



UNIVERSIDADE FEDERAL DO TOCANTINS
CAMPUS UNIVERSITÁRIO DE PALMAS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGROENERGIA

CESAR AUGUSTO COSTA NASCIMENTO

**AVALIAÇÃO DE ÍNDICES DE VEGETAÇÃO COMO
ALTERNATIVA PARA ESTIMATIVA DE RENDIMENTO DE
ÓLEO DE SOJA PARA PRODUÇÃO DE BIOCOMBUSTÍVEL EM
VÁRZEA NO ESTADO DO TOCANTINS**

PALMAS– TO

2018

CESAR AUGUSTO COSTA NASCIMENTO

**AVALIAÇÃO DE ÍNDICES DE VEGETAÇÃO COMO
ALTERNATIVA PARA ESTIMATIVA DE RENDIMENTO DE
ÓLEO DE SOJA PARA PRODUÇÃO DE BIOCOMBUSTÍVEL EM
VÁRZEA NO ESTADO DO TOCANTINS**

Dissertação apresentada ao Programa de Pós-Graduação em Agroenergia como requisito parcial à obtenção do grau de Mestre em Agroenergia.

Orientador: Dr. Joênes Mucci Peluzio

Co-Orientador: Dr. Erich Collicchio

PALMAS– TO

2018

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Tocantins

N244a NASCIMENTO, CESAR AUGUSTO COSTA.

Avaliação de índices de vegetação como alternativa para estimativa de rendimento de óleo de soja para produção de biocombustível em várzea no estado do Tocantins. / CESAR AUGUSTO COSTA NASCIMENTO. – Palmas, TO, 2018.

119 f.

Dissertação (Mestrado Acadêmico) - Universidade Federal do Tocantins – Câmpus Universitário de Palmas - Curso de Pós-Graduação (Mestrado) em Agroenergia, 2018.

Orientador: Joênes Mucci Peluzio

Coorientador: Erich Collicchio

1. Sensoriamento remoto. 2. Geoestatística. 3. Temperatura. 4. Landsat 08.
I. Título

CDD 333.7

TODOS OS DIREITOS RESERVADOS – A reprodução total ou parcial, de qualquer forma ou por qualquer meio deste documento é autorizado desde que citada a fonte. A violação dos direitos do autor (Lei nº 9.610/98) é crime estabelecido pelo artigo 184 do Código Penal.

Elaborado pelo sistema de geração automática de ficha catalográfica da UFT com os dados fornecidos pelo(a) autor(a).



UNIVERSIDADE FEDERAL DO TOCANTINS
CAMPUS UNIVERSITÁRIO DE PALMAS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGROENERGIA

FOLHA DE APROVAÇÃO

**AVALIAÇÃO DE ÍNDICES DE VEGETAÇÃO COMO
ALTERNATIVA PARA ESTIMATIVA DE RENDIMENTO DE
ÓLEO DE SOJA PARA PRODUÇÃO DE BIOCOMBUSTÍVEL EM
VÂRZEA NO ESTADO DO TOCANTINS**

ALUNO: Cesar Augusto Costa Nascimento

COMISSÃO EXAMINADORA

Presidente:

Prof. Dr. Joênes Mucci Peluzio (UFT)

Examinadores:

Prof. Dr. Erich Collicchio (UFT)

Prof. Dr. Balbino Antonio Evangelista (EMBRAPA)

Data da Defesa: 30/05/2018

As sugestões da Comissão Examinadora e as Normas PGA para o formato da
Dissertação foram contempladas:

Prof. Dr. Joênes Mucci Peluzio (UFT)

As mulheres da minha vida, mãe, filha e
esposa, amor que não se mede, sou
agraciado de poder contar com todas
você.

AGRADECIMENTOS

A Deus, pela saúde e determinação que tem me oferecido ao longo dessa jornada;

A minha esposa Viviane Alves de Araújo pelo amor, paciência e palavras de estímulo que me confortaram nas dificuldades durante esta fase da minha vida;

Aos meus filhos, Jadhya Saraiva Nascimento e Júlio César Araújo Nascimento, pois ao fazerem parte da minha vida estímulo ainda maior em alcançar meus objetivos;

Aos meus pais, Coraci Barros do Nascimento e Maria do Socorro Costa Nascimento, mesmo na saudade e enfermidades, nunca me abandonaram ou desistiram de seu filho;

Aos meus irmãos, Iran Costa Nascimento e Igor Costa Nascimento e suas famílias, que junto aos nossos pais fizeram parte do incentivo e palavras de conforto junto às dificuldades;

Aos meus sogros e amigos, Florípedes José de Araújo e Cleusa Maria Alves de Araújo e seu filho Bruno Alves de Araújo e família pelo apoio e auxílios oferecidos;

Ao orientador, professor e amigo, Joênes Mucci Peluzio por ter acreditado nos meus ideais e me orientado de forma paciente e com sabedoria durante toda a elaboração deste trabalho;

Às contribuições do Dr Balbino Antonio Evangelista, pesquisador da EMBRAPA, que me direcionou na condução do projeto;

A coordenadora do Mestrado em Agroenergia, Dra. Flavia Lucila Tonani, por ter sempre me apoiado com grande entusiasmo e pelo apoio dado na participação em eventos representando a UFT;

A secretária do Mestrado em Agroenergia, Geane José da Silveira e sua substituta Raioneide Maria N. da Silva, sempre flexíveis e dispostas;

A todo corpo docente do programa de mestrado, em especial ao co-orientador Dr. Erich Collicchio, Dra. Yolanda Abreu e Alisson Moura Santos; excelentes profissionais, docentes e conselheiros.

Aos amigos e colegas mestrados e já mestrados do programa. Sucesso a todos, e sempre que precisarem podem contar comigo;

Aos amigos e aluno, Cristiano Patha Flain, Sandro Rodrigues Nogueira e Gabriel Borges, sem vocês seria muito difícil coletar as informações, obrigado de coração;

Ao Gerente de Produção, José Luís Venâncio Corrêa e funcionários da empresa Talismã Sementes. Apoio considerado primordial para execução do trabalho, sem a contribuição desses profissionais, não seria possível alcançar os objetivos do projeto, muito obrigado;

A todos os colegas e amigos de profissão e funcionários da Faculdade Católica do Tocantins, que de alguma forma contribuíram com dicas e sugestões, em especial, Professor Evandro Reina que me auxiliou nas análises laboratoriais;

A todos os funcionários e da Universidade Federal do Tocantins pela amizade construída e pelo auxílio oferecido durante o curso.

RESUMO

Estudos com culturas agroenergéticas tem sido desenvolvido e implementados com a análise de imagens, tanto de aeronaves não tripuladas, como é o caso dos drones e vant's e da utilização de imagens orbitais, como exemplo das imagens do satélite Landsat 08 disponibilizadas pelo Sistema Geológico dos Estados Unidos (USGS). Nesse contexto, o presente estudo tem o objetivo de estimar, área plantada, teor de óleo e rendimento de óleo de soja na região de várzea do Tocantins, no município de Formoso do Araguaia – TO, a partir de amostragem em campo e imagens obtidas do satélite LANDSAT 08 por meio de índices de vegetação: SAVI, NDVI e IAF para os anos de 2016 e 2017 visando a produção de biocombustível na região. Os valores de área plantada apresentaram diferença entre os índices com os resultados significativos $p < 0,005$ para o NDVI com R^2 0,7523 e R igual a 0,8673 e boa diferenciação entre os talhões e as áreas de acesso para índice IAF. Já quanto à produtividade foi estimada por meio do índice NDVI e as produtividades obtidas em campo correlacionadas com resultados significativos $p < 0,005$ com valores de R^2 0,70 e R igual a 0,84. Os teores de óleo foram estimados a partir da amostragem em campo com valor de R^2 0,89 e ao final apresentou resultados entre 15 e 26%. As temperaturas foram obtidas por meio das imagens Landsat 08 e estimada para os talhões com plantio em 2017 com valor de R^2 igual a 0,93. O rendimento de óleo foi realizado em função da produtividade estimada e os valores de teor de óleo para os talhões de 2017 variando entre 380 e 710 litros. Pode se afirmar que a metodologia adotada obteve êxito na estimativa de rendimento de óleo e teor de óleo, podendo contribuir para estudos futuros acrescentando uma maior variabilidade de amostras.

