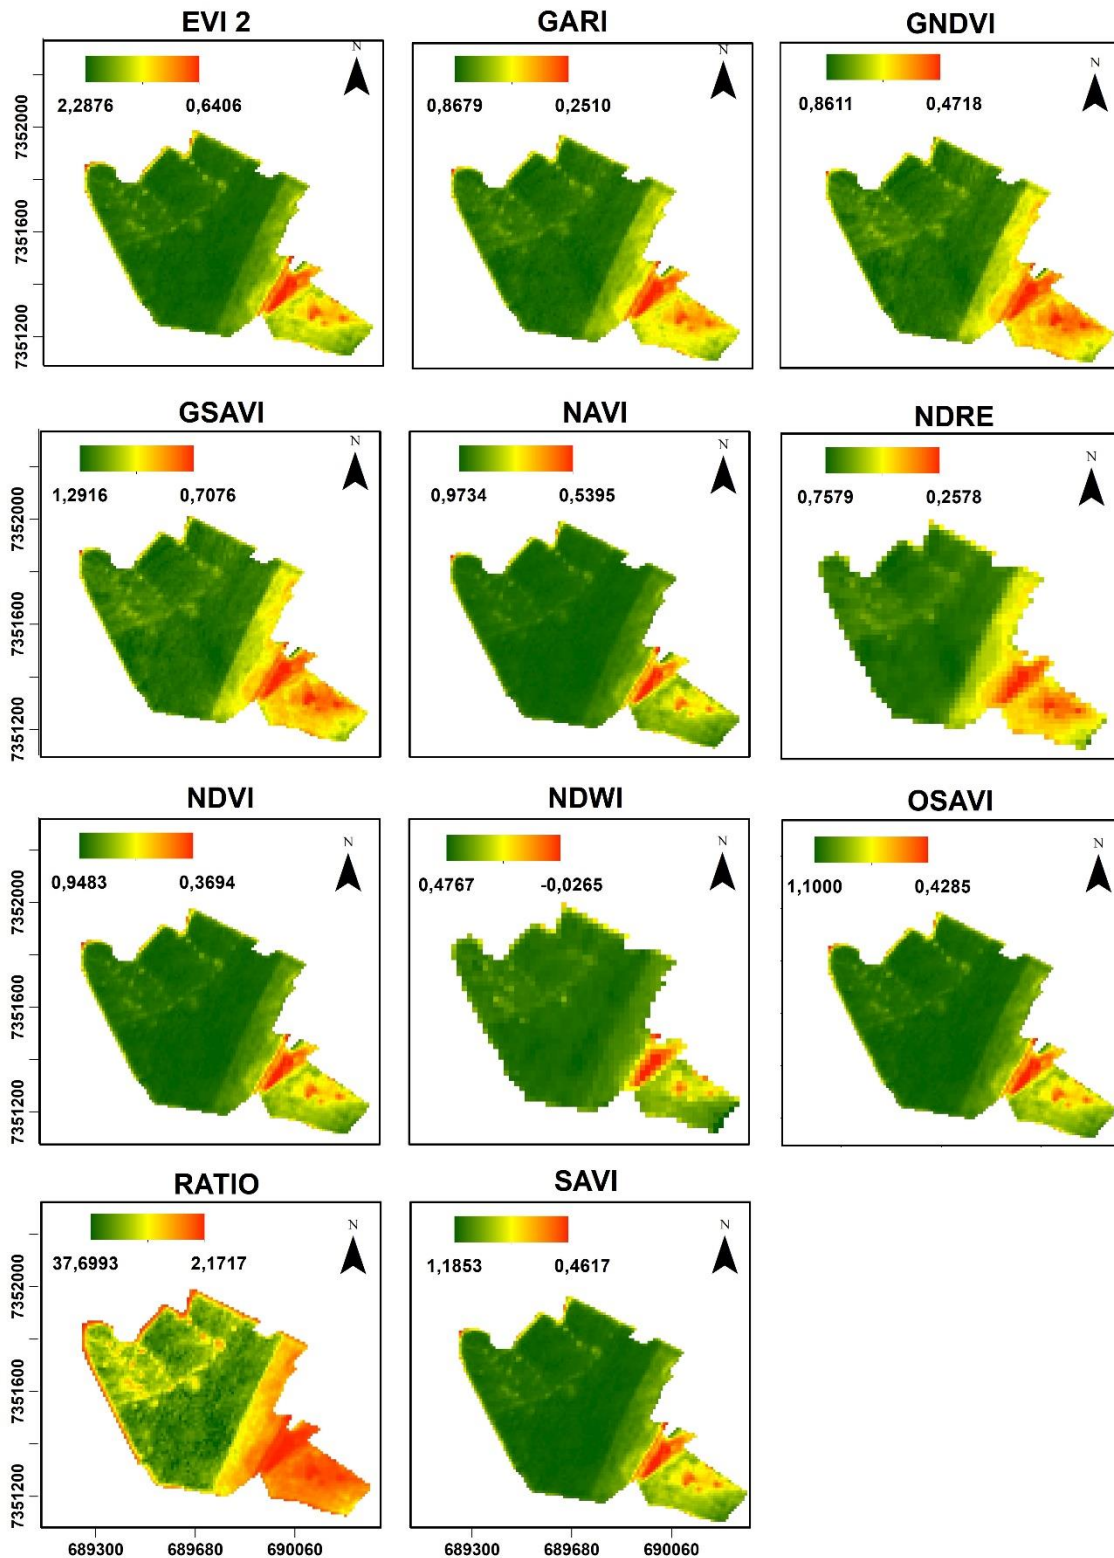


SIRGAS 2000 UTM 22S 0 80 160 320 480 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AP - Índices calculados para o talhão 3 do mês de janeiro de 2020

TALHÃO 3 - JANEIRO 2020

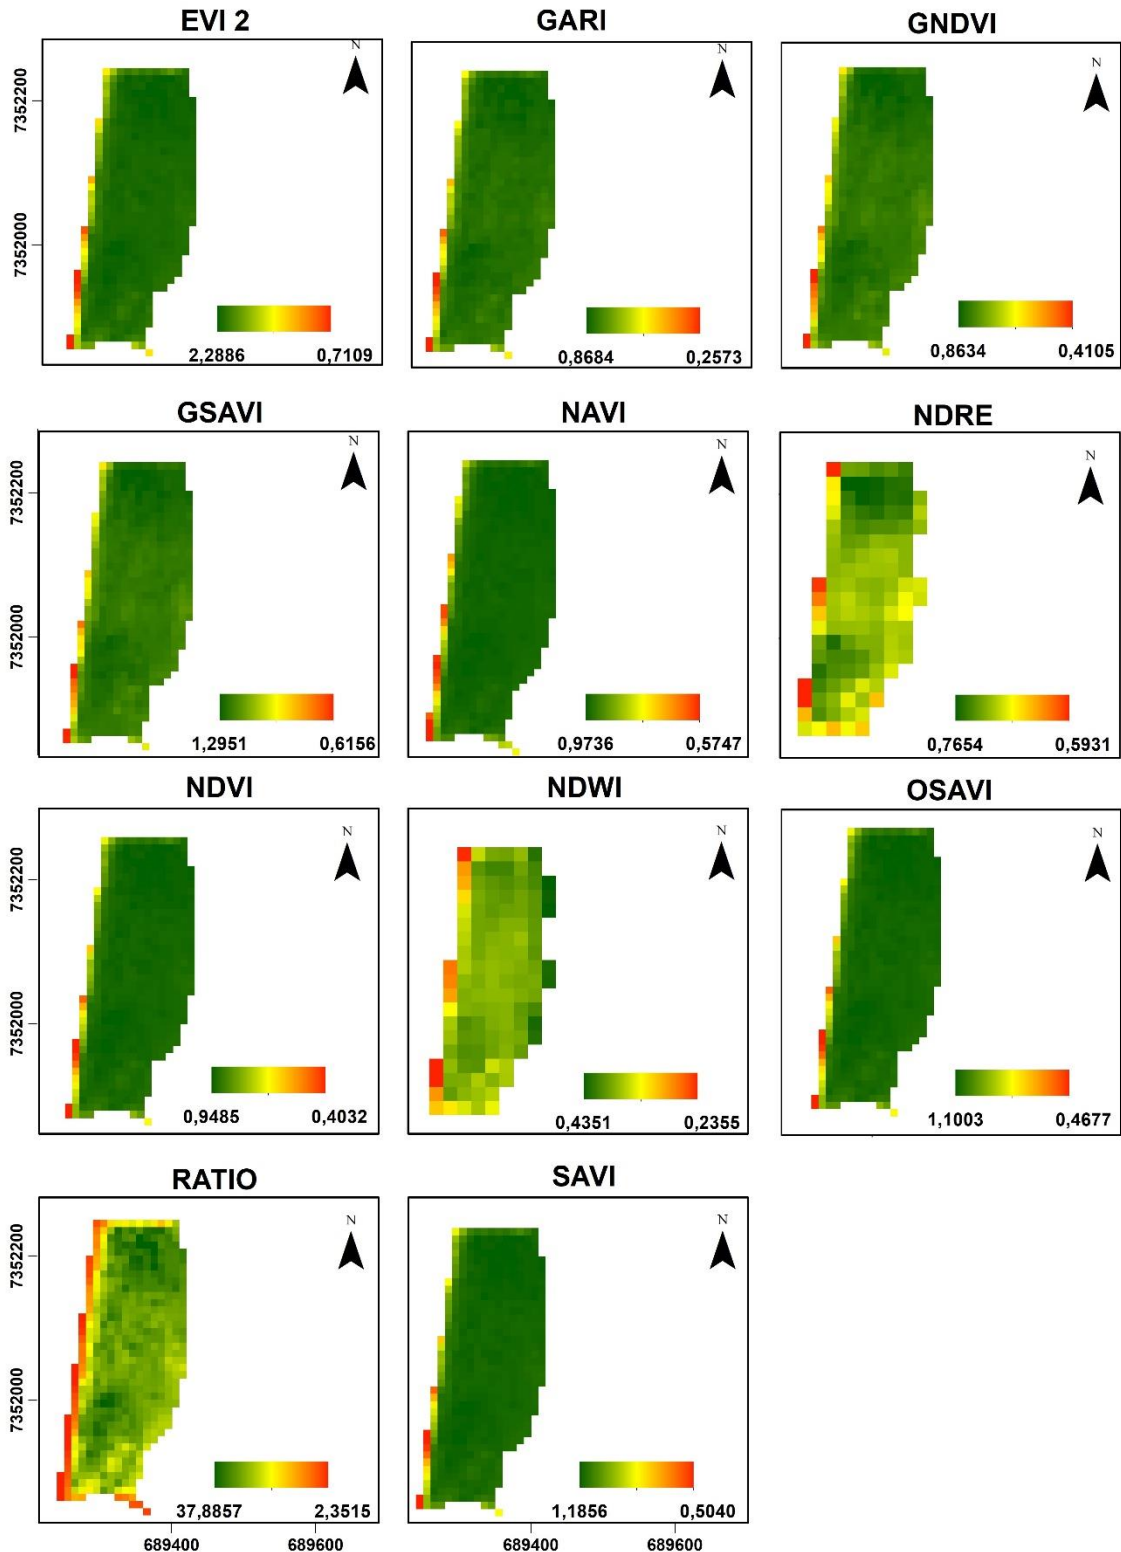


SIRGAS 2000 UTM 22S 0 150 300 600 900 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AQ- Índices calculados para o talhão 4 do mês de janeiro de 2020

TALHÃO 4 - DEZEMBRO 2020

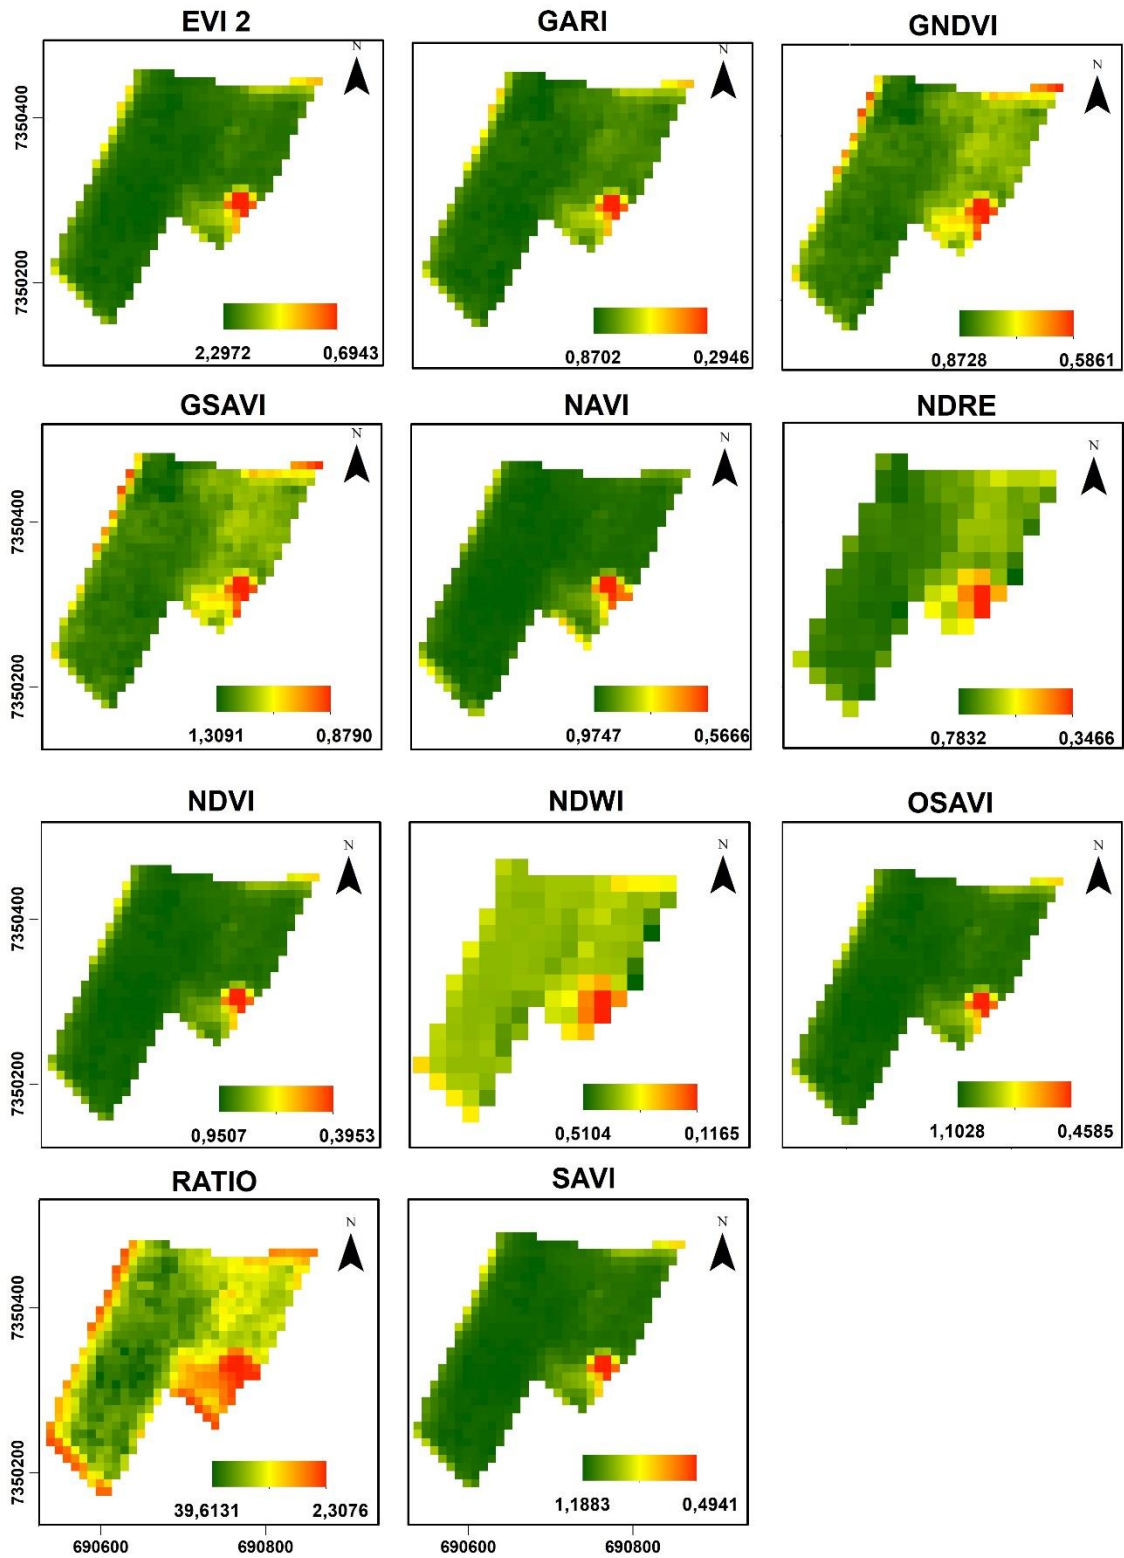


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AR - Índices calculados para o talhão 5 do mês de janeiro de 2020