Palavras Chaves: Sensoriamento Remoto, Geoestatística, Temperatura, Landsat 08

ABSTRACT

Studies on agroenergy cultures have been developed and implemented with the analysis of images of both unmanned aircraft, such as drones and vans and the use of orbital images, as an example of Landsat 08 satellite images made available by the Geological Survey of the States United States (USGS). In this context, the present study has the objective of estimating the oil content and yield of soybean oil in the Tocantins várzea region, in the municipality of Formoso do Araguaia - TO, using field sampling and images obtained from LANDSAT 08 satellite through vegetation indexes: SAVI, NDVI and IAF for the years 2016 and 2017 aiming at the production of biofuel in the region. The values of planted area presented a difference between the indices with significant results $p < 0.005$ for the NDVI with R^2 0,7523 and R equal to 0.8673 and good differentiation between the plots and the access areas for the IAF index. The productivity was estimated using the NDVI index and the yields obtained in the field correlated with significant results, $p < 0.005$, with a values of R^2 0.70 and R values equal to 0.84. The oil contents were estimated from field sampling with a value of R^2 0.89 and at the end presented results between 15 and 26%. The temperatures were obtained by means of the Landsat 08 images and estimated for the plots with planting in 2017 with R^2 value equal to 0,93. The yield of the oil was carried out in function of the estimated productivity and the values oil content for the fields of 2017 varying between 380 and 710 liters. It can be affirmed that the adopted methodology was successful in the estimation of oil yield and oil content, being able to contribute to future studies adding a greater variability of samples.

Keywords: Remote sensing, Geostatistics, Temperature, Landsat 08

LISTA DE FIGURAS

Figura 01 – Mapa com os grupos de maturidade relativa.	24
Figura 02 – Consumo Biodiesel	30
Figura 03 – Produção de Biodiesel 2014	30
Figura 04 – Mapa de Localização Formoso do Araguaia/Projeto Formoso do Araguaia	57
Figura 05 –Área de plantio das variedades de ciclo curto (CC) e ciclo médio (CM) – 2016	59
Figura 06 – Características das Bandas Espectrais do Landsat 08.....	61
Figura 07 – Fluxo do processo de obtenção da área estimada plantada para o ano de 2016.....	63
Figura 08 – Classificação fuzzy – NDVI e identificação das áreas de plantio de soja	65
Figura 09 – Talhão E1-03 e malha de pontos para coleta de teor de óleo e temperatura.....	67
Figura 10 – Área estimada colhida para o talhão A7-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	70
Figura 11 – Área estimada colhida para o talhão A9-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	70
Figura 12 – Área estimada colhida para o talhão B7-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	71
Figura 13 – Área estimada colhida para o talhão A12-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	72
Figura 14 – Área estimada colhida para o talhão E03-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	72
Figura 15 – Área estimada colhida para o talhão I11-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	73
Figura 16 – Área estimada colhida para o talhão A10-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	74
Figura 17 – Área estimada colhida para o talhão E04-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	74
Figura 18 – Área estimada colhida para o talhão E06-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	75

Figura 19 – Área estimada colhida para o talhão I09-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	76
Figura 20 – Área estimada colhida para o talhão B02-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	79
Figura 21 – Área estimada colhida para o talhão C2-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	79
Figura 22 – Área estimada colhida para o talhão G10-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	80
Figura 23 – Área estimada colhida para o talhão G12-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)	81
Figura 24 – Produtividade estimada para variedade M8644IPRO (CC), para os talhões com plantio do ano 2017.....	89
Figura 25 – Histograma com a representação da análise das 28 amostras de teor de óleo amostradas no talhão E1-03	93
Figura 26 – Histograma com a representação da análise das 35 amostras de temperatura do dossel amostradas no talhão E1-03	96
Figura 27 – Valores de teor de óleo (a) e a espacialização dos teores de óleo para o talhão E1-03 (b) e valores de temperatura do solo (c) e a espacialização das temperaturas para o talhão E01-03 (d), ano 2017	98
Figura 28 – Estimativa do teor de óleo para os talhões plantados em 2017 a partir das imagens Landsat 08 e o teor de óleo obtido para o talhão E1-03 para o ano de 2107.....	100
Figura 29 – Estimativa de rendimento de óleo para os talhões plantados em 2017 a partir do teor de óleo estimado e a produtividade estimada para o ano de 2017.....	102

LISTA DE TABELAS

Tabela 01 – Descrição dos estádios vegetativos da soja	22
Tabela 02 – Descrição dos estádios reprodutivos da soja	23
Tabela 03 – Variedades de 2016 e as datas de plantio, colheita e o ciclo	60
Tabela 04 – Imagens Landsat 08/2016 entre junho e setembro e os estádios reprodutivos.....	61
Tabela 05 – Imagens Landsat 08/2017 entre junho e outubro e os estádios reprodutivos	64
Tabela 06 – Áreas colhidas e estimadas a partir do NDVI, IAF e SAVI – ciclo curto 2016.....	76
Tabela 07 – Áreas colhida e estimadas a partir do NDVI, IAF e SAVI – ciclo médio 2016.....	81
Tabela 08 – Análise exploratória dos dados de produtividade obtidos em campo no ano de 2017	87
Tabela 09 – Valores da validação cruzada para os dados de produtividade para finalização do processo de Krigagem ordinária.....	88
Tabela 10 – Amostragem de teor de óleo realizada em campo – Talhão E1-03, ano 2017.....	92
Tabela 11 – Análise exploratória dos dados de teor de óleo obtidos em campo no ano de 2017	93
Tabela 12 – Valores da validação cruzada para os dados de teor de óleo para finalização do processo de Krigagem ordinária.....	94
Tabela 13 – Temperaturas coletadas em campo no talhão E1-03 na altura do dossel, na 1/2 da planta e no solo, ano de 2017.....	95
Tabela 14 – Análise exploratória dos dados de temperatura do dossel obtidos em campo no ano de 2017.....	97
Tabela 15 – Valores da validação cruzada para os dados de temperatura do dossel para finalização do processo de Krigagem ordinária.....	97
Tabela 16 – Reclassificação da produtividade dos talhões para valores únicos.....	100
Tabela 17 – Reclassificação dos teores de óleo estimado para os talhões em valores únicos...	101
Tabela 18 – Reclassificação das produtividades estimadas para os talhões em 2017 para valores únicos	101

LISTA DE GRÁFICOS

Gráfico 01 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) pelo índice SAVI para variedades de ciclo curto (CC) ano de 2016	77
Gráfico 02 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) pelo índice NDVI para variedades de ciclo curto (CC) ano de 2016.....	77
Gráfico 03 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) pelo índice IAF para variedades de ciclo curto (CC) ano de 2016	78
Gráfico 04 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice SAVI para variedades de ciclo médio (CM) ano de 2016	82
Gráfico 05 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice NDVI para variedades de ciclo médio (CM) ano de 2016.....	82
Gráfico 06 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice IAF para variedades de ciclo médio (CM) ano de 2016	83
Gráfico 07 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice IAF para variedades de ciclo médio (CM) ano de 2016	90
Gráfico 08 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre os teores de óleo coletados em campo e as temperaturas do dossel	98

SUMÁRIO

1. INTRODUÇÃO	15
2. OBJETIVO.....	18
2.1 Objetivo geral.....	18
2.2 Objetivos específicos.....	18
3. REFERENCIAL TEÓRICO	19
3.1 Cultura da soja.....	19
3.1.1 Histórico	19
3.1.2 Panorama mundial e nacional.....	19
3.1.3 Aspectos Fenológicos.....	20
3.1.3.1 Hábito de crescimento	20
3.1.3.2 Cultivares	21
3.1.3.3 Estádios de desenvolvimento	21
3.1.3.4 Ciclo e grupo de maturidade relativa	23
3.1.4 Exigências Edafoclimáticas da Soja.....	24
3.1.4.1 Fotoperíodo	24
3.1.4.2 Temperatura	25
3.2 Produtividade da soja	26
3.3 Teor de Óleo.....	27
3.4 Rendimento de Óleo.....	28
3.5 Biodiesel.....	28
3.5.1 Cenário Mundial do Biodiesel.....	29
3.5.2 Cenário nacional biodiesel	30
3.5.3 Biodiesel no estado do Tocantins.....	31
3.6 Produção de sementes de soja	31
3.6.1 Cenário Tocantins – Soja subirrigada	32
3.6.2 Projeto Formoso	32
3.7 Geotecnologias	34
3.8 Sensoriamento Remoto	35
3.8.1 Resolução Temporal.....	36
3.8.2 Resolução espacial	37
3.8.3 Resolução radiométrica	37
3.8.4 Resolução espectral	38
3.8.5 Landsat 08	39
3.8.6 Índices de Vegetação.....	40
3.8.6.1 Índice de Área Foliar (IAF).....	41