TALHÃO 5 - JANEIRO 2020

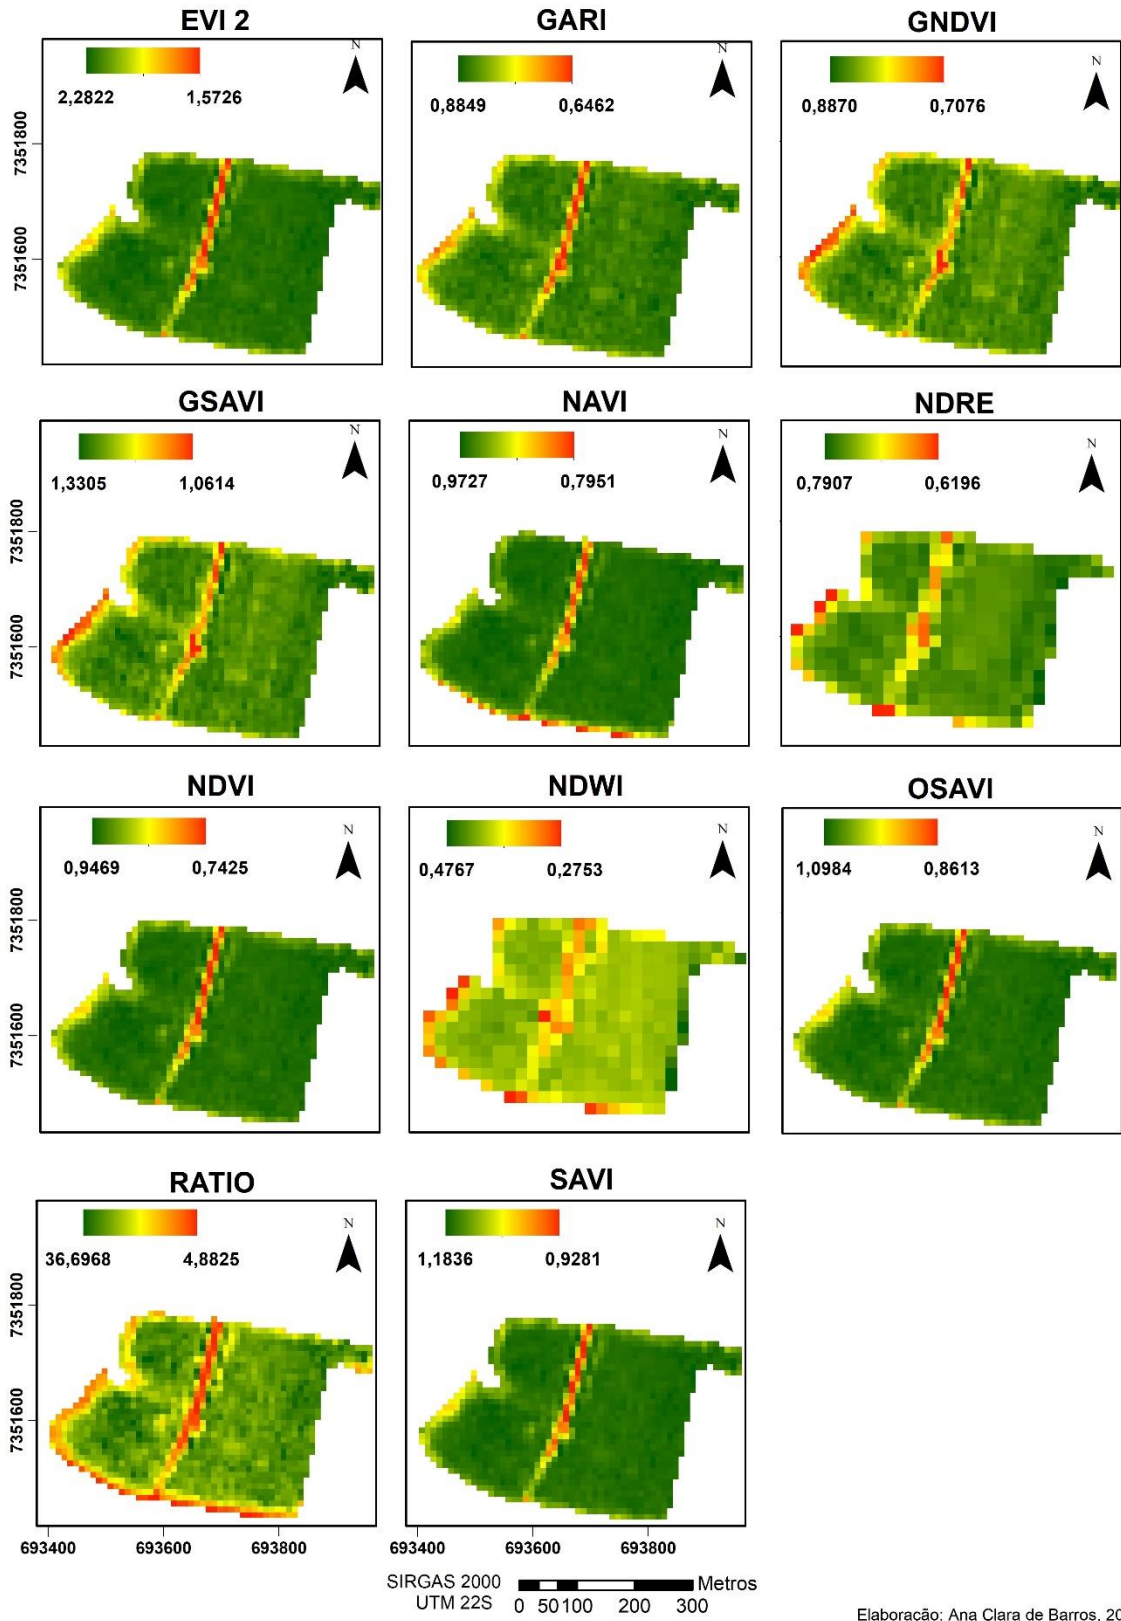


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

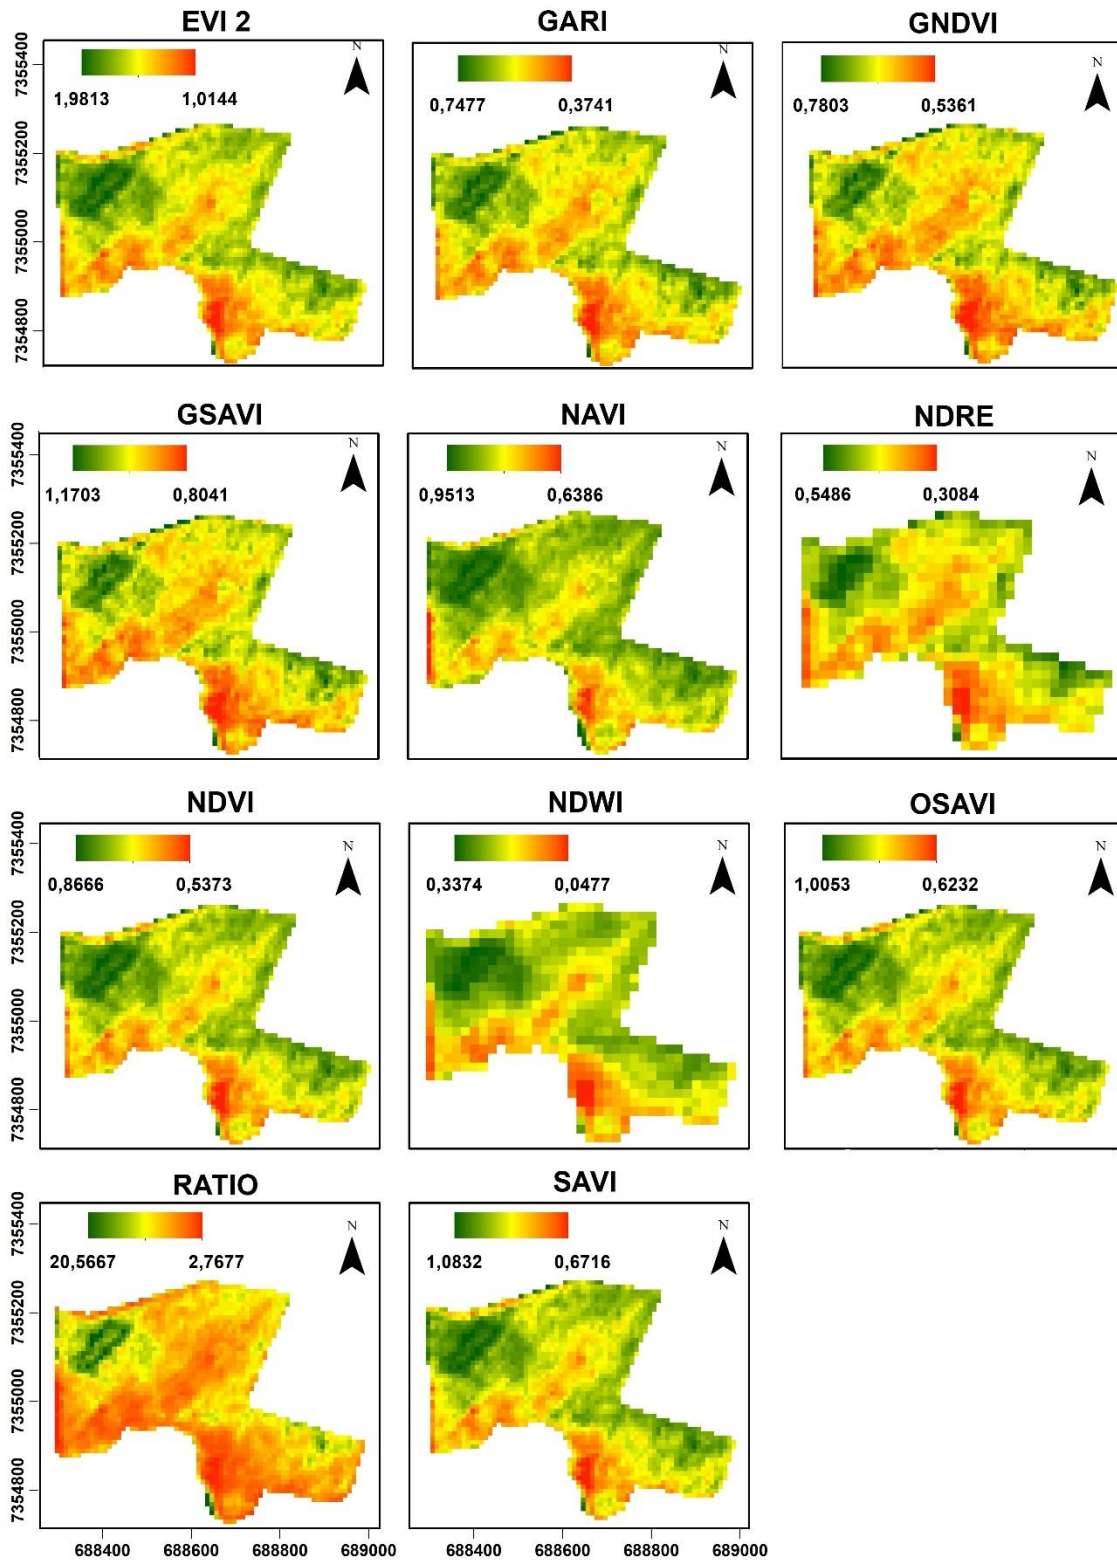
APÊNDICE AS - Índices calculados para o talhão 6 do mês de janeiro de 2020

TALHÃO 6 - JANEIRO 2020



APÊNDICE AT - Índices calculados para o talhão 7 do mês de janeiro de 2020

TALHÃO 7 - JANEIRO 2020

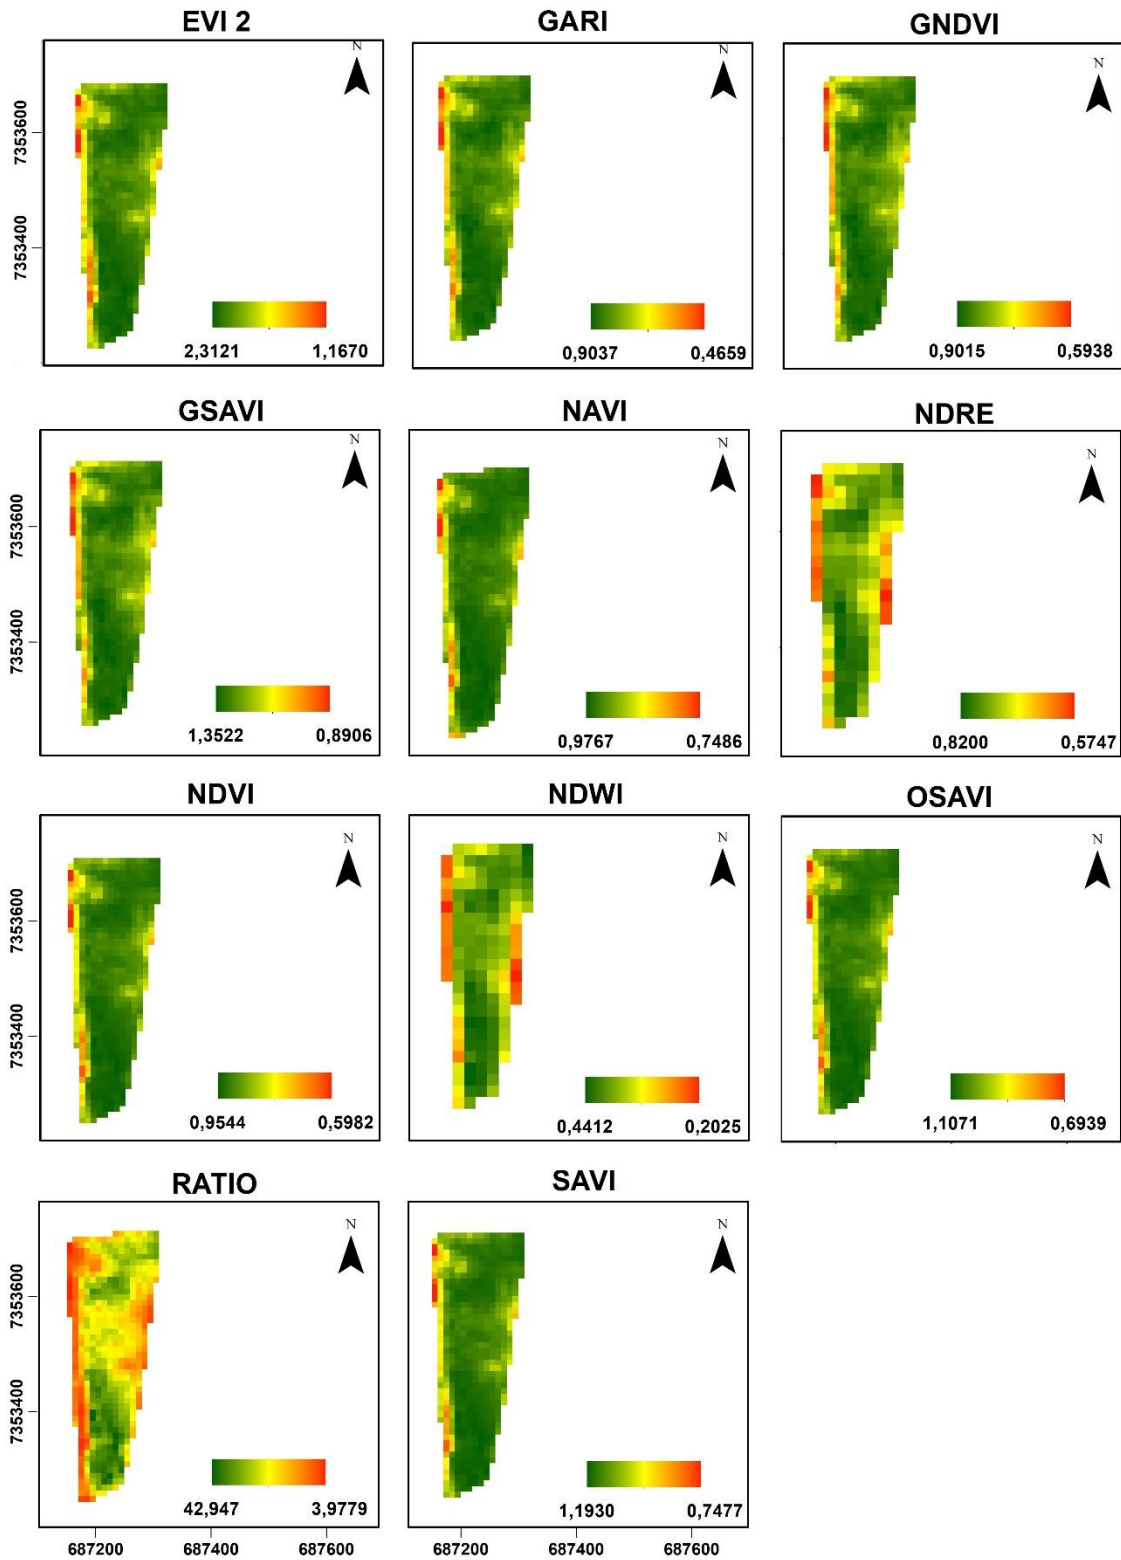


SIRGAS 2000 UTM 22S 0 100 200 400 600 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AU - Índices calculados para o talhão 8 do mês de janeiro de 2020

TALHÃO 8 - JANEIRO 2020

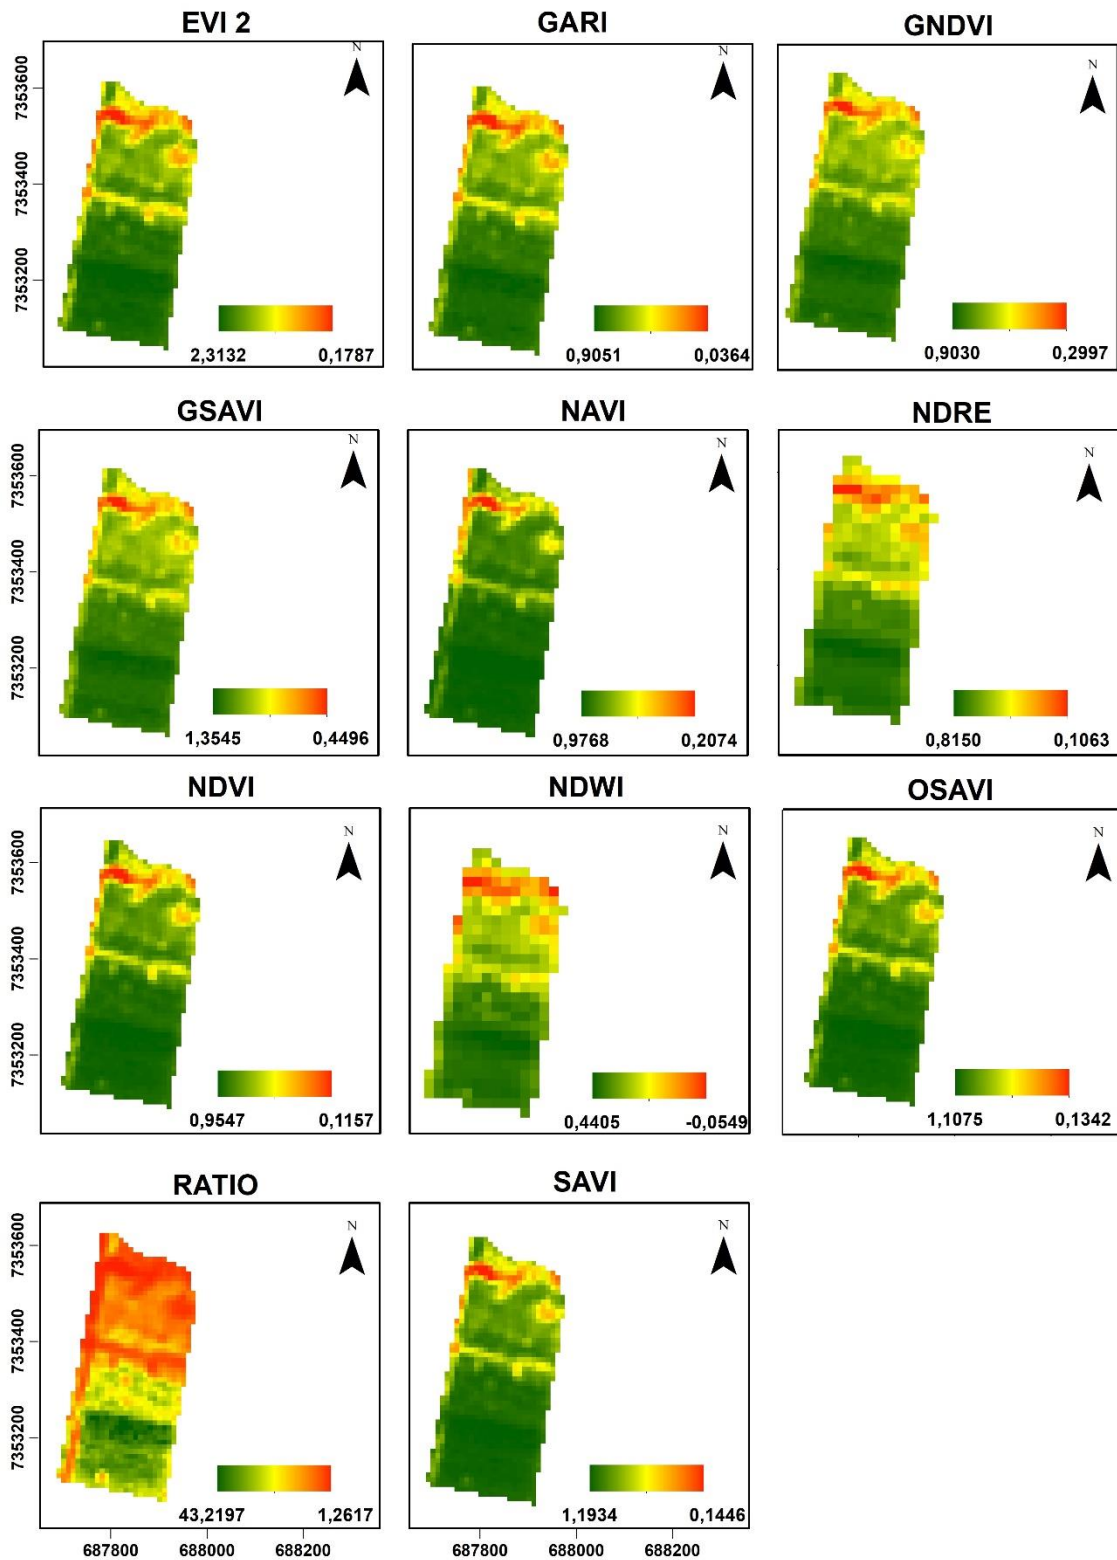


SIRGAS 2000 UTM 22S 0 65 130 260 390 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AV - Índices calculados para o talhão 9 do mês de janeiro de 2020

TALHÃO 9 - JANEIRO 2020

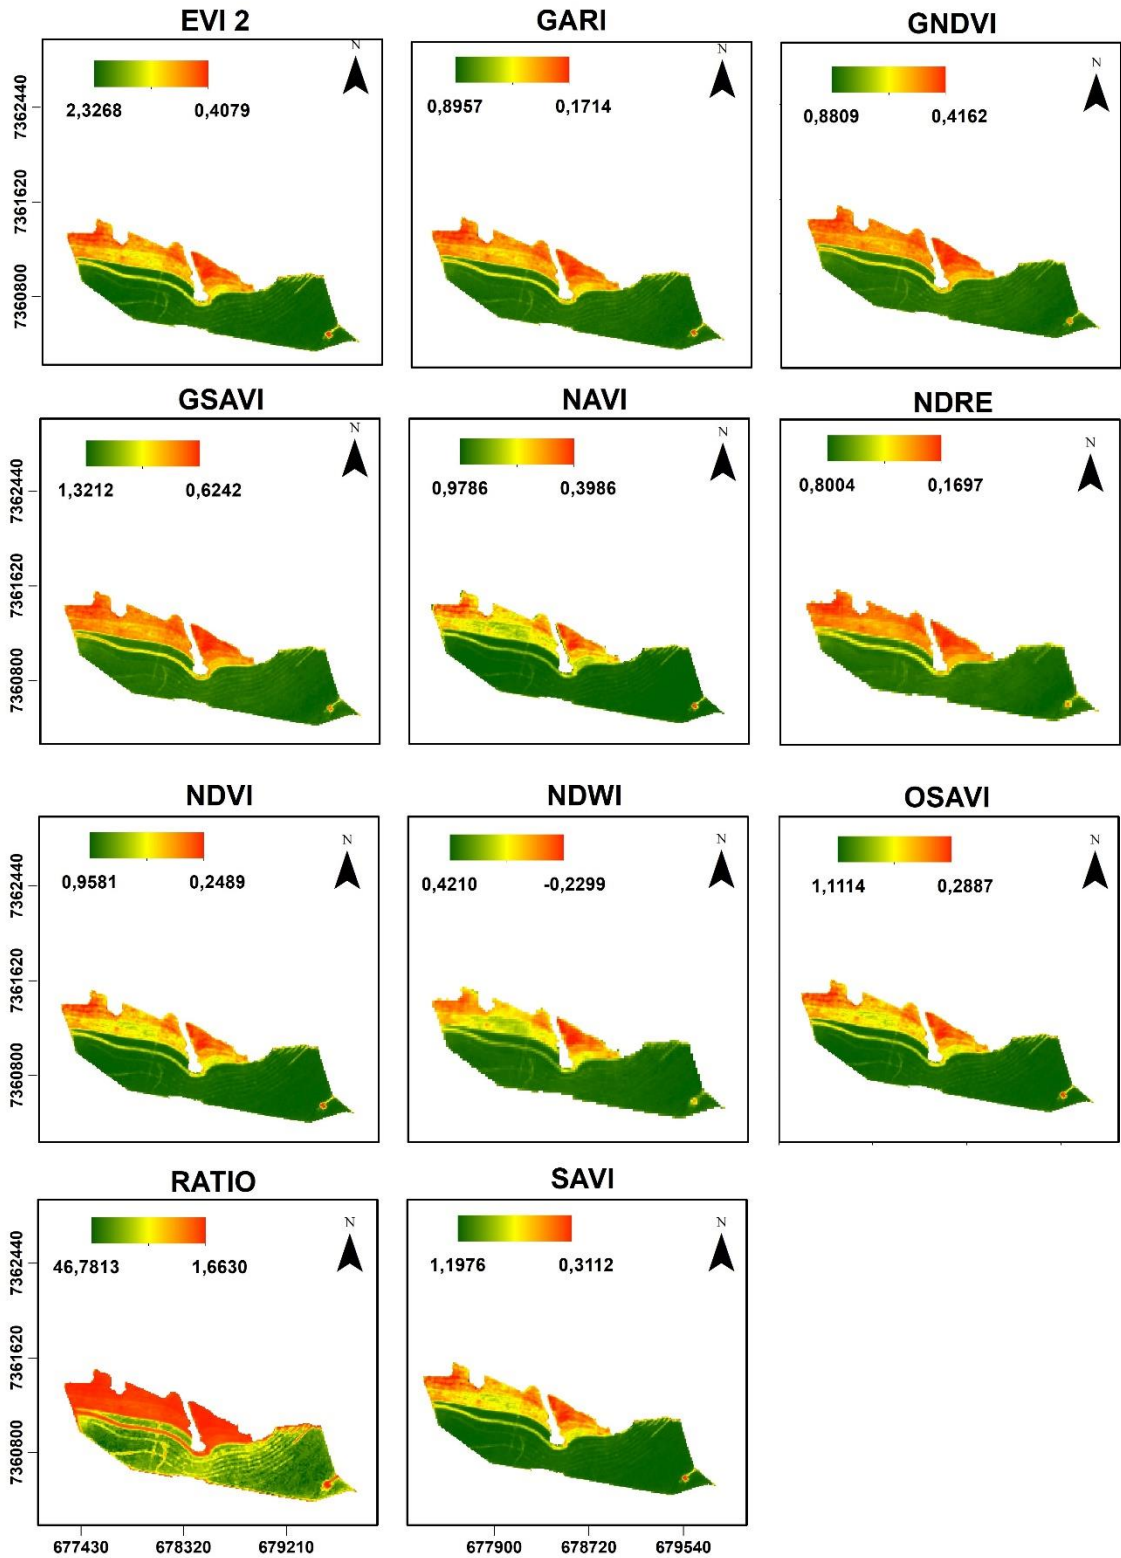


SIRGAS 2000 UTM 22S 0 75 150 300 450 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AW - Índices calculados para o talhão 10 do mês de janeiro de 2020

TALHÃO 10 - JANEIRO 2020

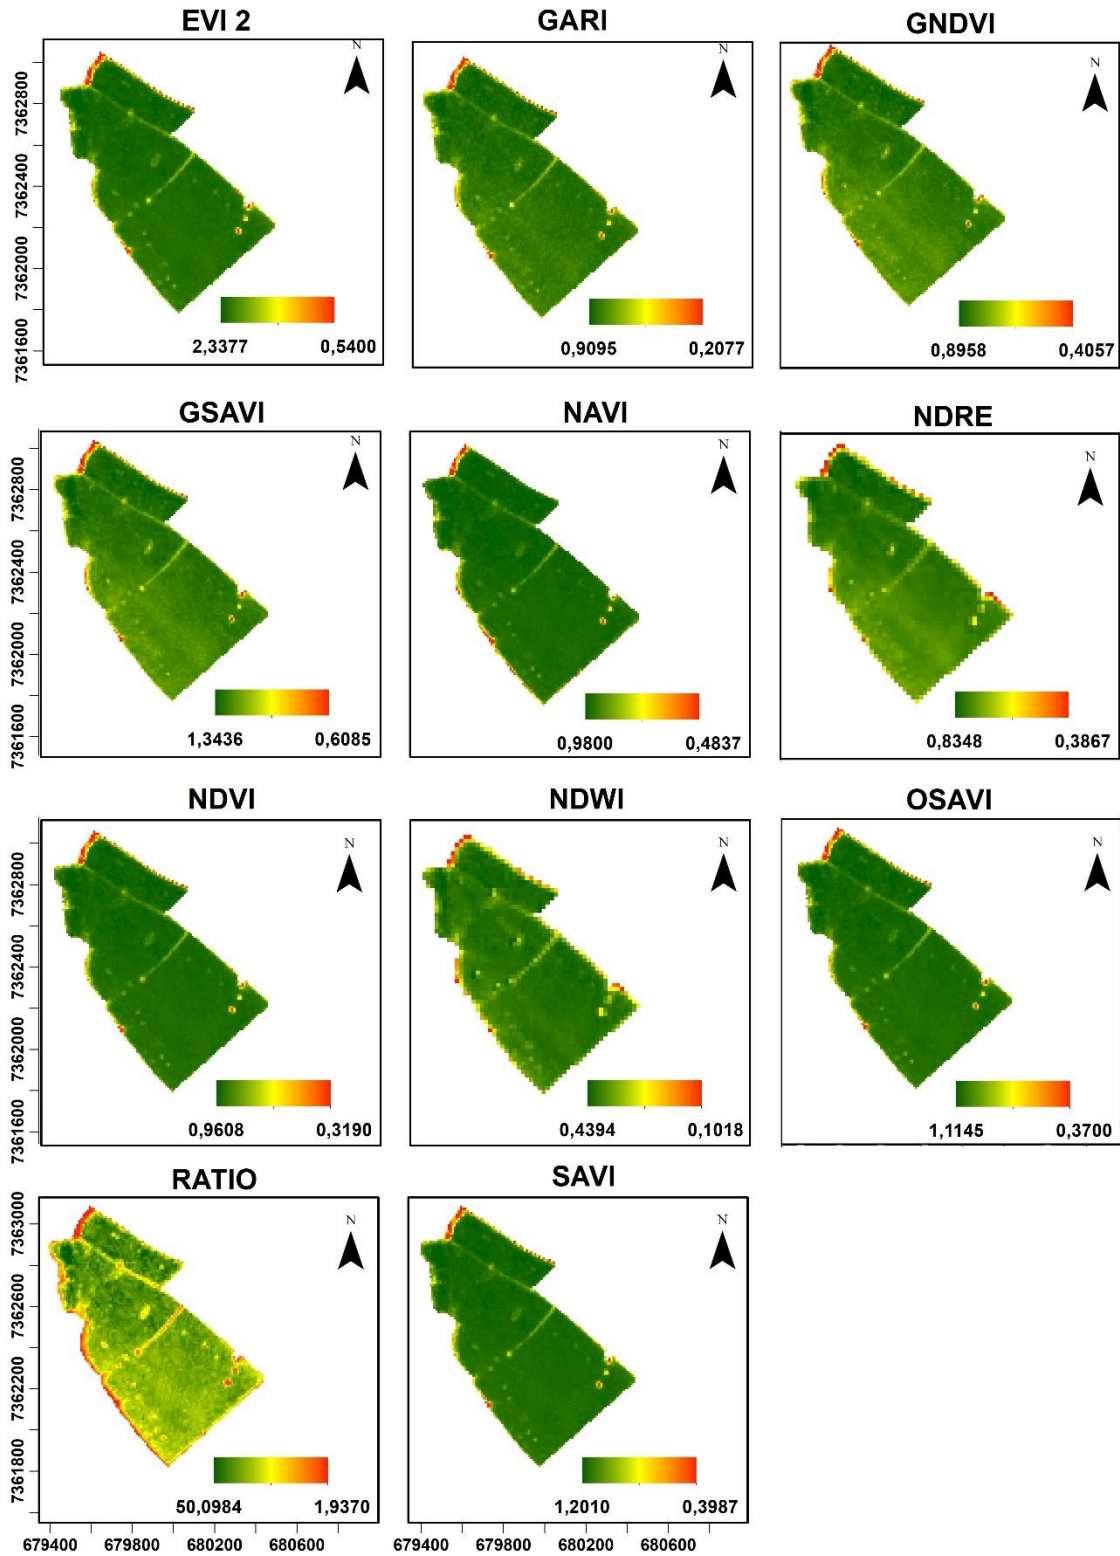


SIRGAS 2000 UTM 22S 0 300600 1.200 1.800 Metros

Elaboração: Ana Clara de Barros. 2021.