3.8.6.2	Índice de Vegetação por Diferença Normalizada (NDVI)	42
3.8.6.3	Índice de Vegetação Ajustado ao Solo (SAVI)	43
3.8.7	Estimativa da Temperatura.....	44
3.8.8	Modelos de Estimativas	46
3.8.8.1	Estimativa área plantada.....	47
3.8.8.2	Estimativa produtividade.....	47
3.8.9	Lógica <i>fuzzy</i>	49
3.9	Geoestatística	50
3.9.1	Histórico	50
3.9.2	Modelos geoestatísticos.....	51
3.9.3	Kriging	52
3.9.4	Tipos de kriging	52
3.9.5	Semivariogramas.....	54
3.9.5.1	Modelo gaussiano.....	55
4.	MATERIAL E MÉTODOS	57
4.1	Área de estudo.....	57
4.2	Estimativa de área plantada.....	58
4.2.1	Seleção das variedades ano 2016	58
4.2.2	Identificação e obtenção das imagens Landsat 08, ano 2016.....	60
4.2.3	Procedimentos para estimativa de área plantada ano 2016	61
4.2.4	Correlação estatística entre área colhida e área estimada ano 2016	64
4.3	Estimativa da Produtividade.....	64
4.3.1	Interpolação dos dados	65
4.4	Teor de óleo e temperatura.....	66
5.	RESULTADOS E DISCUSSÃO	69
5.1	Estimativa de área plantada de variedades de ciclo curto, ano 2016.....	69
5.1.1	Análise estatística ciclo curto	76
5.2	Estimativa de área plantada de variedades de ciclo médio, ano 2016.....	78
5.2.1	Análise estatística ciclo médio	81
5.3	Estimativa da produtividade para o ano de 2017	87
5.4	Teor de óleo.....	91
5.5	Temperatura	95
5.6	Rendimento de óleo.....	99
6.	CONCLUSÃO	103

1. INTRODUÇÃO

As culturas agrícolas são caracterizadas pelos seus específicos ciclos fenológicos que interpretam como a cultura se desenvolve desde a emergência até a maturação. Diante disso, é possível mensurar as suas exigências aos fatores climáticos como, a temperatura em determinadas fases do seu desenvolvimento (ALBRECHT; BRACCINI et al., 2008)

Na agricultura atual, incrementos nos rendimentos e reduções nos custos e nos riscos de insucesso dependem cada vez mais de decisões mais acertadas, tendo em vista a atual situação da economia mundial. Sendo assim, o agricultor sempre deve tomar decisões baseadas nos riscos que envolvem a produção de determinada cultura e a obtenção de maior lucratividade.

Em relação aos riscos, são considerados aqueles referentes às incertezas de mercado e às condições climáticas imprevisíveis. Toda e qualquer ferramenta que venha ajudar no processo decisório é de grande valia ao setor agrícola (FARIAS; ALMEIDA; GARCIA, 1997).

Nessa perspectiva, novas tecnologias de produção, como a de biodiesel, baseadas em culturas agroenergéticas como, a soja, girassol, pinhão manso, amendoim, entre outros, exigem as mesmas atenções a serem dadas, quanto aos riscos que influenciam diretamente no teor e no rendimento de óleo para a produção de biodiesel, assim como no valor proteico para os produtos alimentícios.

Apesar desses cuidados, a produção de biocombustível apresenta um cenário promissor por caracterizar-se como um produto capaz de redução dos níveis de poluição. Diante desse contexto, é considerado como alternativa estratégica em substituição ao óleo diesel e outros derivados do petróleo (CLEMENTE; CAHON, 2009).

Sendo assim, o Brasil apresentou em 2006 o Plano Nacional de Agroenergia que visa organizar e desenvolver uma proposta de pesquisa, desenvolvimento, inovação e transferência de tecnologia com intuito de garantir sustentabilidade e competitividade às cadeias de agroenergia (OLIVEIRA; RAMALHO, 2006).

A ideia do plano leva em consideração a quantidade de vantagens que qualifica o país como líder na produção de bioenergia, bem como, o mercado de produtos bioenergéticos em nível mundial. Isso ocorre mediante a quantidade de terras agricultáveis, além de situar-se, predominantemente, nas faixas tropical e subtropical, o que proporciona receber durante todo o ano intensa radiação solar, que é a base da

produção de bioenergia, como também possui ampla diversidade de clima (OLIVEIRA; RAMALHO, 2006).

Além disso, existem outras vantagens como a disponibilidade hídrica por conta da quantidade de Bacias Hidrográficas e solos adequados para implantação dessas culturas bioenergéticas, o que demonstra o perfil positivo como é caso da produção de grãos no Brasil.

A soja é cultivada em regiões com temperaturas do ar com variações entre 20°C e 30°C e a temperatura ideal para seu crescimento e desenvolvimento está em torno de 30°C (EMBRAPA, 2016). A variabilidade da temperatura entre os 20-40 dias antes da maturação dos grãos exerce maior influência sobre o acúmulo de óleo do que as ocorridas em outros estádios do desenvolvimento da cultura (BARBOSA; PELUZIO et al, 2011).

Além da alimentação, a soja possui destaque na produção de biocombustível (biodiesel), que no Brasil, atingiu a produção de 237.585 m³, conforme Anuário Estatístico da Agroenergia (2014) onde 79,7% dos biocombustíveis são oriundos do óleo de soja (BRASIL, 2014).

A soja é o maior destaque na produção de grãos do Tocantins, com aproximadamente 1 milhão de hectares de áreas com plantio e produção de mais de 2,85 milhões de toneladas. Essa leguminosa é seguida do milho, que tem uma área aproximada de 200 mil hectares e produção de mais de 882 mil toneladas. Na sequência, vem o arroz com 129 mil hectares e produção de 650 mil toneladas, número que coloca o Estado em terceiro lugar no índice de produção do grão (PAIXÃO, 2018).

No município de Formoso do Araguaia – TO, a soja é cultivada no período de entressafra (maio-junho) entre os períodos seco e chuvoso, podendo variar o início do plantio conforme o regime de chuvas durante o ano. Um outro fator é a baixa umidade e a temperatura noturna em condições de várzea irrigada, sob regime de irrigação subsuperficial (controle do lençol freático), o que favorecem a produção sementes de qualidade (ALMEIDA; PELUZIO; AFFÉRI, 2011).

O cenário de Formoso do Araguaia na entressafra é de ausência de chuvas, aliada à baixa umidade relativa do ar e à baixa temperatura noturna, o que tem possibilitado a obtenção de sementes de boa qualidade. Assim, a produção de soja comercializada na forma de semente, nesse período, tem-se tornado altamente atrativa e compensadora para os produtores (PELÚZIO; FIDELIS, et al 2005).

Em busca de mais informações sobre as culturas em geral, atualmente, diversas tecnologias são empregadas em uma escala geográfica maior e com um nível de

detalhamento de maior qualidade, ou seja, o mais próximo da informação realista que é presenciada em campo. Através de imagens aéreas é possível o mapeamento de culturas, a avaliação de áreas cultivadas, a detecção de áreas afetadas, o mapeamento do solo, entre outras possibilidades, como exemplo, o uso das imagens do satélite Landsat 08, que são disponibilizadas pelo Serviço Geológico dos Estados Unidos (USGS) (MOREIRA, 2007).

Juntamente ao Sensoriamento Remoto, as informações extraídas são tratadas com auxílio de técnicas de Geoprocessamento que conforme Silva (2009) são trabalhados volumes de dados com técnicas computacionais e são disponibilizados atributos geotopológicos, para fins de análises, sínteses e utilização no planejamento ambiental e na gestão territorial. Esse conjunto de tecnologias torna-se mais acessível devido aos avanços de hardwares e softwares com alta capacidade de processamento. Além disso, são produtos disponibilizados gratuitamente e com um alto índice de aceitabilidade, como é caso das imagens orbitais disponibilizadas pela da missão LANDSAT 08, no portal do USGS.