APÊNDICE AX - Índices calculados para o talhão 11 do mês de janeiro de 2020

TALHÃO 11 - JANEIRO 2020

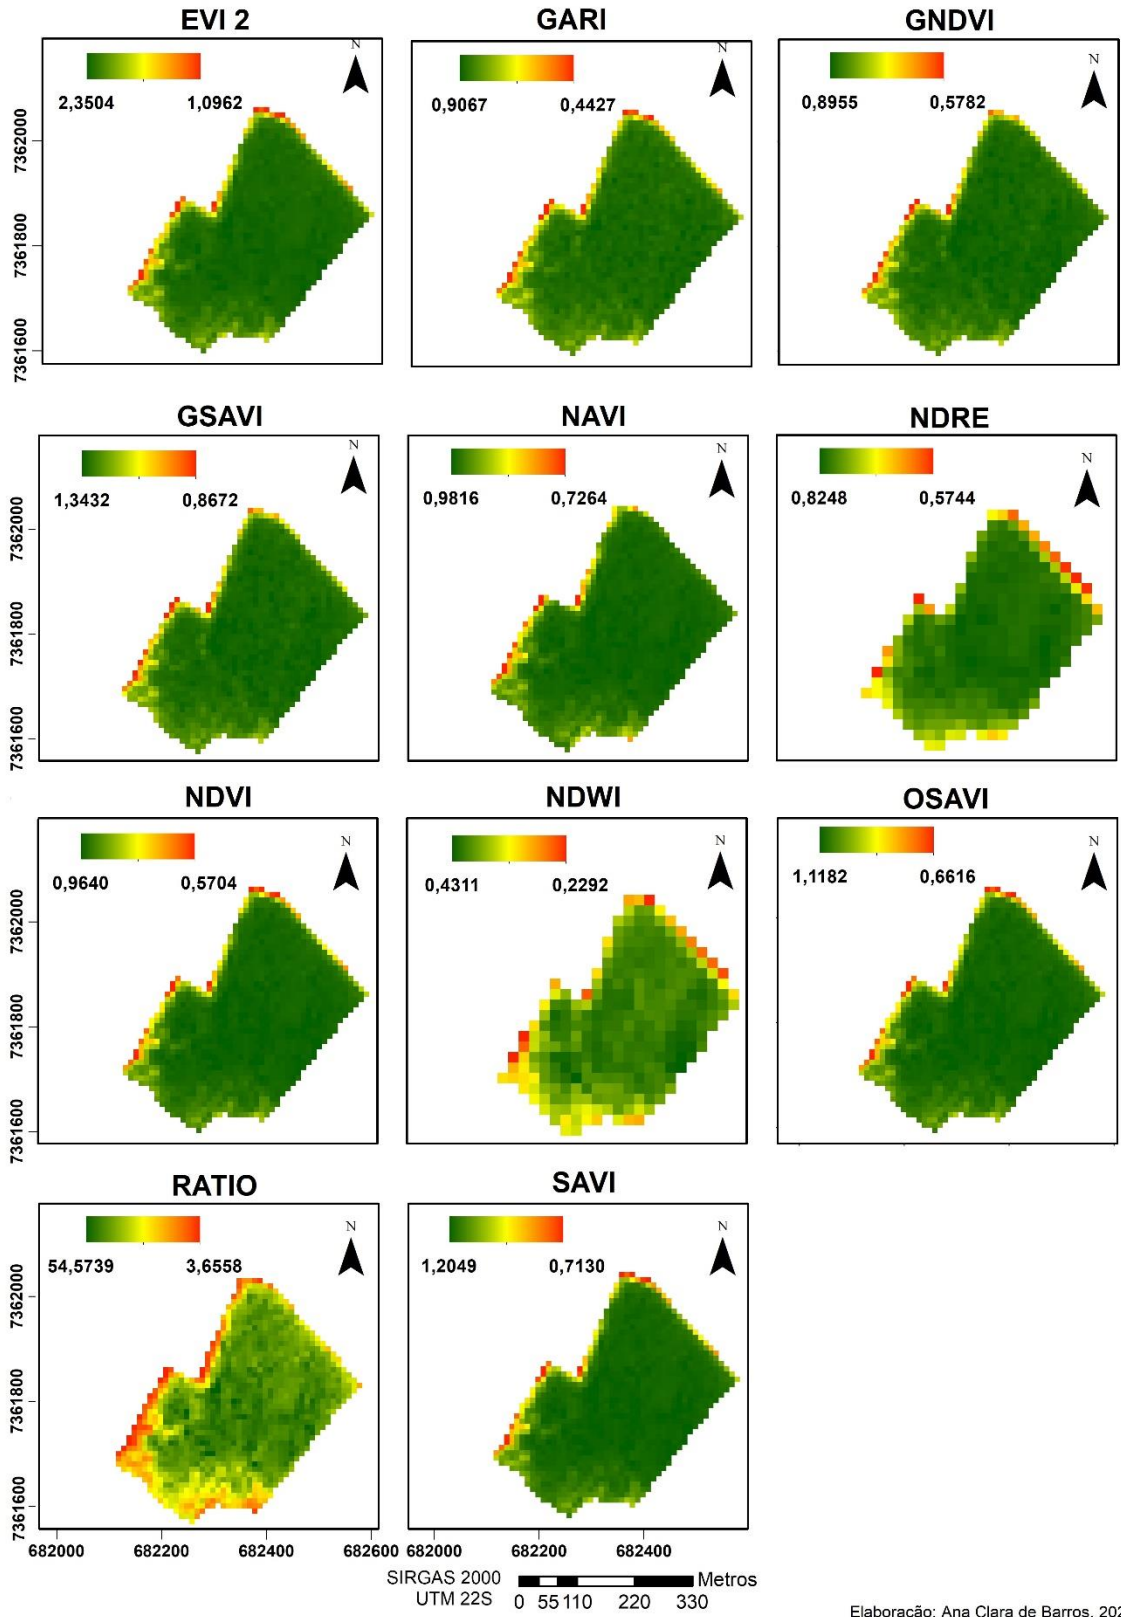


SIRGAS 2000 UTM 22S 0 205 410 820 1.230 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AY - Índices calculados para o talhão 12 do mês de janeiro de 2020

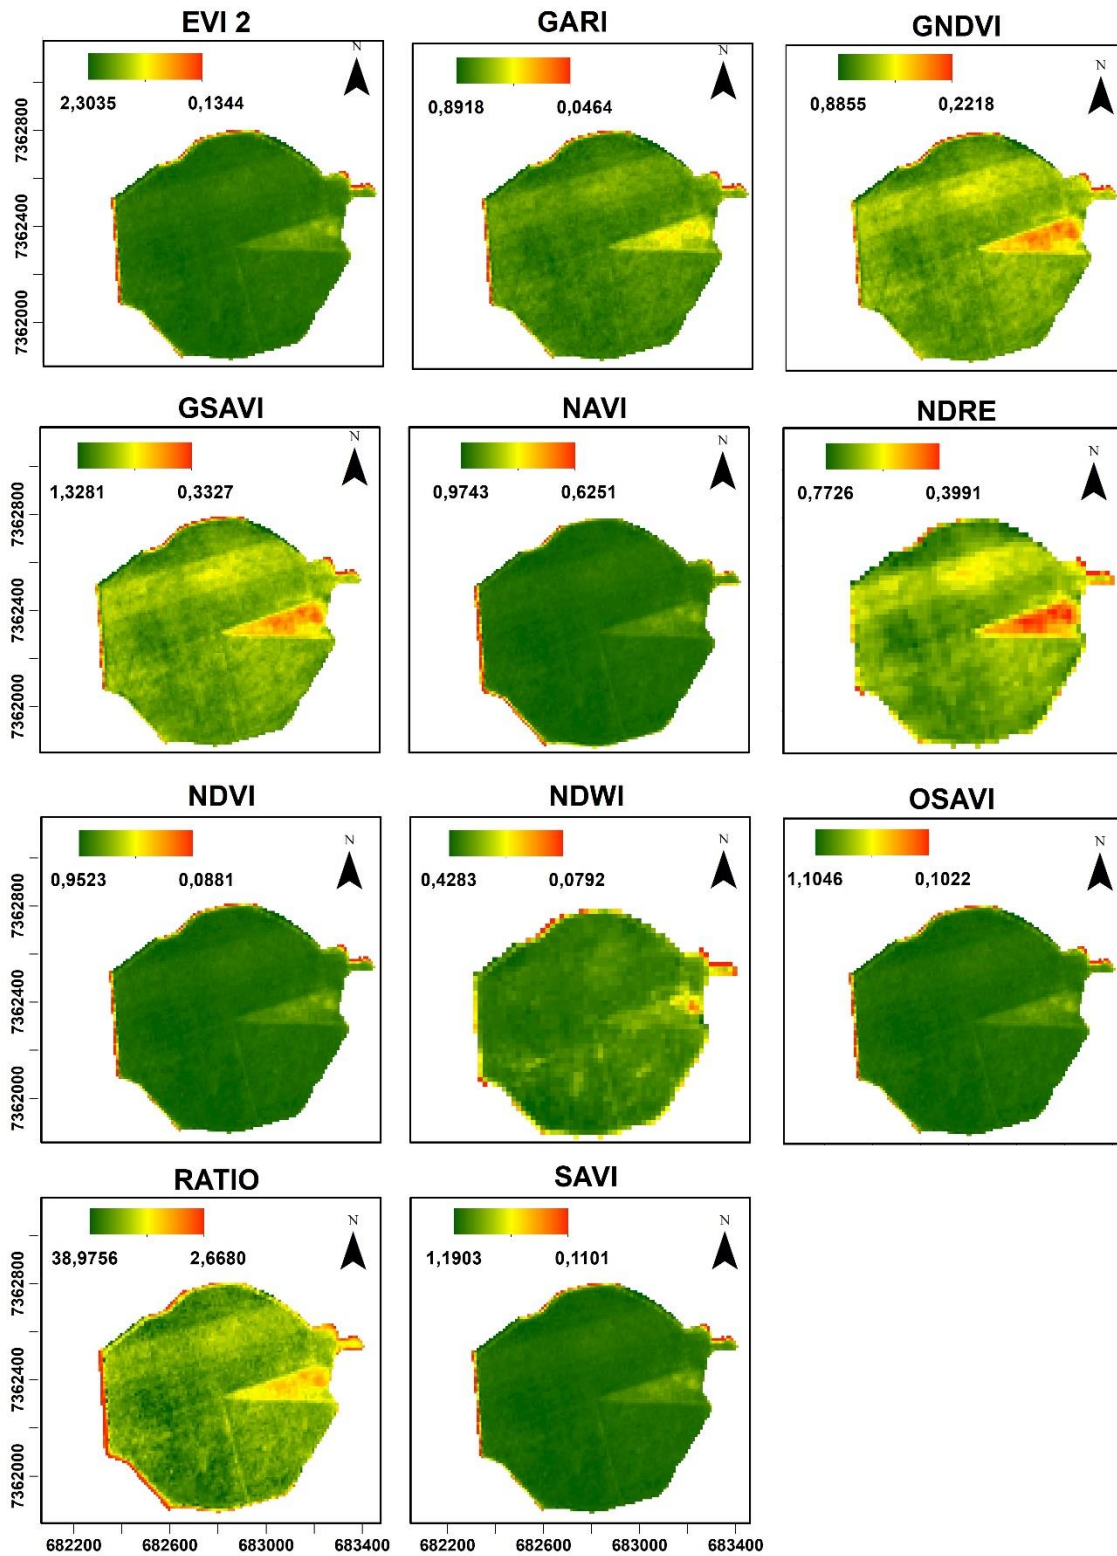
TALHÃO 12 - JANEIRO 2020



Elaboração: Ana Clara de Barros, 2021.

APÊNDICE AZ - Índices calculados para o talhão 13 do mês de janeiro de 2020

TALHÃO 13 - JANEIRO 2020

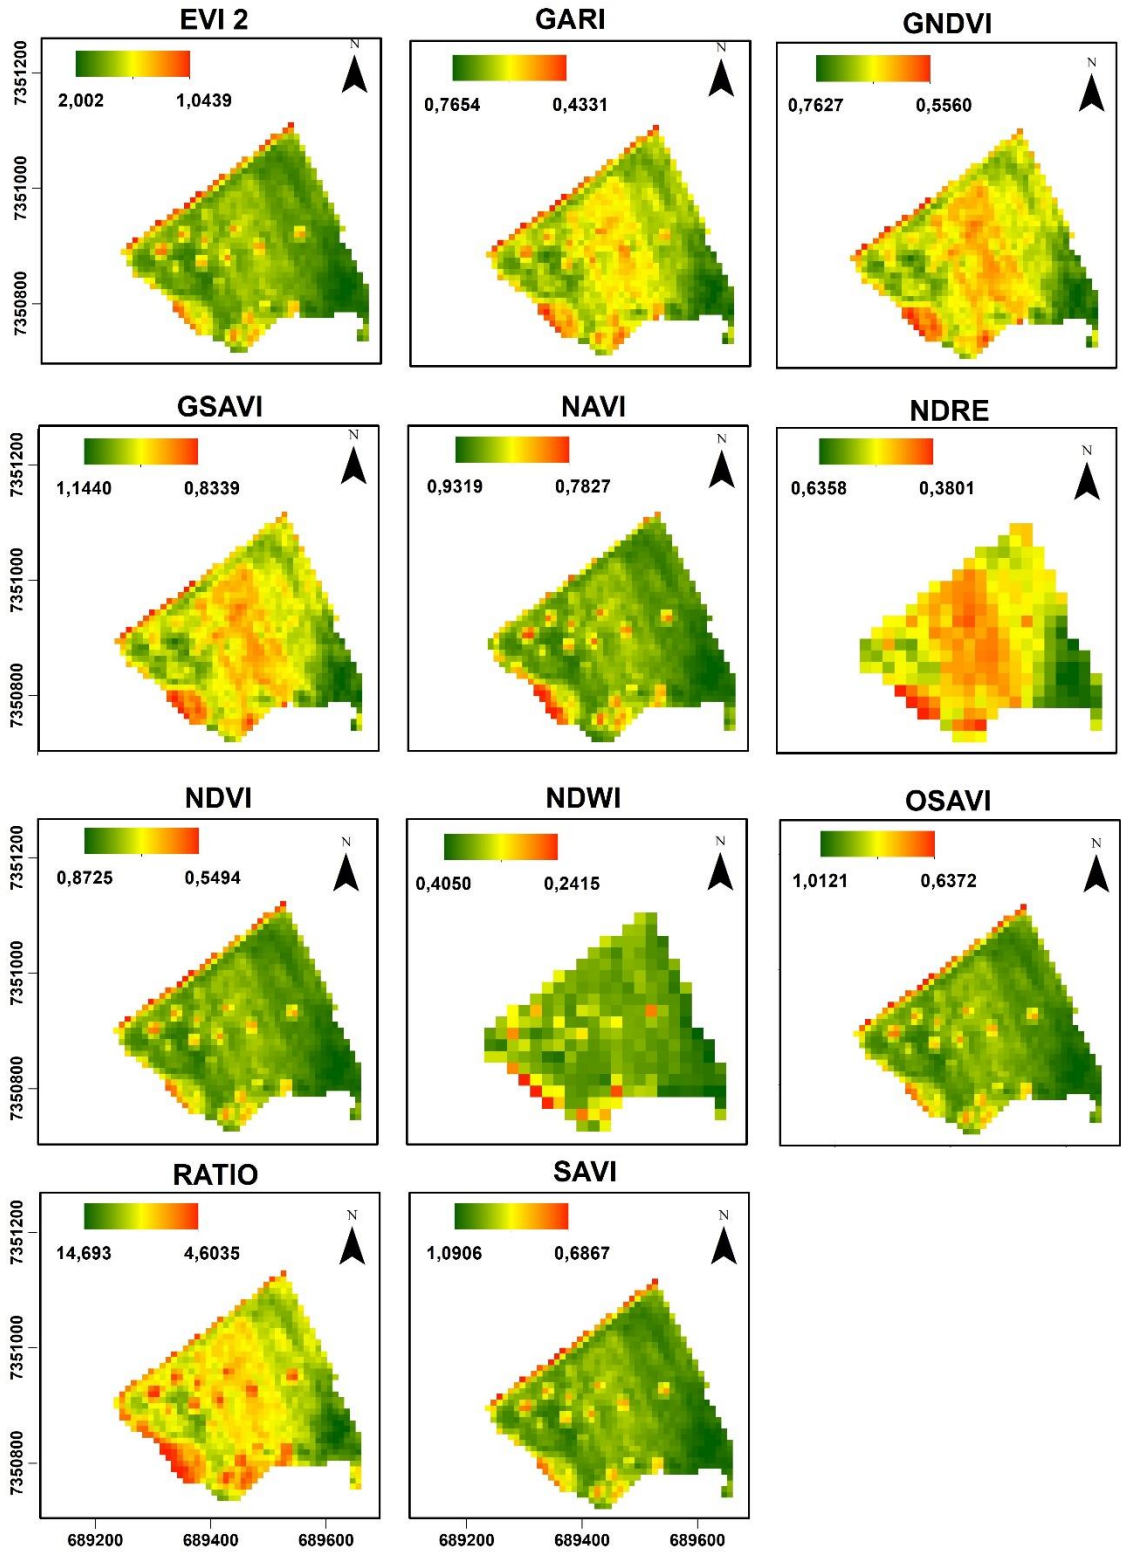


SIRGAS 2000 UTM 22S 0 180 360 720 1.080 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BA - Índices calculados para o talhão 1 do mês de fevereiro de 2020