A missão do Landsat-8 foi lançada pela NASA em 11 de fevereiro de 2013. A plataforma opera com dois instrumentos imageadores, Operational Land Imager (OLI) que consistem em nove bandas espectrais com uma resolução espacial de 30 metros para Bandas 1 a 7 e 9. A resolução para a faixa 08 (pancromática) é de 15 metros e o Thermal Infrared Sensor (TIRS) com as bandas térmicas 10 e 11, que são úteis para proporcionar temperaturas de superfície mais precisas e são recolhidas com uma resolução espacial de 100 metros. O tamanho aproximado da cena é 170 km norte-sul por 183 km Leste-Oeste (USGS, 2015).

2. OBJETIVO

2.1 Objetivo geral

O presente estudo tem o objetivo de avaliar índices de vegetação e temperatura, como alternativa para estimar área plantada, produtividade de grãos e rendimento de óleo na região de várzea do Tocantins, no município de Formoso do Araguaia – TO visando a produção de biocombustível na região.

2.2 Objetivos específicos

- ✓ Analisar os índices de vegetação (NDVI, SAVI e IAF) e as áreas colhidas em campo no ano de 2016 obtendo o melhor comportamento dentre eles;
- ✓ Interpolar os dados de produtividade de 2017 para obter a análise de regressão para as estimativas de produtividades para os talhões;
- ✓ Ajustar uma função de regressão para estimar o teor de óleo, a partir da temperatura obtida dos sensores remotos;
- ✓ Obter o rendimento do óleo baseado nos resultados das estimativas de teor de óleo e as produtividades estimadas para os talhões no ano de 2017.

3. REFERENCIAL TEÓRICO

O Brasil representa uma referência mundial na produção de agroenergia. Programas como o etanol e o biodiesel atraem a atenção do mundo por representarem alternativas que oferecem viabilidade econômica e ecológica à substituição dos combustíveis fósseis (ÁVILA, 2013).

O biodiesel é um combustível renovável obtido a partir de um processo químico denominado transesterificação. Por meio desse processo, os triglicerídeos presentes nos óleos e gordura animal reagem com um álcool primário, metanol ou etanol, gerando dois produtos: o éster e a glicerina, e em se tratando da soja, referente ao teor de óleo, com um percentual de 18% em relação ao grão (OLIVEIRA; RAMALHO, 2006).

3.1 Cultura da soja

3.1.1 Histórico

A soja (*Glycine Max* L. Merrill) é uma planta da família das leguminosas originária da Ásia, mais precisamente no nordeste da China, na região da Manchúria (HYMOWITZ, 2015). Considerada uma das culturas mais antigas, a soja chegou ao ocidente no final do século XV e início do século XVI permanecendo no oriente pelos 02 milênios seguintes (HARLAN, 2015). No Brasil, a soja constou na estatística a partir de 1941 no estado do Rio Grande do Sul com uma área de 702 hectares. A partir de 1950 expandiu-se para o Sudeste, Norte e Nordeste (SEDIYAMA; TEIXEIRA; BARROS, 2009).

3.1.2 Panorama mundial e nacional

A nível mundial houve um aumento de 120 milhões de hectares (2016/17), para 124,5 milhões de hectares para 2017/18 (USDA, 2018) em relação a área plantada de soja. O Brasil segue esse aumento com 33,94 milhões hectares na safra 2016/17, e em 2017/18, aumento de 2,6%, com área plantada de 34,82 milhões de hectares (IBGE, 2018), inferior aos Estados Unidos com 36,23 milhões de hectares (USDA, 2018).

A produção mundial de soja na safra 2016/17 alcançou 351,32 milhões de toneladas e já na safra 2017/18 houve uma diminuição para 336,69 milhões de toneladas. Desse total, os Estados Unidos aparecem com 119,51 milhões de toneladas (USDA, 2018), enquanto que o Brasil na safra 2016/17 alcançou as 114,98 milhões de toneladas e em 2017/18 com 116,30 milhões de toneladas, aumento de 1,2% em relação à safra anterior (IBGE, 2018).

Os Estados Unidos em 2016/17 com produtividade de 3,49 toneladas por hectares, diminuiu para 3,29 toneladas em 2017/18 (USDA, 2018). O Brasil foi o segundo colocado no ranking mundial com a diminuição de 3,39 para 3,34 toneladas por hectare, variação de -1,4% em relação à safra anterior (IBGE, 2018).

No Brasil, o estado do Mato Grosso é o maior produtor brasileiro de soja com uma produção de 31,88 milhões de toneladas e área plantada de 9.519 milhões de hectares seguido pelo Paraná com 19 milhões de toneladas e 5.444 milhões de hectares e o Rio Grande do Sul com 16,97 milhões de toneladas e 5.692 milhões de hectares (CONAB, 2017).

O Tocantins apresentou aumento da produção em relação à safra de 2017 com 2.471 milhões de toneladas à safra de 2018 com 2.586.846 milhões de toneladas, acréscimo de 4,7% na produção de soja no estado. A área plantada também aumentou de 871.254 hectares para 888.601 hectares, assim como a produtividade de 2.836 kg/ha com um aumento de 2,6% com 2.911 kg/ha na safra de 2018 (IBGE, 2018).

3.1.3 Aspectos Fenológicos

Assim como toda cultura agrônômica, o estabelecimento adequado das plantas de soja determina-se pelo número de plantas por área e a formação do dossel que é composto pelas folhas e as diversas ramificações dos caules. Esse processo é de fundamental importância para a obtenção de elevados rendimentos de grãos.

3.1.3.1 Hábito de crescimento

As cultivares de soja são classificadas quanto ao hábito de crescimento, sendo consideradas como determinado ou indeterminado. O crescimento determinado apresenta plantas com caules finalizados por racemos florais com a finalização do ciclo vegetativo. E após o início do florescimento, as plantas aumentam muito pouco em altura, pois a haste principal termina com uma inflorescência racemosa e, geralmente, as últimas folhas apresentam similaridade (de forma e tamanho) com as demais. Já as cultivares com crescimento indeterminado não apresentam racemos florais terminais, isto é, continuam o crescimento por um período longo, com aproximadamente o dobro do tamanho da planta após iniciado o florescimento.

O início do estabelecimento da planta de soja é dado pela semeadura e, em seguida, pela emergência das plântulas que ocorre entre 07 e 10 dias. Esse desenvolvimento depende do vigor da semente, da profundidade de semeadura, umidade,

textura e temperatura do solo. O desenvolvimento após a semeadura é dividido em dois períodos: o vegetativo, da semeadura ao florescimento e o reprodutivo, do florescimento à colheita. (SEDIYAMA; SILVA; BORÉM, 2015).

3.1.3.2 Cultivares

O uso de cultivares de diferentes ciclos é a estratégia de manejo mais apropriada para melhor utilização da estação de crescimento. As cultivares mais tardias são preferencialmente semeadas no início e fim da época recomendada enquanto às precoces são semeadas em períodos intermediários da época preconizada. No Brasil, os primeiros cultivares plantados não eram adaptados às nossas condições de clima tropical, com o estabelecimento inicial na região sul (SILVA; SEDIYAMA et al., 2015).

No Brasil, estão registradas 2.810 cultivares de soja avaliados em diferentes safras, épocas e locais para determinação da interação entre genótipo x ambiente, identificando a adaptabilidade e estabilidade dos genótipos. Também, são consideradas as características agronômicas, ciclo e reação a doenças, o que possibilita a recomendação de cultivares adaptados às condições específicas e amplas em busca da melhor exploração do potencial produtivo (MAPA, 2017).

3.1.3.3 Estádios de desenvolvimento

A caracterização dos estádios de desenvolvimento é fundamental para o estabelecimento de um organizado sistema de produção por meio do manejo adequado da lavoura. (CÂMARA, 1998). O desenvolvimento da soja compreende duas principais fases: a vegetativa e a reprodutiva. A duração de cada uma delas é controlada geneticamente e influenciada por condições ambientais.

A classificação dessas fases é feita com base na observação das folhas, flores e no desenvolvimento da vagem e semente, que se encontram nos nós da haste principal da planta. As tabelas 01 e 02 especificam os estádios vegetativo e reprodutivo.

Tabela 01 – Descrição dos estádios vegetativos da soja

Estádios	Denominação	Descrição
VE	Emergência	Os cotilédones estão acima da superfície do solo
VC	Cotiledonar	As folhas unifolioladas estão suficientemente estendidas de tal modo que os bordos não se tocam
V1	Primeiro nó	Folhas unifolioladas completamente desenvolvidas
V2	Segundo nó	Folha trifoliolada completamente desenvolvida, localizada no nó acima dos nós das folhas unifolioladas
V3	Terceiro nó	Três nós sobre a haste principal com folhas completamente desenvolvidas, iniciando-se a contagem dos nós a partir dos nós das folhas unifolioladas
Vn	E-nésimo nó	n número de nós sobre a haste principal com folhas completamente desenvolvidas, iniciando-se a contagem dos nós a partir dos nós das folhas unifolioladas

Fonte: FEHR; CAVINESS, 1977

Tabela 02 – Descrição dos estádios reprodutivos da soja

Estádios	Denominação	Descrição
R1	Início da floração	Uma flor aberta em qualquer nó da haste principal
R2	Floração plena	Folha aberta e um dos dois últimos nós, da haste principal com folha completamente desenvolvida
R3	Início da formação de vagem	Vagem com 5mm de comprimento em um dos quatro últimos nós superiores com folha completamente desenvolvida, sobre a haste principal
R4	Vagem completamente desenvolvida	Vagem com 20 mm de comprimento em um dos quatro últimos nós superiores com folha completamente desenvolvida, sobre a haste principal
R5	Início da formação da semente	Semente com 03 mm de comprimento em uma vagem localizada em um dos quatro últimos nós superiores com folha completamente desenvolvida sobre a haste principal
R6	Semente completamente desenvolvida	Vagem contendo semente verde, preenchendo a cavidade da vagem localizada em um dos quatro últimos nós superiores com folha completamente desenvolvida sobre a haste principal
R7	Início da maturação	Vagem normal sobre a haste principal que tenha atingido a cor da vagem madura
R8	Maturação plena	95% de vagens que tenham atingido a cor de vagem madura. Após R8, são necessários de 5 a 10 dias de tempo seco para que a semente de soja apresente menos de 15% de umidade

Fonte: FEHR; CAVINESS, 1977

3.1.3.4 Ciclo e grupo de maturidade relativa

A maioria dos cultivares adaptados para as condições brasileiras apresenta o ciclo em torno de 90 a 150 dias (SEDIYAMA; TEIXEIRA; BARROS, 2009). Os cultivares

podem ser classificados quanto ao ciclo, em: superprecoce, precoce, semiprecoce, médio, semitardio e tardio. Sendo que o ciclo varia quando é deslocada entre o Sul e o Norte, em razão da sensibilidade da soja ao fotoperíodo (EMBRAPA, 2010), logo os cultivares tem faixa limitada de adaptação. A divisão do país em faixa de latitude, em grupos de maturidade relativa (GMR) foi proposta inicialmente nos EUA. Os GMR's predominantes em cada região do Brasil estão apresentados na seguinte Figura 01:



Figura 1. Distribuição dos grupos de maturidade relativa de cultivares de soja no Brasil, em função da latitude.

Fonte: Adaptado de Alliprandini et al (2009)

Dimensionados dessa forma para latitude, certos cultivares podem ser de maturação precoce ou tardia, dependendo do fotoperíodo crítico exigido para que ocorra a indução ao florescimento. Dessa forma, se dois cultivares forem semeados na mesma data, o que tiver fotoperíodo crítico maior irá florescer antes, pois será induzido mais precocemente, enquanto o cultivar com fotoperíodo crítico menor será induzido mais tardiamente.

3.1.4 Exigências Edafoclimáticas da Soja

3.1.4.1 Fotoperíodo

O fotoperíodo é o fator mais importante para se determinar a proporção relativa entre os estádios vegetativos e reprodutivos da planta de soja, uma vez que, influencia diretamente a indução floral, e conseqüentemente, o crescimento, maturação, altura da planta, peso de sementes, número de ramificações e outras características agrônômicas (BARROS; SEDIYAMA, 2015).

O tempo compreendido entre a emergência da plântula e o dia em que ela estiver apta a receber o estímulo floral é denominado período juvenil curto e longo. A soja é uma planta de dia curto, ou seja, floresce em fotoperíodos menores que um máximo crítico. A planta de soja é induzida a florescer se a duração do dia for igual ou inferior àquele valor crítico que caracteriza o cultivar (SEDIYAMA; TEIXEIRA; BARROS, 2015).

Dessa forma, na ausência do comprimento de dia favorável para induzir a expressão dos processos reprodutivos, a planta de soja pode continuar seu crescimento vegetativo. Ao contrário, sob influência do fotoperíodo adequado, o florescimento pode ser induzido mais precocemente, desde que esta esteja apta a perceber a variação do comprimento do dia. Em razão desses fatores, considerando as estações do ano, a soja é semeada na primavera/verão e floresce quando os dias já estão se encurtando no verão (SILVA; SEDIYAMA; BORÉM, 2015).

3.1.4.2 Temperatura

A soja melhor se adapta a temperaturas do ar entre 20°C e 30°C, sendo que a temperatura ideal para seu crescimento e desenvolvimento está em torno de 30°C. A semeadura da soja não deve ser realizada quando a temperatura do solo estiver abaixo de 20°C, pois prejudica a germinação e a emergência. A faixa de temperatura do solo adequada para semeadura varia de 20°C a 30°C, sendo 25°C a temperatura ideal para uma emergência rápida e padronizada (FARIAS; NEPOMUCENO; NEUMAIER, 2007).

O crescimento vegetativo da soja é pequeno ou nulo às temperaturas menores ou iguais a 10°C. Temperaturas acima de 40°C tem efeito adverso na taxa de crescimento, pois provocam distúrbios na floração e diminuem a capacidade de retenção de vagens (EMBRAPA, 2010).

Quando o fotoperíodo se apresenta de forma constante, é a temperatura que influencia bastante o tempo de florescimento (GARNER; ALLARD, 1930), caso haja uma relação inversa entre a temperatura média e o número de dias necessários para a floração (RODRIGUES; DIDONET et al., 2001). Para qualquer cultivar, a taxa de desenvolvimento da planta está diretamente relacionada à temperatura (HUNGRIA, CAMPO; MENDES, 2002). Assim, a duração de tempo dentre os diferentes estádios será variável conforme as mudanças de temperatura entre e dentro dos estádios de crescimento. A duração desses subperíodos é determinada pelo grau de sensibilidade a temperatura e ao fotoperíodo do genótipo.

A nodulação da soja também é influenciada pela temperatura, assim como maior massa de nódulos e fixação de nitrogênio são observadas quando a temperatura do solo está em torno de 27°C. As temperaturas elevadas e o estresse hídrico, muitas vezes atuando juntos, são os principais fatores ambientais limitantes à fixação biológica de nitrogênio nos trópicos (HUNGRIA; CAMPO; MENDES, 2002).

A qualidade das sementes é afetada negativamente quando a umidade e a temperatura estão altas, mas temperaturas baixas na fase de maturação, associadas aos períodos chuvosos ou de alta umidade, podem adiar a data de colheita (EMBRAPA, 2010).

3.2 Produtividade da soja

A cultura da soja possui componentes importantes de rendimento que são responsáveis pela produtividade como, número de plantas por área, número de vagens por planta, número de grãos por vagem e o peso de grão (normalmente expresso em peso de mil grãos). Todos os componentes possuem uma relação entre si, sendo assim, é impossível manejar apenas um deles sem influenciar os outros. Dessa forma, se aumentarmos muito o número de plantas por área, pode-se favorecer o aparecimento de plantas com menor número de vagens ou com redução de grãos por vagem. Sendo assim, para obter altas produtividades é necessário manejo adequado da cultura (LEE; HERBEK, 2005).

O manejo inicia-se sempre pela escolha de cultivares recomendadas para a região, com sementes de boa qualidade e plantio realizado na época recomendada, além do manejo adequado de plantas invasoras, pragas e doenças.

A estimativa da produtividade é realizada após o estágio R5 (início do enchimento dos grãos) é a mais adequada, pois é neste momento que as vagens estão formadas e o número de grãos por vagem definido. Estimativas anteriores a esta fase podem ser imprecisas, levando em consideração as modificações que ainda acontecem nos componentes de rendimento até a colheita (CASTEEL, 2012).