TALHÃO 1 - FEVEREIRO 2020

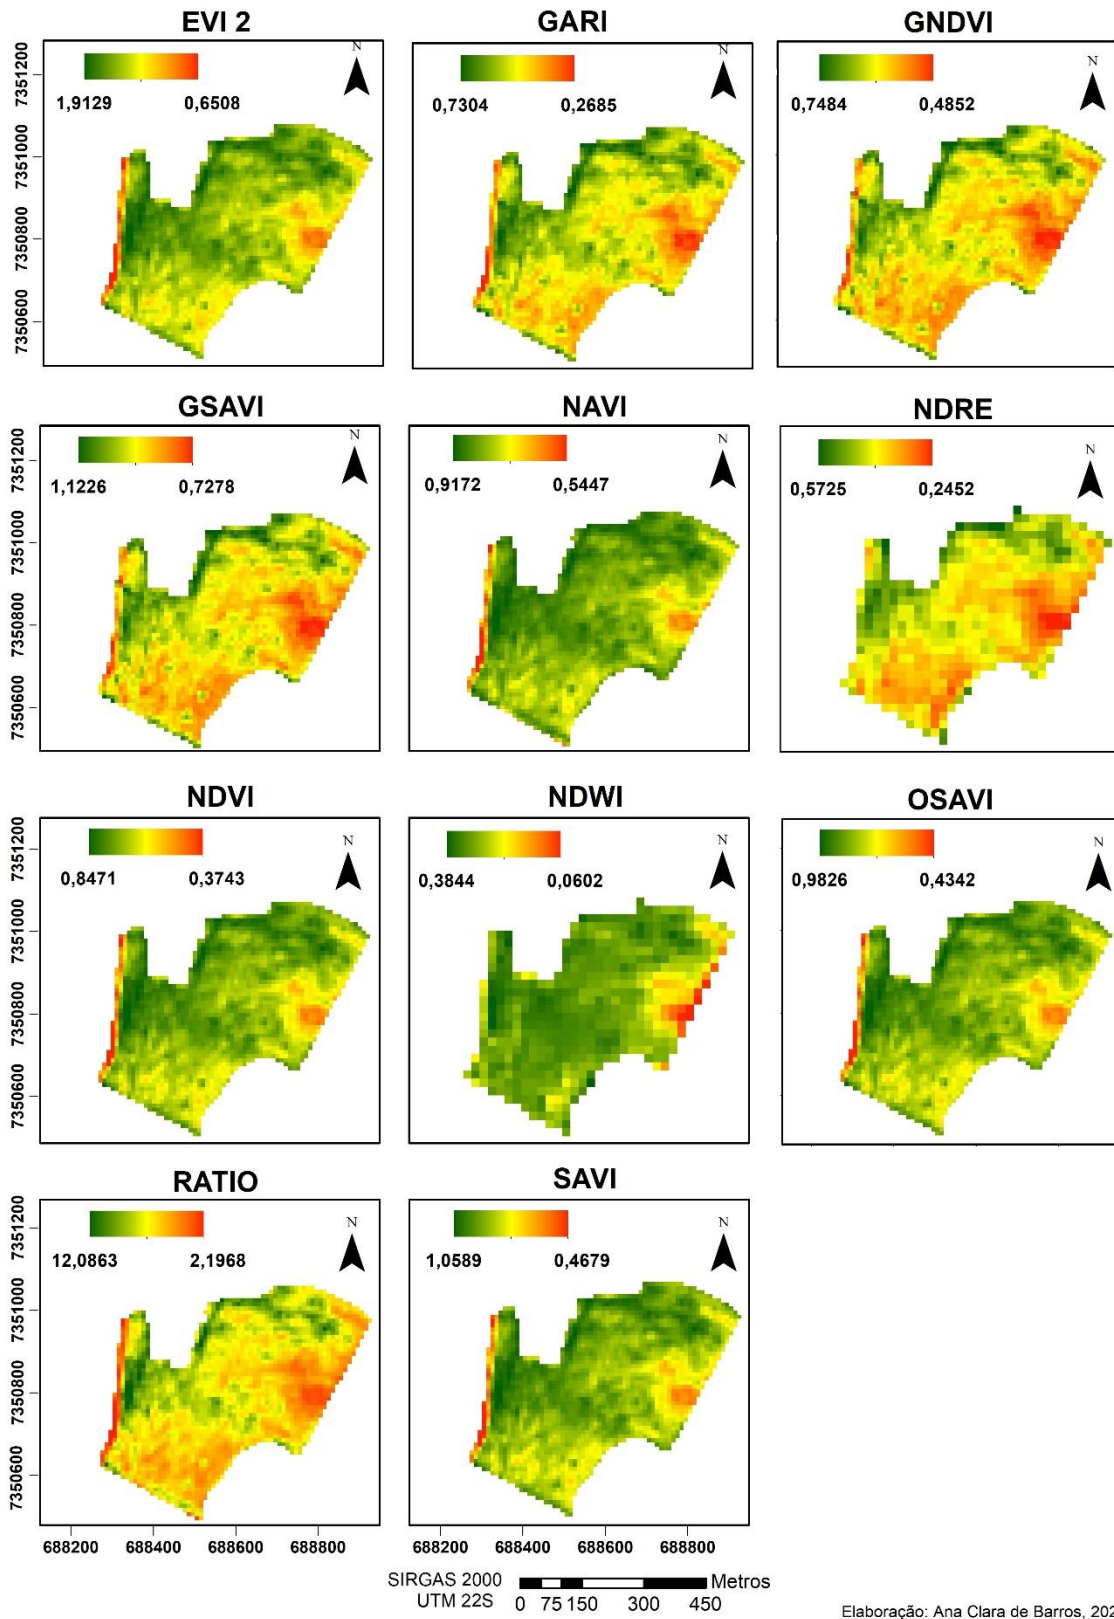


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BB - Índices calculados para o talhão 2 do mês de fevereiro de 2020

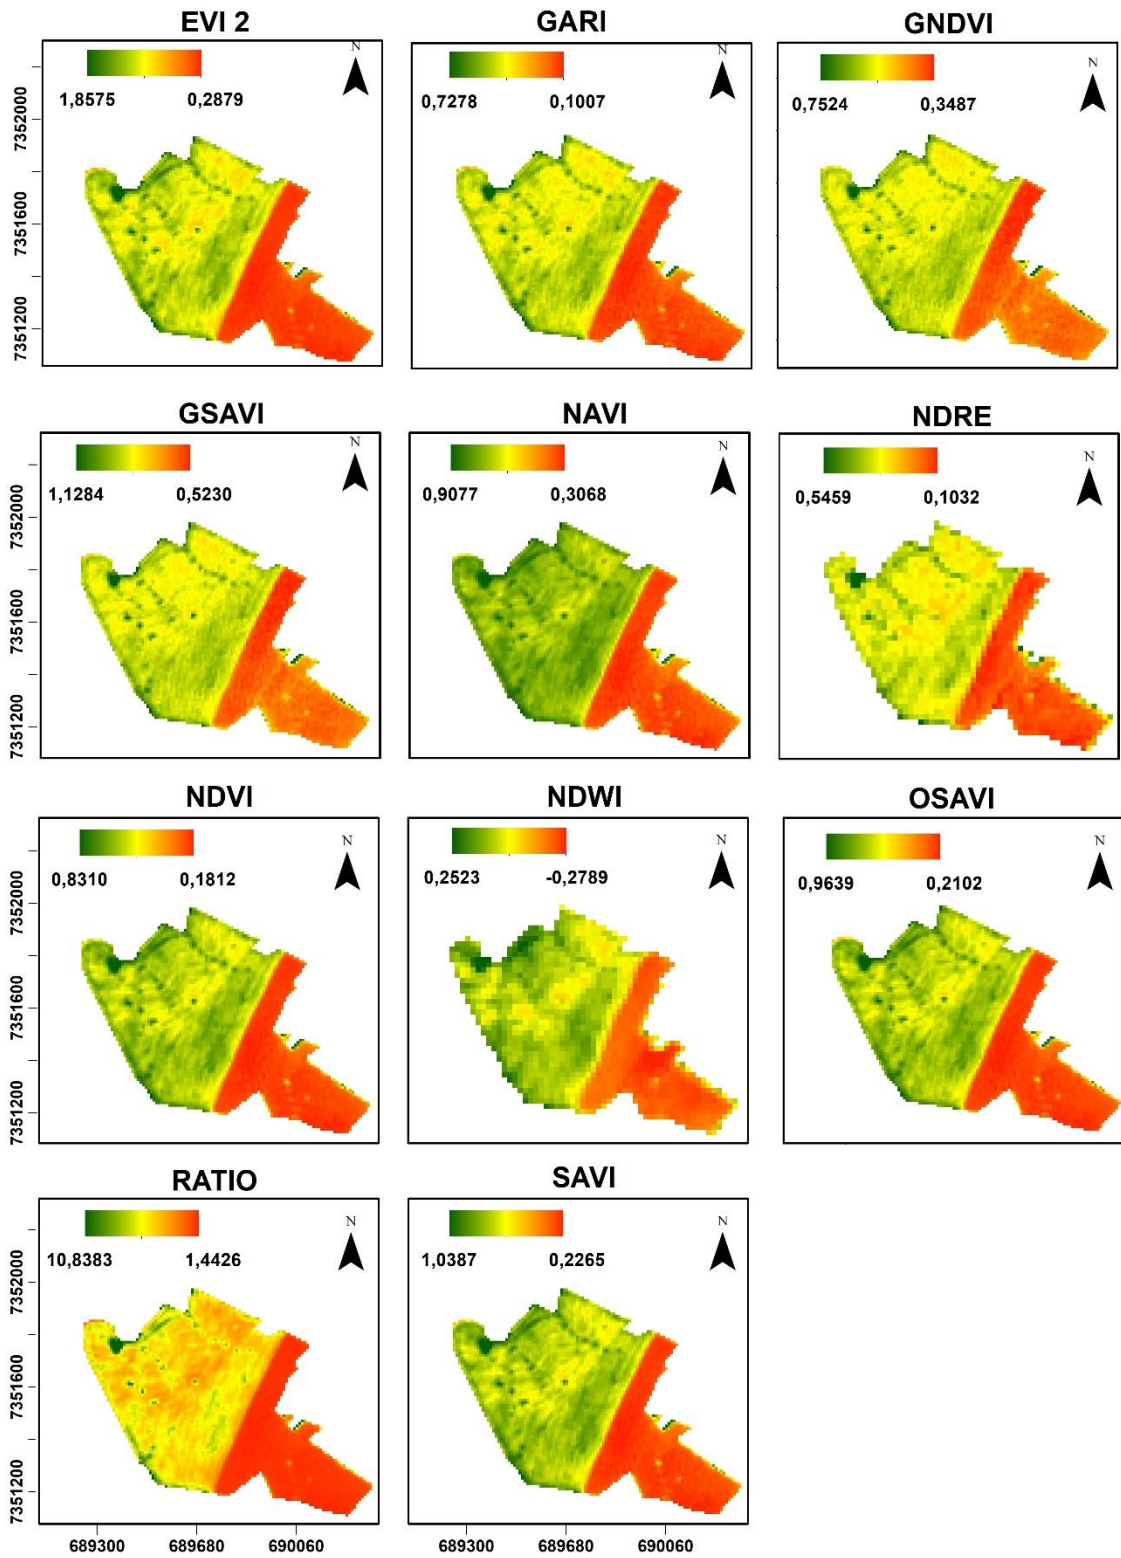
TALHÃO 2 - FEVEREIRO 2020



Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BC - Índices calculados para o talhão 3 do mês de fevereiro de 2020

TALHÃO 3 - FEVEREIRO 2020

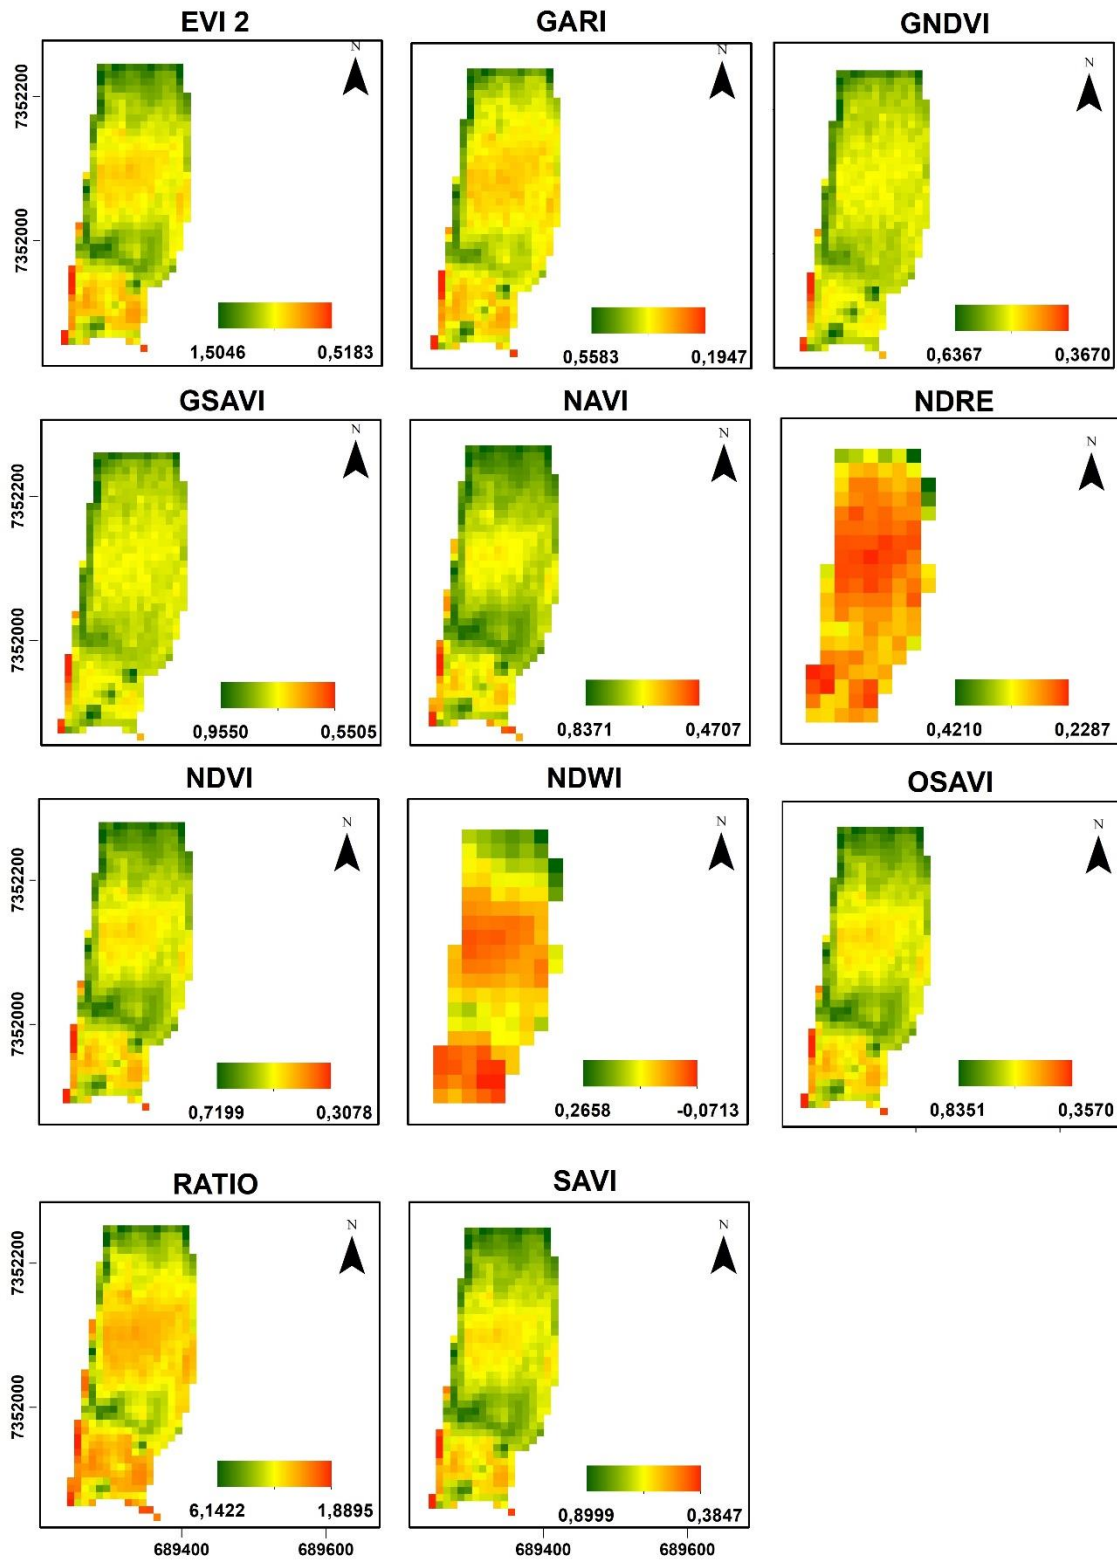


SIRGAS 2000 UTM 22S 0 150 300 600 900 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BD - Índices calculados para o talhão 4 do mês de fevereiro de 2020