Atualmente o maquinário de colheita representado pelas colheitadeiras possuem sistemas que permitem ao operador mensurar a produtividade e umidade do que está sendo colhido, com sensores instalados que trazem ao operador, a visualização quanto à condição da cultura colhida. Este sistema proporciona a geração de um mapa de colheita, com informações importantes para o próximo plantio (DEER; COMPANY, 2018). No

presente trabalho os dados de produtividade foram fornecidos pela empresa Talismã Sementes.

3.3 Teor de Óleo

O óleo de soja continua sendo a principal matéria-prima para a produção de biodiesel (B100), equivalente a 79,1% do total, com uma queda de 1,3% em relação a 2015. (ANP, 2017).

A variação do teor de óleo é determinada principalmente por fatores genéticos, mas com forte influência ambiental, principalmente no período de enchimento de grãos. Como a cultura da soja é semeada em todo o território brasileiro, é esperado que ocorram variações expressivas nesses teores de óleo à medida que varie as práticas culturais, as características e o manejo do solo, a altitude e as condições de clima, sobretudo chuvas e radiação solar (PÍPOLO; HUNGRIA et al., 2015).

Os cultivares de soja semeados em diferentes ambientes expressam suas potencialidades em relação às condições ocorridas que mudam no espaço e no tempo. Como os genótipos podem responder diferencialmente ao ambiente, as indicações da melhor época para cada cultivar devem ser precedidas de ensaios regionalizados, conduzidos em diferentes ambientes (PELUZIO; AFFÉRI et al., 2010).

Para diminuir o efeito da interação entre o genótipo e o ambiente, a condução dos experimentos no maior número possível de locais e anos é necessária para se avaliar a magnitude da interação e seu possível impacto sobre a seleção e a recomendação de cultivares. A fim de tornar essa recomendação segura, é necessário um estudo detalhado acerca da adaptabilidade e da estabilidade das cultivares, assim como de seus caracteres importantes economicamente (SILVA; DUARTE, 2006).

Dentre essas variações, as temperaturas mais altas e as menores incidências de precipitação na fase final de enchimento dos grãos, promovem um comportamento diferencial entre as cultivares que provavelmente acarretam em distúrbios bioquímicos nas biossínteses de óleo (ALBRECHT, 2008).

Os mecanismos de enchimento dos grãos quanto ao teor de óleo, ainda são incipientes, mas é sabido que há correlação negativa entre o teor de proteína e o teor de óleo (PÍPOLO; HUNGRIA et al., 2015).

As médias dos teores de óleo das cultivares se diferem conforme as posições das vagens na haste das plantas. Em análise multivariada nos grãos de soja localizados em diferentes partes da planta visando a produção de bioenergia, com exceção da BRS

Valiosa, apresentaram diferenças significativas quanto ao teor de óleo, para as diferentes posições das vagens na haste da planta, sendo os maiores valores observados nos terços inferior e médio (SALES, 2014).

A resposta diferenciada das cultivares quanto ao teor médio de óleo nos grãos, para as diferentes posições da vagem na haste da planta, pode estar associada ao sombreamento (BURKLEY; WILSON; WELLS, 1997) à arquitetura da planta, hábito de crescimento e maturação (BELLALLOUI; GILLEN, 2010).

3.4 Rendimento de Óleo

Os altos rendimentos da soja ocorrem num período de 50 a 55 dias de crescimento vegetativo e acúmulo de 400 a 500g de matéria seca da parte aérea por m² no florescimento. Neste período (vegetativo), formam-se o aparato fotossintético (folhas) e o número potencial de locais (nós do caule e dos ramos) com gemas onde poderá haver florescimento.

Resultados de rendimento de óleo são baseados na produtividade e no teor de óleo da semente, onde o percentual de variação do teor gira em torno de 17 e 28%, dependendo do método de extração e das características climáticas do local. De certa forma, ainda, são escassas as pesquisas quanto à obtenção desse produto, que apesar da grande importância da cultura no Estado do Tocantins na produção de grãos e em destaque, objeto desse estudo, as várzeas tropicais, há escassez de pesquisas relacionadas à influência da época de semeadura em características agronômicas nas cultivares, principalmente, em relação às características teor e rendimento de óleo (BARBOSA, PELUZIO et al., 2011).

3.5 Biodiesel

Criado em 1977, o biodiesel é um combustível renovável, biodegradável e ambientalmente correto, sucedâneo ao óleo diesel mineral, constituído de uma mistura de ésteres metílicos ou etílicos de ácidos graxos, obtidos da reação de transesterificação de qualquer triglicerídeo com um álcool de cadeia curta, metanol ou etanol (PARENTE, 2003).

Considera-se o biodiesel como sendo uma denominação genérica para combustíveis produzidos a partir de fontes renováveis, como óleos vegetais e gorduras animais para serem utilizados em motores de ignição por compressão, também

conhecidos como motores a diesel. Além disso, o biodiesel pode ser usado para geração de energia em substituição ao óleo diesel e ao óleo combustível (LIMA, 2004).

O biodiesel é obtido a partir de um processo químico denominado transesterificação. Por meio desse processo, os triglicerídeos presentes nos óleos e gordura animal reagem com um álcool primário, metanol ou etanol, gerando dois produtos: o éster e a glicerina. O primeiro somente pode ser comercializado como biodiesel, após passar por processos de purificação para adequação à especificação da qualidade, sendo destinado principalmente à aplicação em motores de ignição por compressão (ANP, 2016).

Segundo a lei 11.097 de 13 de janeiro de 2005 art. 6º inciso XXV diz que : O Biodiesel é um biocombustível derivado de biomassa renovável para uso em motores a combustão interna com ignição por compressão ou conforme regulamento, para geração de outro tipo de energia que possa substituir parcial ou totalmente combustíveis de origem fóssil (BRASIL, 2005).

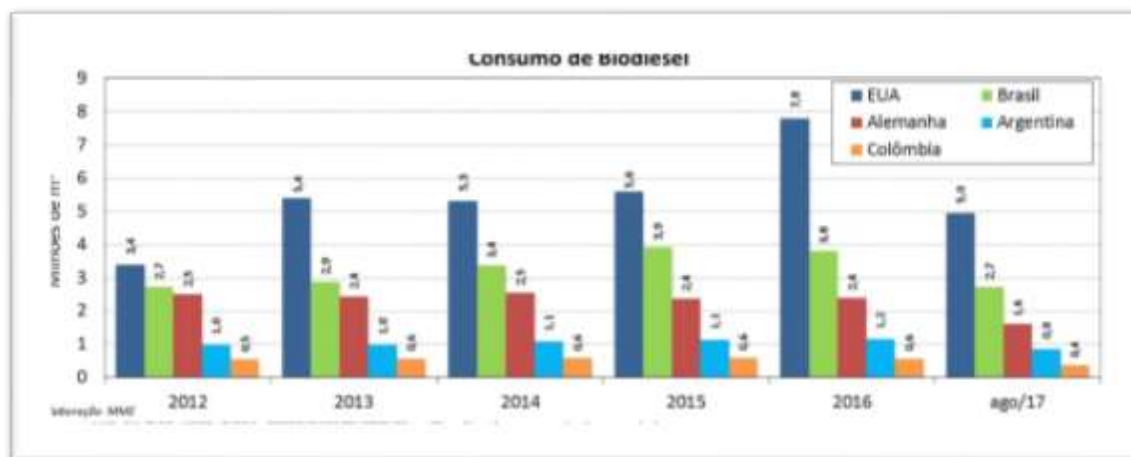
Quimicamente, o biodiesel é definido como éster monoalquílico de ácidos graxos derivados de lipídeos de ocorrência natural e pode ser produzido, juntamente com a glicerina, através da reação de triacilgliceróis (ou triglicerídeos) com etanol ou metanol, na presença de um catalisador ácido ou básico (RAMOS; KUCEK et al., 2003).

Seguindo esta tendência, no mercado dos biocombustíveis adotou-se internacionalmente a expressão BXX na qual “B” significa Biodiesel e “XX” a proporção do biocombustível misturado ao óleo diesel. Assim, a sigla “B2” significa 2% de biodiesel, derivado de fontes renováveis e 98% de óleo diesel e o “B5” equivale a 5% de biodiesel e 95% de óleo mineral e assim sucessivamente sendo produzido conforme especificações técnicas definidas pela Agência Nacional de Petróleo (BRASIL, 2016).

3.5.1 Cenário Mundial do Biodiesel

Em 2014, o Brasil foi o segundo maior consumidor de biodiesel (3,4 milhões de m³), atrás somente dos Estados Unidos (5,3 milhões de m³). Até outubro de 2015, estimou-se o consumo brasileiro em 3,3 milhões de m³. Nesse período, não foram registradas exportações significativas (BRASIL, 2017).


Figura 02 – Consumo Biodiesel



Fonte: MME, 2017

Em 2014, os Estados Unidos como sendo o maior produtor de biodiesel (4,7 milhões de m³) seguido por Brasil e Alemanha, (com semelhantes 3,4 milhões de m³), e na sequência, Indonésia, Argentina, França, Tailândia e China. A oferta mundial de biodiesel em 2014 foi de 29,7 milhões de m³ (BRASIL, 2015).

Figura 03 – Produção de Biodiesel 2014



Fonte: MME, 2015

3.5.2 Cenário nacional biodiesel

No Brasil os percentuais mínimos de biodiesel que devem ser adicionados ao diesel são constituídos pela lei 11.097/2005 que estabeleceu os percentuais mínimos e introduziu o biodiesel na matriz energética nacional, assim como determinou que no período de 2005 a 2007 estava autorizada a utilização de 2% de biodiesel no diesel. E no período de 2008 a 2012 essa porcentagem passaria a ser obrigatória, deixando de ser facultativa, e de 2013 em diante a porcentagem mínima passaria a ser de 5% (BRASIL, 2005). A proporção de biodiesel adicionada ao óleo diesel passou a ser de 6% a partir de

julho e de 7% a partir de novembro de 2014, conforme a Lei nº 13.033/2014 (BRASIL, 2014).

Em 2016, a capacidade nominal de produção de biodiesel (B100) no Brasil era de cerca de 7,4 milhões de m³ (20,5 mil m³/dia). Entretanto, a produção nacional foi de 3,8 milhões de m³, o que correspondeu a 51,3% da capacidade total. Em comparação a 2015, a produção de biodiesel foi 3,5% inferior. A Região Centro-Oeste permaneceu como a maior produtora de biodiesel, com volume de cerca de 1,6 milhão de m³, equivalente a 43,3% da produção nacional. Em seguida veio a Região Sul, com uma produção de 1,5 milhão de m³, 41% do total nacional. O Rio Grande do Sul continuou como o maior produtor de biodiesel, com um volume de aproximadamente 1,1 milhão de m³, equivalente a 28,3% do total nacional (ANP, 2017).

3.5.3 Biodiesel no estado do Tocantins

O estado do Tocantins apresenta-se como uma alternativa para a produção de biocombustível, principalmente pela disponibilidade de terras e a melhoria das condições de logística, aliadas à perspectiva da redução de custos de transporte pelos projetos de implantação de novos modais de transporte: a Ferrovia Norte-Sul, em estágio mais avançado e a hidrovia Araguaia-Tocantins, ainda na fase de análise da viabilidade de sua implantação (RODRIGUES; LUNCKES, 2011).

Em 2012, a Granol adquiriu a unidade de Porto Nacional operando inicialmente com a produção de biodiesel com capacidade para 500 m³ diários (ANP, 2017). Em 2015 ampliou a operação da unidade com o esmagamento de soja. Três outros armazéns são alojados nos municípios de Aguiarnópolis, Figueirópolis e Guaraí para fazer o armazenamento do grão. A esmagadora de Porto Nacional opera um transbordo interligado à Ferrovia Norte Sul que permite a esta nova planta de esmagamento reduzir custos de movimentação do farelo para os portos do Norte, os quais têm uma posição estratégica, localizados próximos aos mercados da Europa, América do Norte e Canal do Panamá que facilita o acesso ao mercado asiático (SEPLAN, 2016).

3.6 Produção de sementes de soja

O embrião maduro na soja é constituído de um eixo com dois cotilédones, o epicótilo, localizado acima dos cotilédones, e o hipocótilo-radicular que se refere ao eixo abaixo dos cotilédones. Quando ocorre a formação da radícula, é feita a distinção entre

hipocótilo e radícula. As reservas nutricionais (endosperma) e o revestimento (tegumento) do embrião quando maduro constituem a semente (MULLER, 1981).

A produção de semente de alta qualidade requer que as fases de maturação e de colheita ocorram sob temperaturas amenas, associadas às condições climáticas do período seco. Tais condições não são facilmente encontradas em regiões tropicais, porém podem ocorrer em áreas com altitude superior a 700 m, ou com o ajuste da época de semeadura para a produção de semente. Em regiões com latitudes acima de 24° Sul, onde as condições climáticas são mais propícias.

3.6.1 Cenário Tocantins – Soja subirrigada

A região de várzea do Tocantins compreende uma área de plantio com 57.552 hectares de soja que engloba os municípios de Lagoa da Confusão, Dueré, Pium, e Formoso do Araguaia que são atendidas por projetos de subirrigação com uma produção de 159.649 toneladas e produtividade média de 2.774 kg/ha em 2015. O plantio é destinado exclusivamente à pesquisa científica e a produção de semente. Dentre os municípios, os dois maiores quanto a área plantada são Lagoa da Confusão e Formoso do Araguaia (CONAB, 2017).

O município da Lagoa da Confusão com 32.420 ha, apresenta área plantada quase duas vezes maior que Formoso do Araguaia com 17.940 ha. Em relação a produtividade, dentre os municípios com maior área plantada, o município de Formoso do Araguaia apresenta valores médios de produtividade com 2700 kg por hectare, sendo o destaque para Dueré com produtividade média de 2850 kg por hectare (CONAB, 2017).

3.6.2 Projeto Formoso

O projeto Rio Formoso faz parte do Projeto Javaés/Mesopotâmia – atualmente denominados projetos de irrigação das várzeas do Araguaia no Plano Estadual de Irrigação (PEI/TO) –, cujo principal objetivo é permitir o cultivo de duas safras por ano (safra e entressafra), por meio da construção de barramentos. A proposição da agricultura irrigada na Planície do Araguaia iniciou-se com o projeto de desenvolvimento integrado à bacia do Araguaia-Tocantins PRODIAT, no período de 1980 a 1983. O Projeto Rio Formoso situa-se à margem direita do Rio Formoso e foi implantado pelo governo do Estado de Goiás entre os anos de 1979 e 1983. Em 1988, Goiás transferiu o projeto para o governo do Estado do Tocantins, área que se tornou uma das maiores produtoras de arroz do estado.

Na área do Projeto Formoso utiliza-se de um sistema de irrigação de inundação e subirrigação, com produção de arroz irrigado (inundação) no período chuvoso (outubro a abril). Já a soja, milho, feijão e melancia (subirrigação) no período seco (maio a setembro).

As infraestruturas de uso comum no projeto Rio Formoso (barragens, canais principais de irrigação e drenagem, sistema viário interno, etc.), que por questões legais são de domínio público, ficaram durante mais de 30 anos sem a devida manutenção devido à falta de uma política definida na época de sua implantação. Isso acarretou o desgaste destas estruturas, comprometendo o desempenho do projeto. (SEPLAN, 2012)

Muitas cooperativas se instalaram no município para investimentos em cultivo de arroz irrigado, milho, melancia e soja. As cooperativas formadas são: COBRAPE, COOPERFORMOSO, COOPERGRAN e COOPERJAVA, somando uma área de 17.200 ha de arroz irrigado e 300 ha de milho.

Devido a vários projetos irrigados, foram instaladas várias unidades de beneficiamento (secadores e armazéns) para suportar a produção regional, sendo elas: CONAB, COOPERJAVA, CALUMBI, COBRAPE, Verdes Campos, Lagoa Grande, CASETINS, SEVAJA e COOPERFORMOSO.

A temperatura do ar considera-se como elemento climático que exerce maior influência sobre as culturas exploradas na entressafra, principalmente quando não dispõe do quantitativo hídrico apropriado. No município de Formoso do Araguaia – TO, as temperaturas máximas ocorrem no mês de setembro, com médias em torno de 35 graus, e as mínimas 18 graus durante o mês de julho (PARTENIANI, 2006). Durante a entressafra (maio a outubro), as temperaturas máximas nas várzeas do Vale do Araguaia em Formoso do Araguaia são em torno de 36 graus (FARENCENA, 2011).