TALHÃO 4 - FEVEREIRO 2020

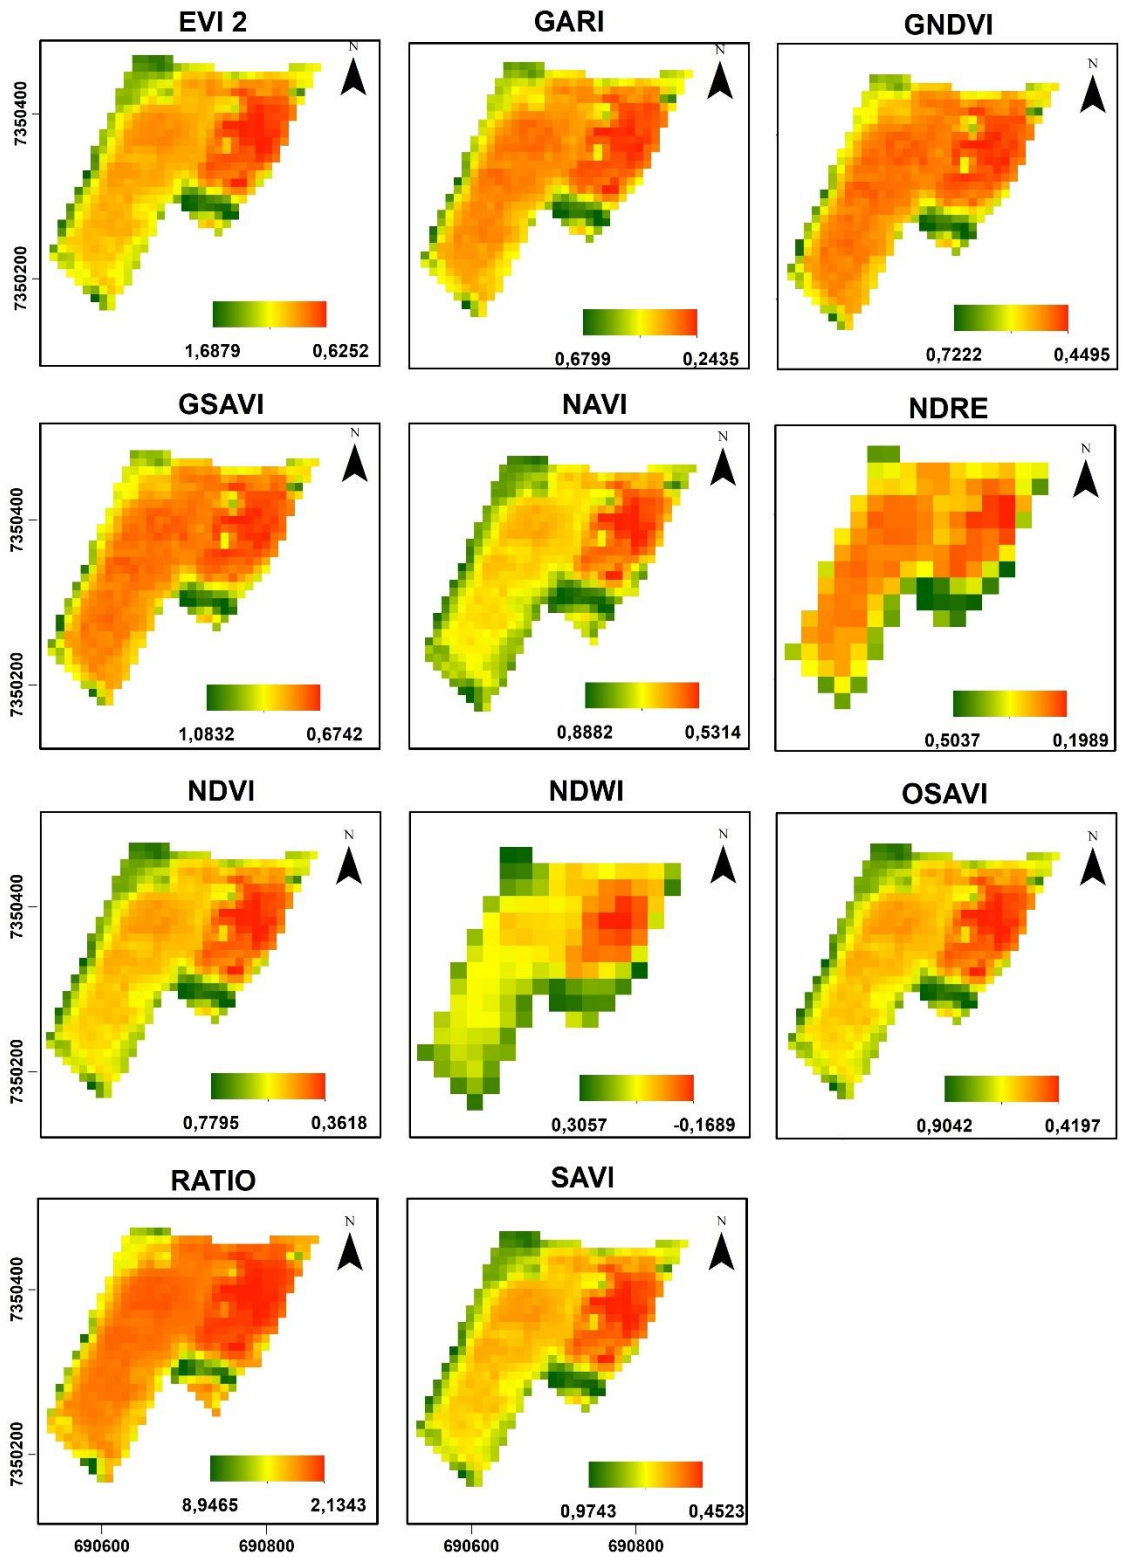


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BE - Índices calculados para o talhão 5 do mês de fevereiro de 2020

TALHÃO 5 - FEVEREIRO 2020

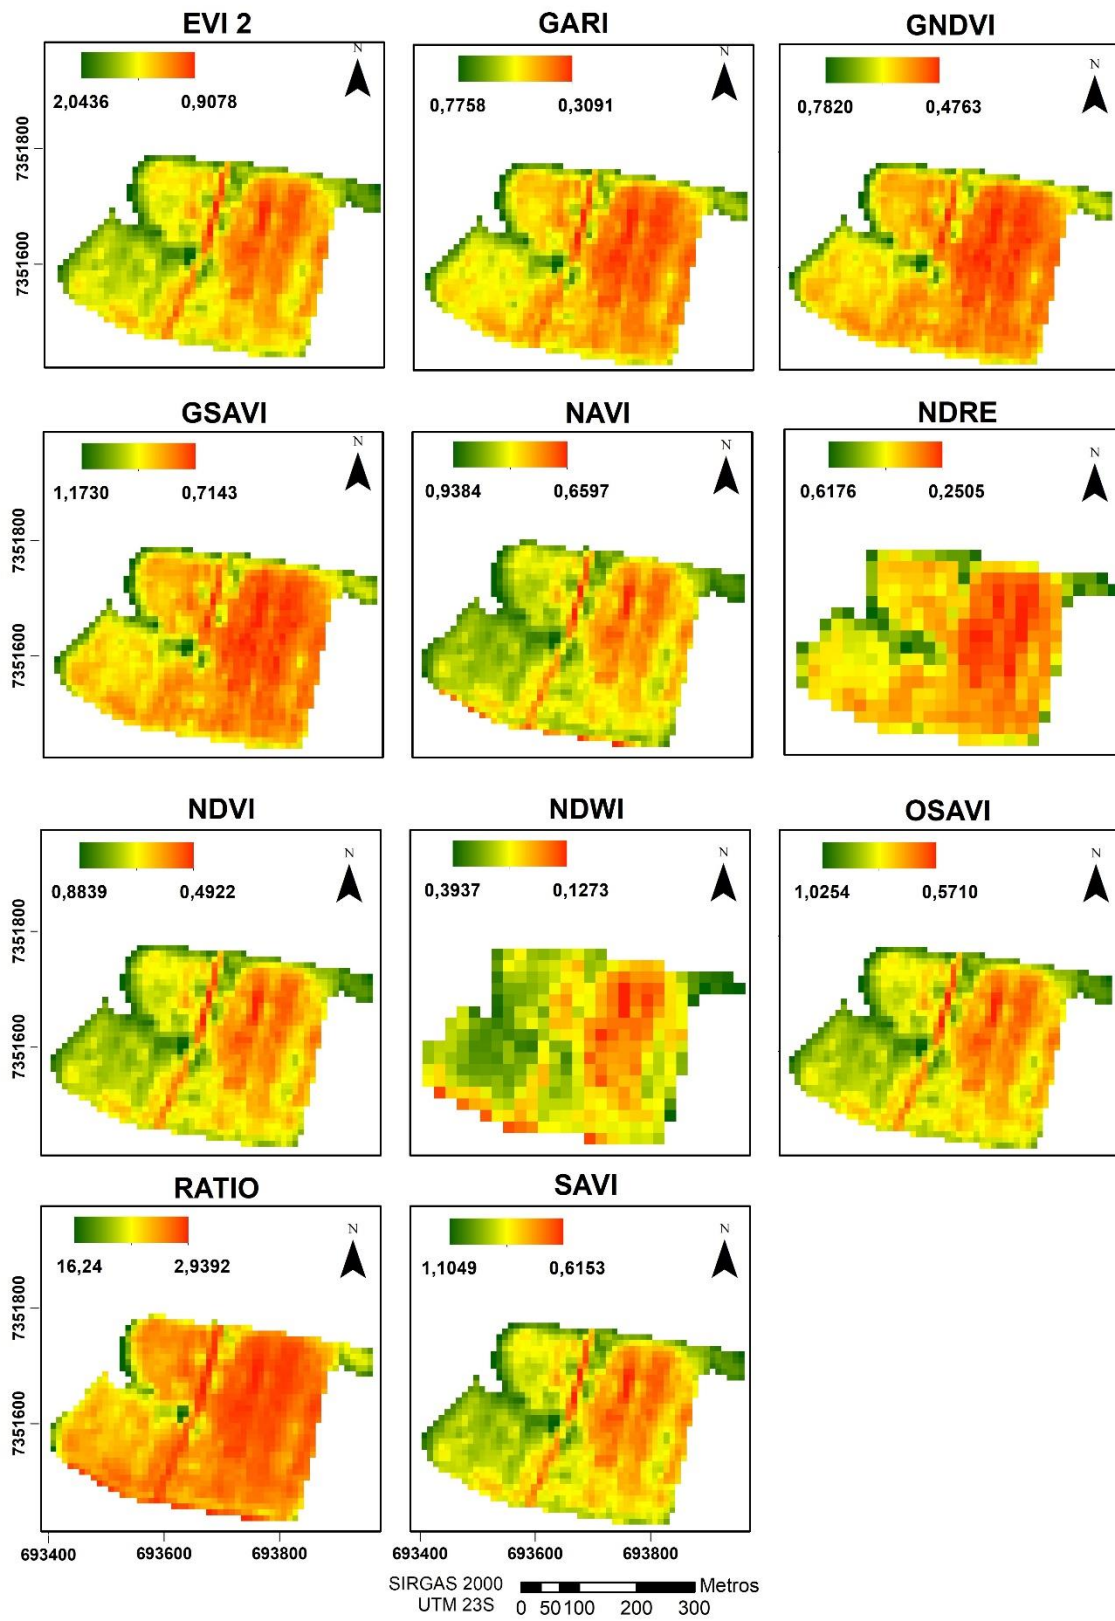


SIRGAS 2000 UTM 22S 0 50 100 200 300 Metros

Elaboração: Ana Clara de Barros, 2021.

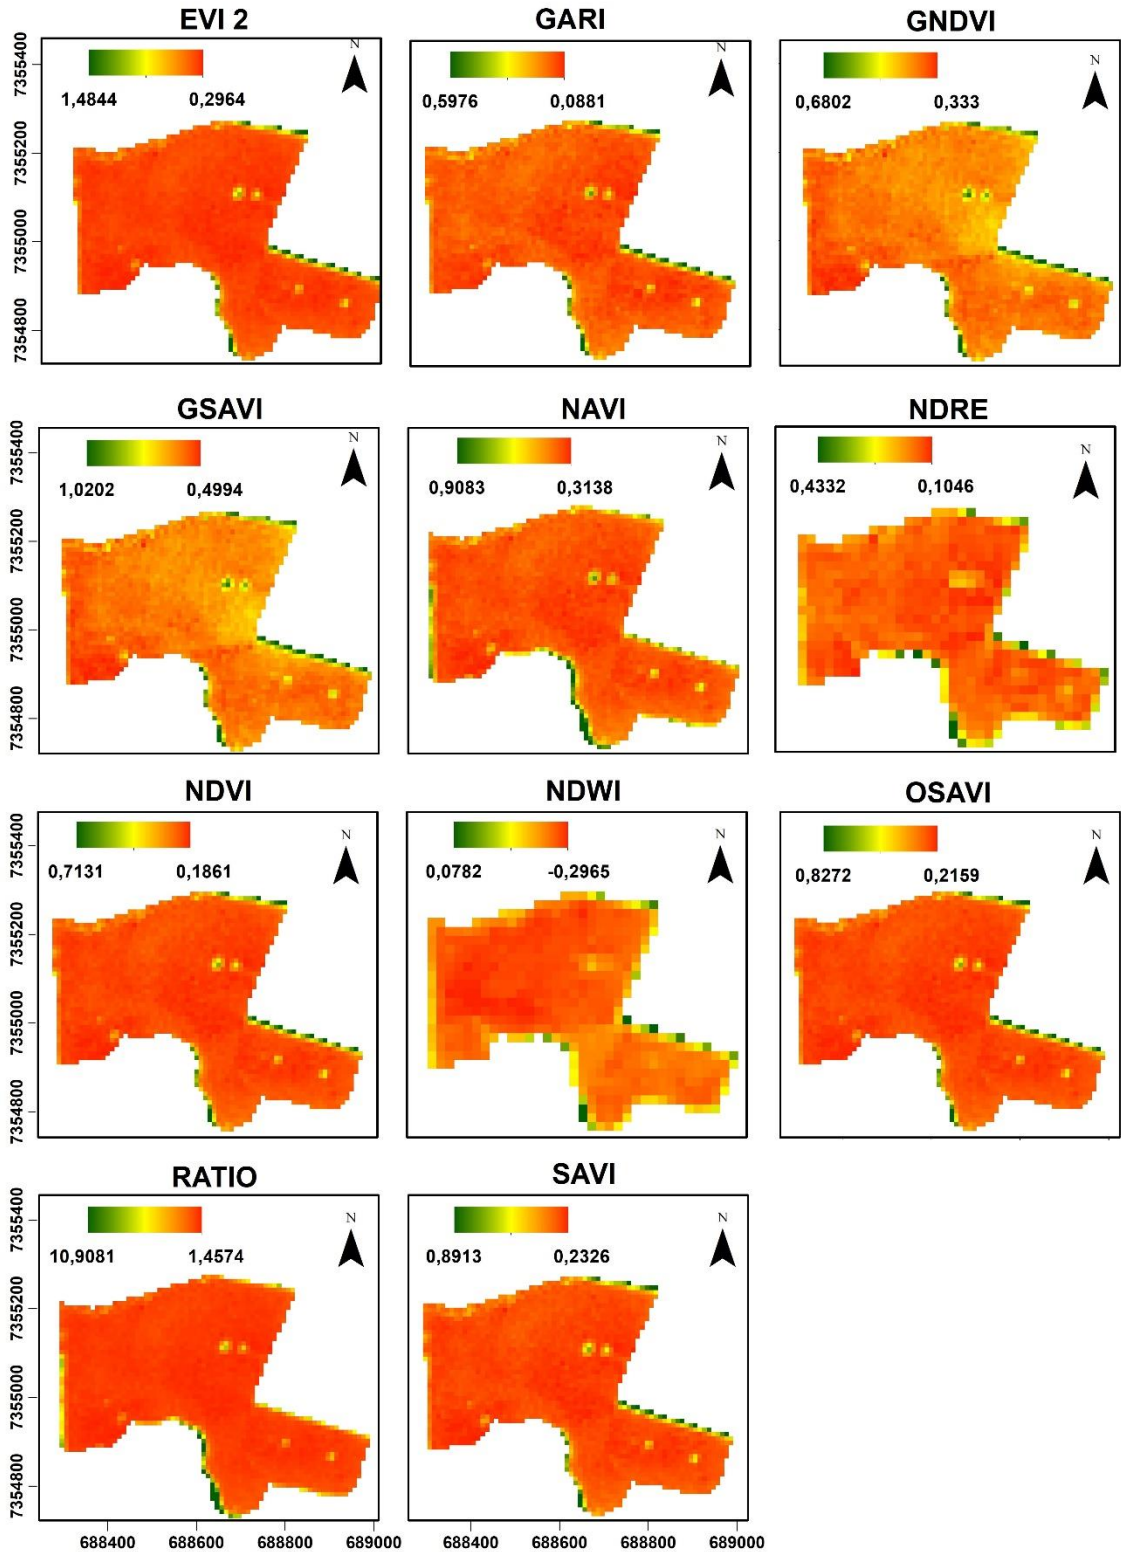
APÊNDICE BF - Índices calculados para o talhão 6 do mês de fevereiro de 2020

TALHÃO 6 - FEVEREIRO 2020



APÊNDICE BG - Índices calculados para o talhão 7 do mês de fevereiro de 2020

TALHÃO 7 - FEVEREIRO 2020

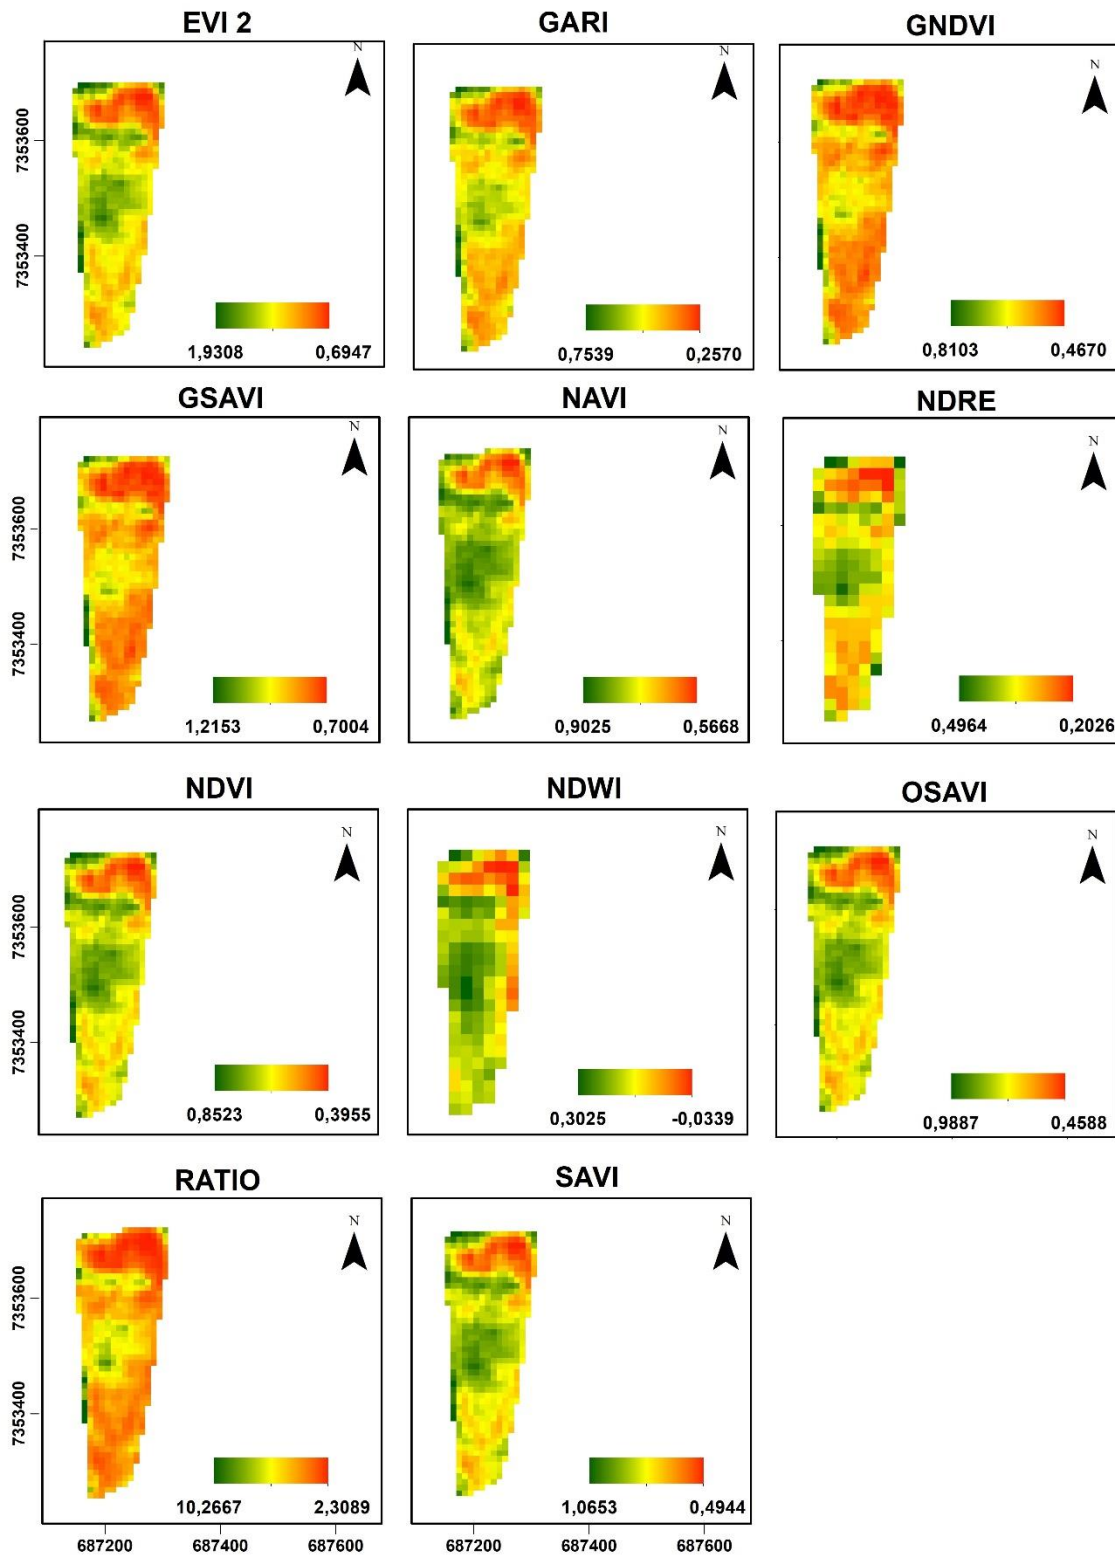


SIRGAS 2000 UTM 22S 0 100 200 400 600 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BH - Índices calculados para o talhão 8 do mês de fevereiro de 2020

TALHÃO 8 - FEVEREIRO 2020

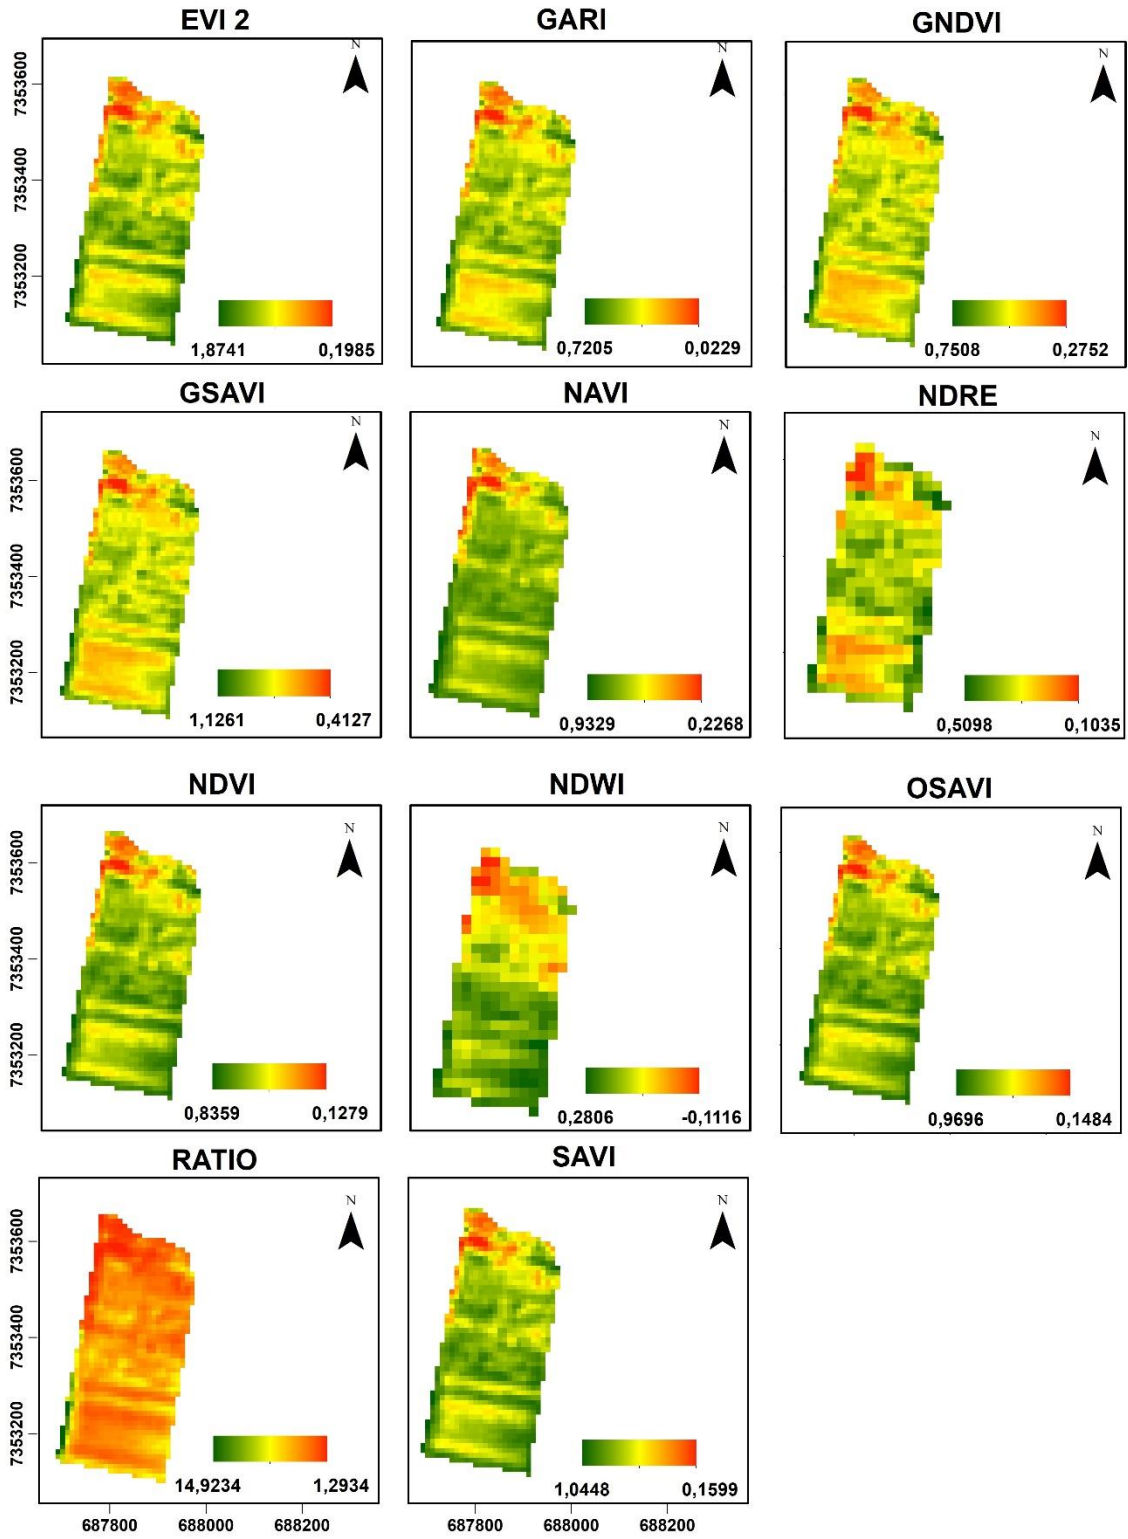


SIRGAS 2000 UTM 22S 0 65 130 260 390 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BI - Índices calculados para o talhão 9 do mês de fevereiro de 2020

TALHÃO 9 - FEVEREIRO 2020

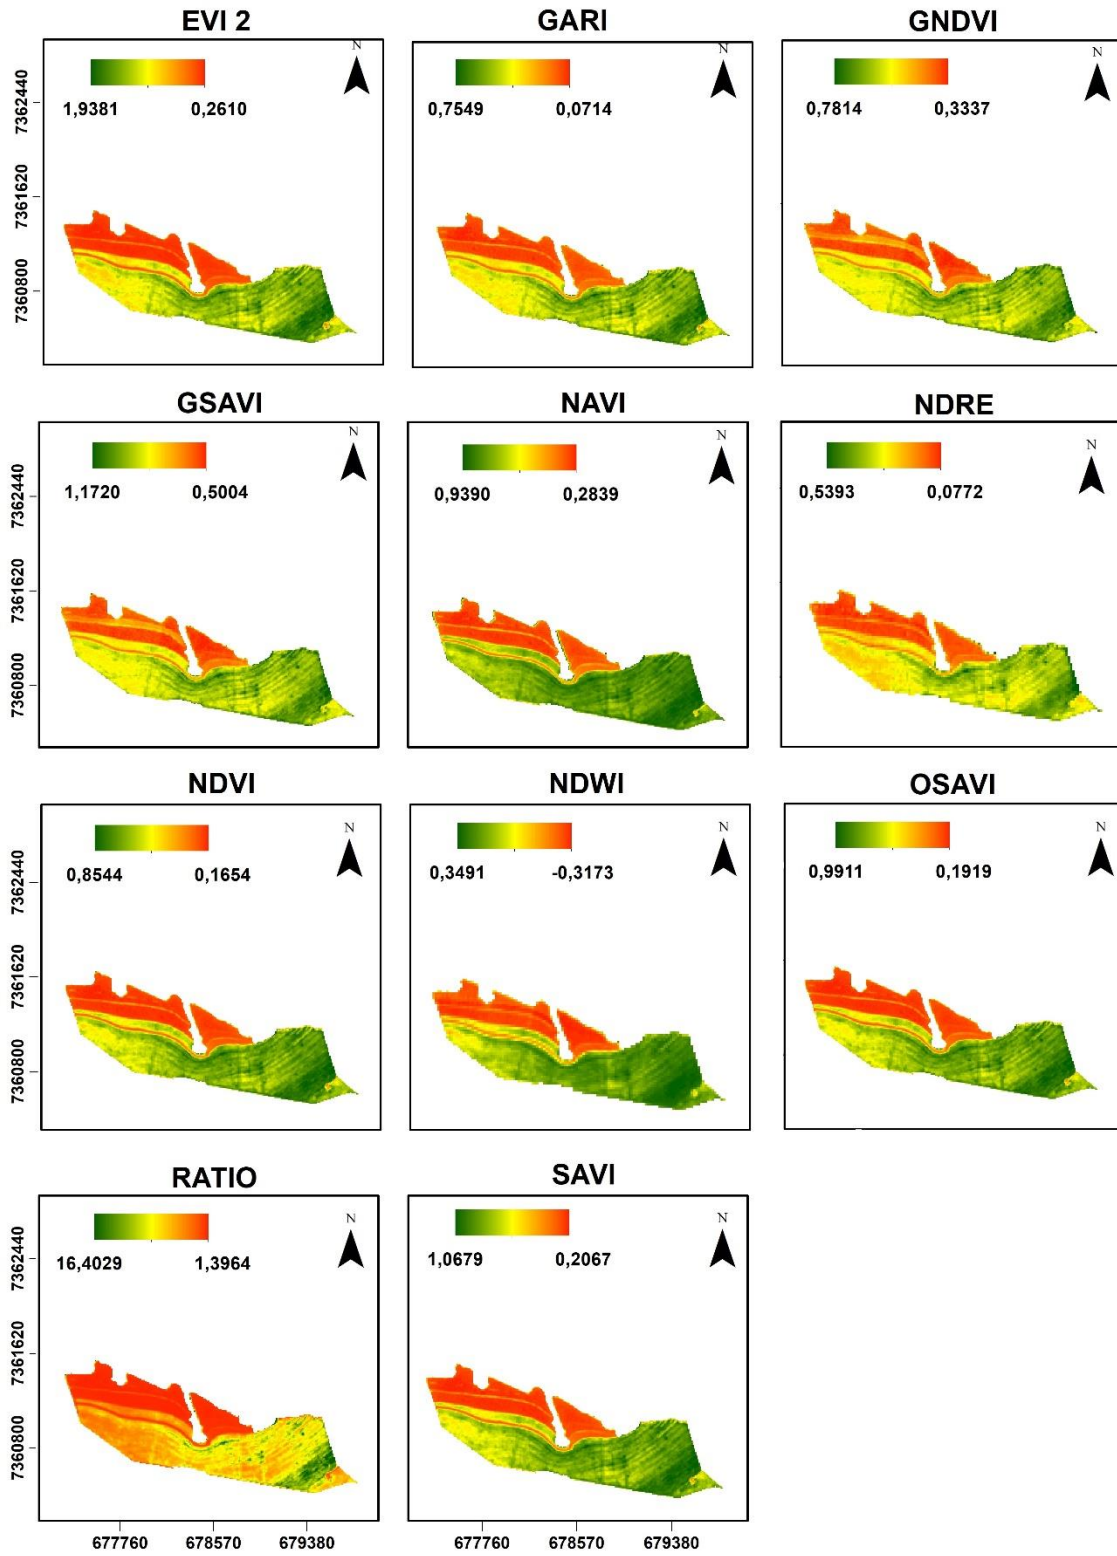


SIRGAS 2000 UTM 22S 0 75 150 300 450 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BJ - Índices calculados para o talhão 10 do mês de fevereiro de 2020

TALHÃO 10 - FEVEREIRO 2020

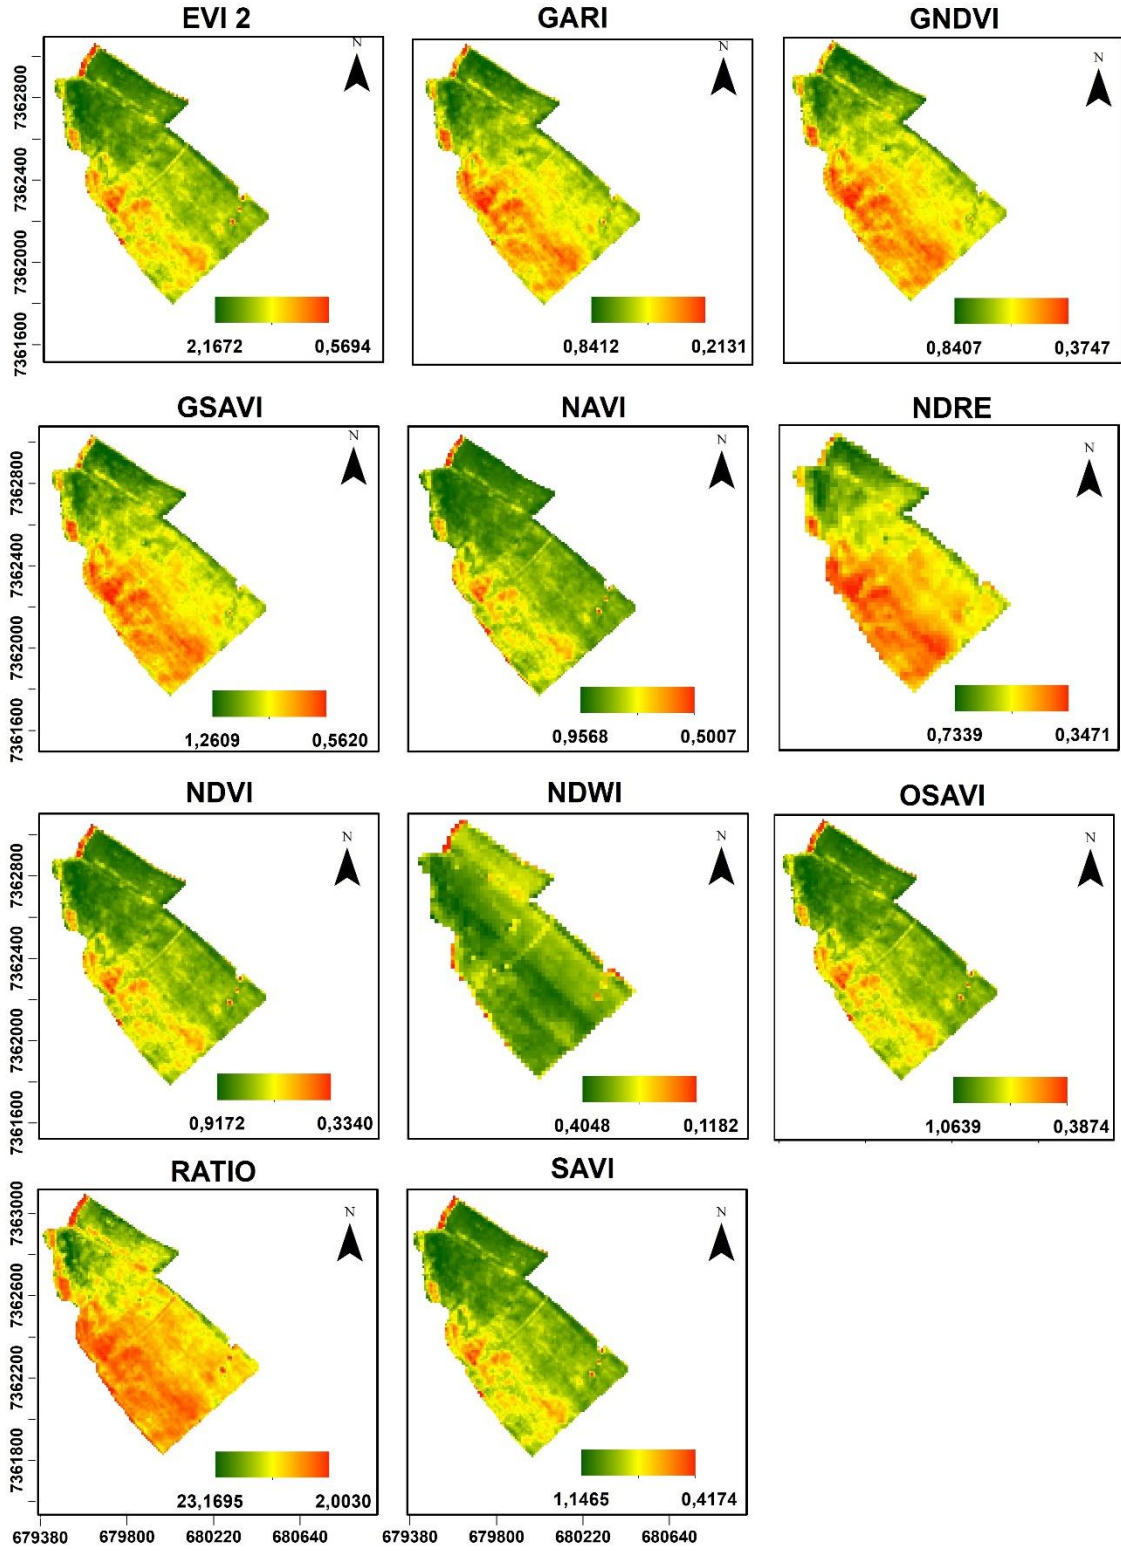


SIRGAS 2000 UTM 22S 0 300600 1.200 1.800 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BK - Índices calculados para o talhão 11 do mês de fevereiro de 2020

TALHÃO 11 - FEVEREIRO 2020

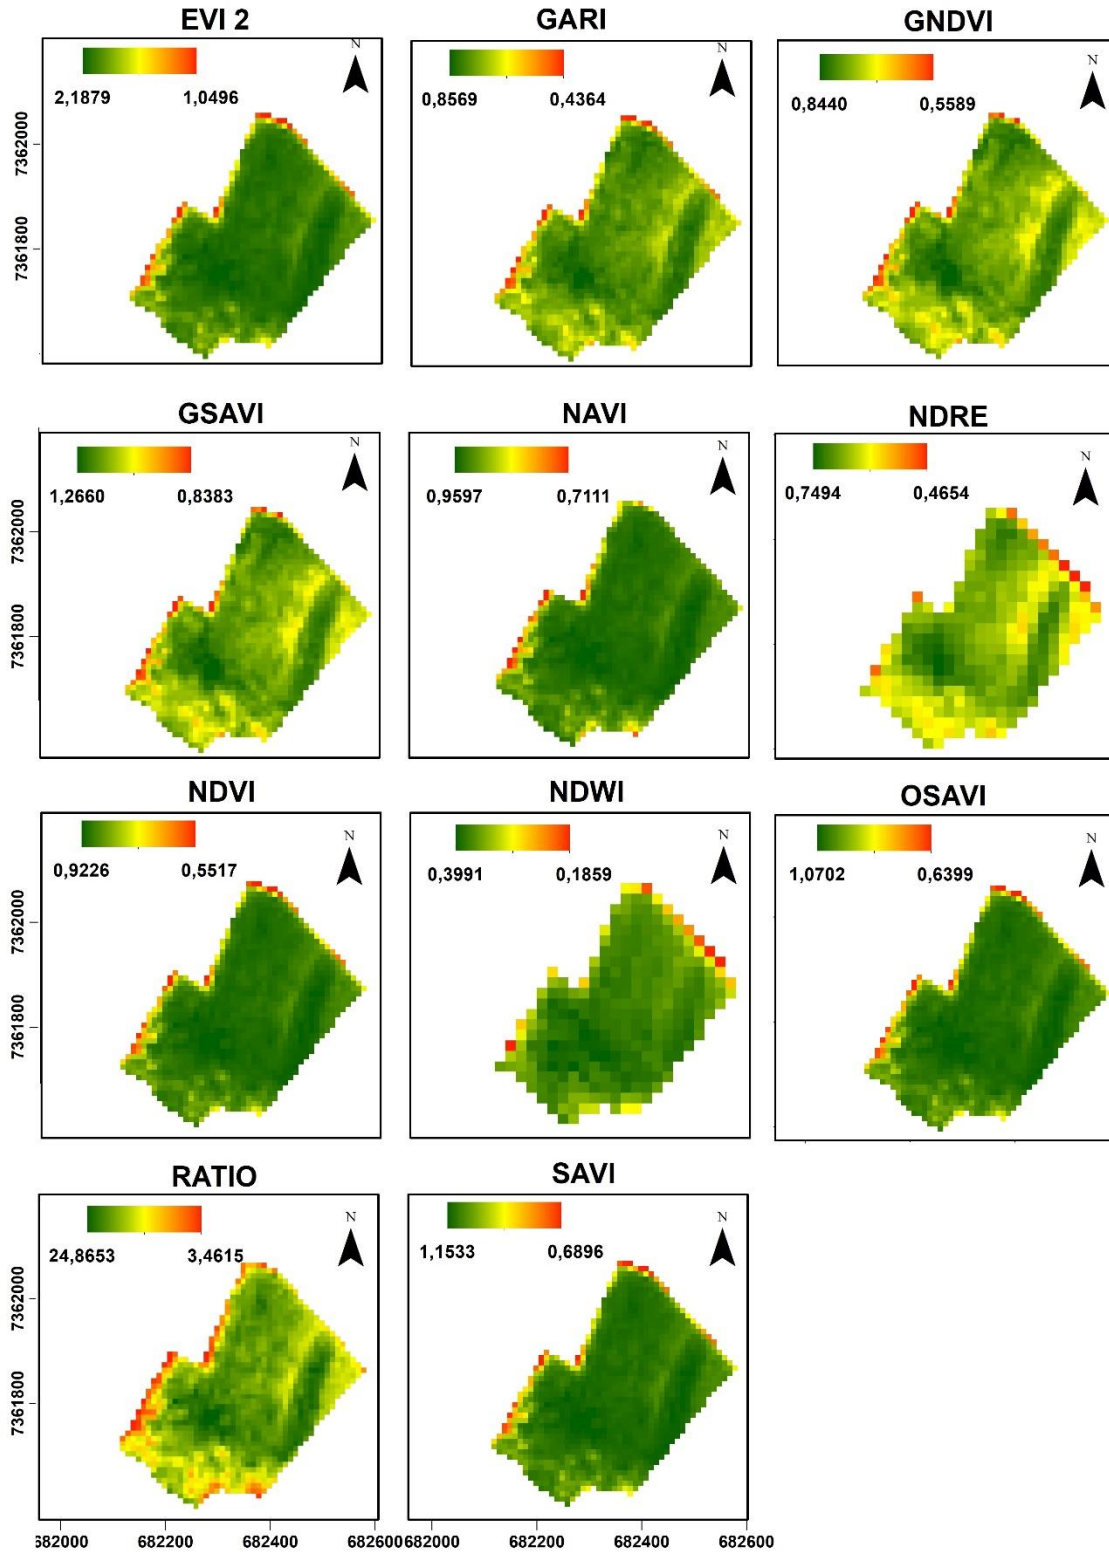


SIRGAS 2000 UTM 22S 0 205 410 820 1.230 Metros

Elaboração: Ana Clara de Barros, 2021.

APÊNDICE BL - Índices calculados para o talhão 12 do mês de fevereiro de 2020

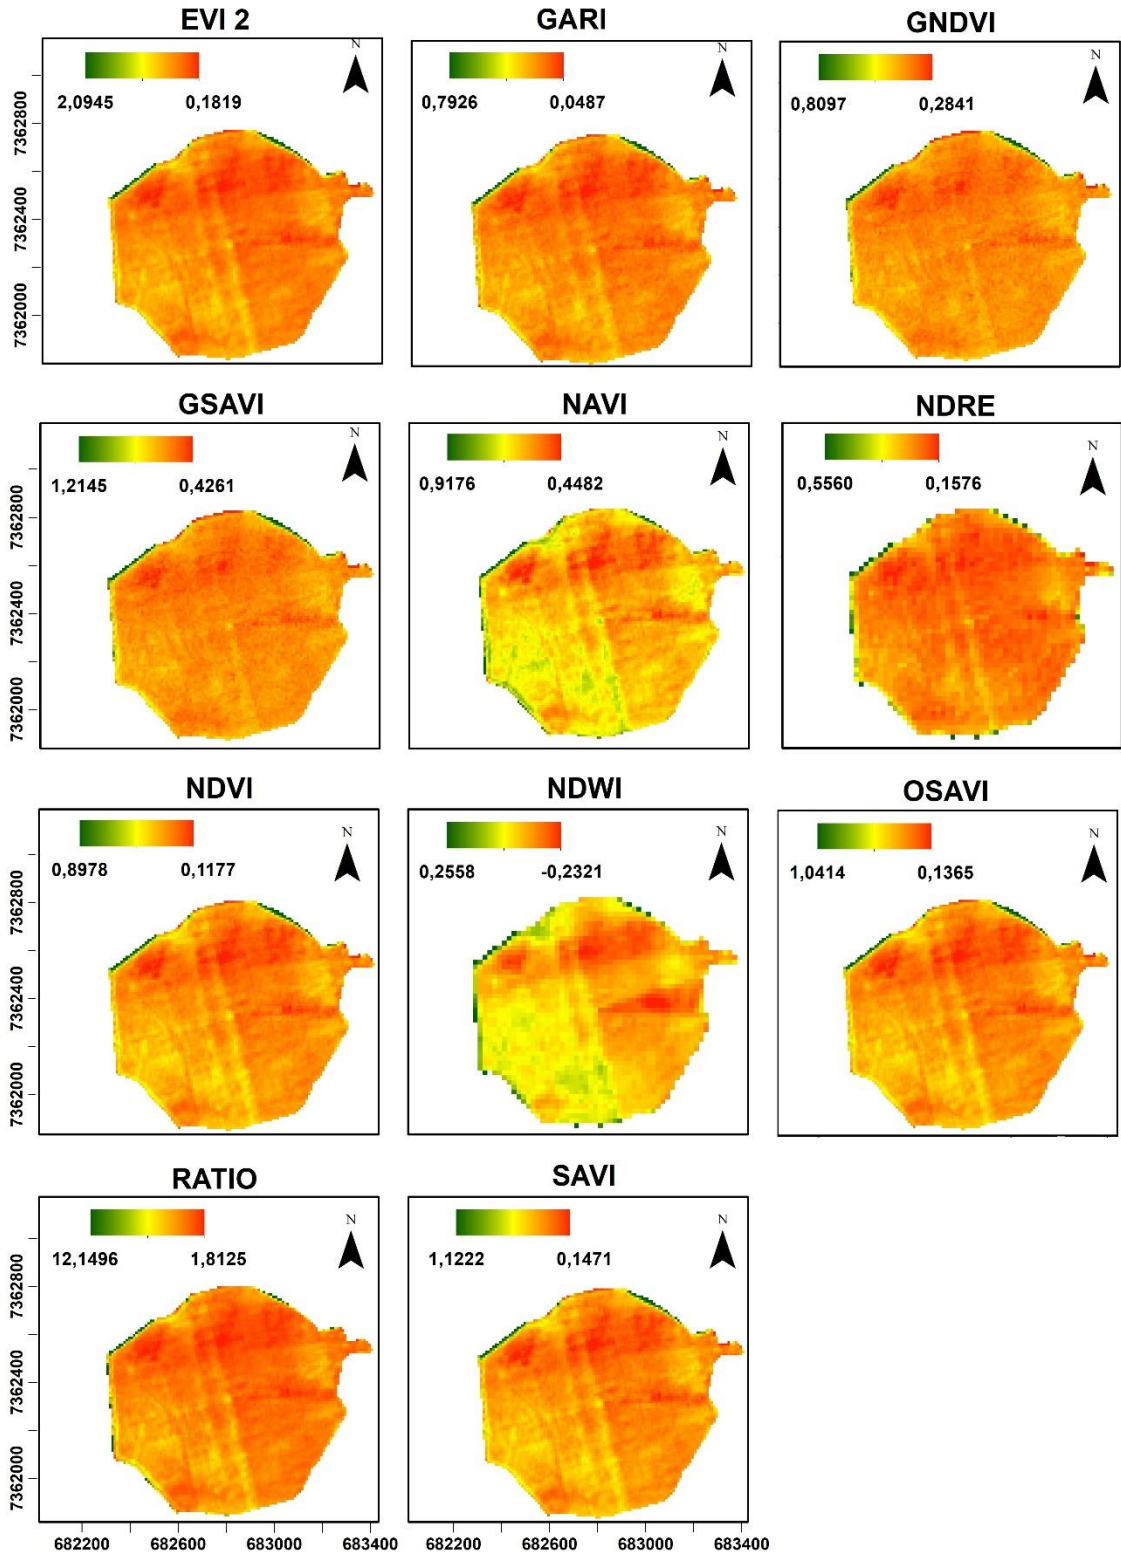
TALHÃO 12 - FEVEREIRO 2020



SIRGAS 2000 UTM 22S 0 55 110 220 330 Metros

APÊNDICE BM - Índices calculados para o talhão 13 do mês de fevereiro de 2020

TALHÃO 13 - FEVEREIRO 2020



SIRGAS 2000 UTM 22S 0 180 360 720 1.080 Metros

Elaboração: Ana Clara de Barros, 2021.