Nas várzeas do Tocantins, a temperatura do solo oscila entre 24 e 30 graus, na profundidade de 5cm durante as 24 horas do dia e de 28 graus na profundidade de 10cm, sendo mais estável a uma temperatura de 26 graus na profundidade de 20cm. As correlações entre as temperaturas do ar e do solo são baixas, indicando uma pequena dependência em solo com umidade constante. (THUNG; SOARES et al., 2005).

Em condições de Várzeas Tropicais, em que o requerimento de água pela planta é suprido adequadamente pela irrigação por subirrigação, os efeitos negativos decorrentes de altas temperaturas podem ser minimizados (THUNG; SOARES et al., 2005). Esse fato justifica-se pela umidade alta está sempre presente no solo, o que resulta em temperatura mais baixa (FARENCENA, 2011).

Em 2015, grande parte das sementes utilizadas no plantio de soja foram produzidas nas várzeas do estado através do sistema de subirrigação onde apenas é permitido o plantio para pesquisa e produção de sementes monitorada e controlada mediante a Ferrugem Asiática. A produtividade média em 2015 nas várzeas do Tocantins ficou em torno de 2.774 kg/ha com uma produção de 159.649 toneladas em uma área plantada de 57.552 hectares. Em 2016, plantou-se na entressafra uma área de 54.006 ha. (ADAPEC, 2017).

3.7 Geotecnologias

O uso de modelos agrícolas representa esquemas quantitativos para estimar o crescimento, o desenvolvimento e o rendimento de uma cultura em função de variáveis ambientais e características genéticas. Como também ferramentas para a escolha da melhor data de plantio, das áreas com maior aptidão para a cultura, bem como identificar os fatores que podem limitar o desenvolvimento ideal das plantas cultivadas (MONTEITH, 1996).

Por meio de técnicas de geoprocessamento é possível o tratamento de volumes de dados juntamente às técnicas computacionais e, dessa forma, são disponibilizados atributos geotopológicos para fins de análises, sínteses e utilização no planejamento ambiental e na gestão territorial (SILVA, 2009).

As técnicas computacionais mencionadas estão relacionadas a modelos matemáticos e computacionais para o tratamento das informações geográficas que são denominadas como Sistema de Informações Geográficas (SIG) e Sensoriamento Remoto. Além disso, são bastante utilizados com o avanço da agroenergia, no monitoramento das mudanças de uso e cobertura da terra (RAMACHANDRA, 2009), assim como na contribuição às mudanças climáticas (DALE, 1997).

Os Sistemas de Informações Geográficas (SIG's), diferentes dos mapas convencionais permitem recuperar, armazenar e visualizar dados espacializados, facilitando o agrupamento, interpolação de informações e a análise de dados, de forma a integrar vários níveis de informação e gerar novos dados e informações (NOON; DALY, 1996).

Durante as últimas décadas, imagens orbitais têm sido utilizadas como auxílio no levantamento da área ocupada pelas culturas agrícolas e outras formas de uso do solo. A utilização de imagens de diversos sensores deve-se ao fato de possuírem caráter de

cobertura abrangente e serem obtidas em períodos diferentes conforme sua resolução temporal (EIPHANIO; LUIZ; FORMAGGIO, 2002).

Alguns autores realizaram avaliações entre resultados diferentes dos índices de vegetação dentre eles: Índice de Vegetação por Diferença Normalizada (NDVI) e o Índice de Vegetação Ajustados ao Solo (SAVI), ambos utilizados para o monitoramento fenológico e classificação da vegetação (RODRIGUES; RIBEIRO; VAZ, 2013).

3.8 Sensoriamento Remoto

Sensoriamento remoto é o registro da informação das regiões do espectro eletromagnético, sem contato físico direto, por meio de instrumentos dentre eles: câmeras, escâneres, lasers e dispositivos lineares e/ou matriciais localizados em plataformas tais como aeronaves ou satélites. Como também, a análise da informação adquirida por meio visual ou processamento digital de imagens. O registro da informação por esses instrumentos chamados de sensores que são classificados como orbitais (satélites) suborbitais (aeronaves) e registram a radiação eletromagnética (REM). No entanto, entre os sensores orbitais e suborbitais e os alvos podem ocorrer interferências que dificultam o uso das imagens, causadas principalmente pela atmosfera. (JENSEN, 2009).

O uso do sensoriamento remoto orbital e das técnicas de geoprocessamento representa um avanço significativo na obtenção de informações sobre dados da agricultura, por seu caráter multiespectral, sua repetitividade, seu custo e por ser uma metodologia menos sujeita a erros de análise humana (GONZALES-ALONSO; CUEVAS et al., 2015). A utilização crescente dessas imagens, ao longo de mais de duas décadas, tem permitido a obtenção de resultados positivos em prazos adequados às necessidades dos usuários, e com maior precisão e menor custo, quando comparada com técnicas convencionais (IPPOLITI-RAMILO; EIPHANIO et al., 1999).

O uso de recursos de sensoriamento remoto orbital e geoprocessamento significa um expressivo avanço no campo de levantamentos de dados sobre a agricultura, sobretudo por ser um sistema de caráter multiespectral que possibilita repetitividade, custo racional e por estar menos sujeito a erros de análise humana (EIPHANIO; LEONARDI; FORMAGGIO, 1994) (DALLEMAND; TARDIN; BATISTA, 1988).

O sensoriamento remoto da vegetação é um processo complexo devido as diferentes propriedades de reflexão foliar numa mesma planta, seus múltiplos componentes refletoras, a não-uniformidade da estrutura interna da planta, o substrato contínuo de solo e os restos vegetais sobre o qual assenta-se, e que, por sua vez,

apresentam propriedades de reflexão próprias. No processo de medição da energia proveniente desse sistema, as configurações angulares do iluminante e dos instrumentos de medição contribuem para a modulação das propriedades de reflexão da vegetação (EPIPHANIO; GLERIAN et al., 1996).

No sistema de levantamento de safras, a estimativa da área plantada envolve a identificação de diferentes culturas presentes em uma determinada região. A identificação de áreas ocupadas pelas culturas através da classificação de imagens de sensoriamento remoto parte do princípio de que as culturas, em função de suas características intrínsecas, possuem comportamento espectral distintos, os quais são manifestados em uma imagem digital. Além da possibilidade da identificação e quantificação da área ocupada, uma imagem classificada possibilita a localização espacial dos talhões, o que facilita uma aferição diretamente no campo, bem como, a estimativa/previsão em anos subsequentes (PAX-LENNEY; WOODCOCK, 1997).

Além dessas diferenças entre as culturas, para o monitoramento da atividade agrícola, é necessário um acompanhamento periódico, visto que, as culturas levam um determinado tempo para se desenvolverem. No caso de estimativas agrícolas, além do tempo do ciclo das culturas, é importante levar em conta que cada cultura tem uma época indicada ou apropriada para ser plantada e colhida. Imagens de sensores orbitais adquiridas em uma data, apenas, têm valia limitada para levantar dados de todas as culturas de uma região. Assim, para obter dados de estatísticas agrícolas ou realizar estudos sobre o comportamento espectral das culturas agrícolas, com o uso de dados de sensoriamento remoto, é recomendável uma análise multitemporal (SANCHES, 2004).

A folha é o componente das plantas que mais influencia as propriedades espectrais dos dosséis das culturas agrícolas. E por isso o conhecimento de suas propriedades ópticas é muito importante. De forma concisa, o comportamento espectral das folhas na região do visível é determinado pela concentração de clorofila e outros pigmentos no infravermelho próximo, sendo afetado pela estrutura do mesófilo e no infravermelho médio dominado pelas propriedades ópticas da água nos tecidos (BAUER; VANDERBILT et al., 1981).

3.8.1 Resolução Temporal

A resolução temporal pode ser genericamente definida pelo intervalo de tempo decorrido entre duas passagens consecutivas do satélite sobre um mesmo ponto da superfície terrestre, ou seja, o conceito de resolução temporal está intimamente

relacionado ao tempo necessário para a obtenção de duas imagens de um mesmo local. Entretanto, alguns sistemas sensores possuem a capacidade de adquirir imagens em visada lateral para imagear áreas localizadas à esquerda ou à direita em relação à órbita real do satélite. Isto permite aumentar a frequência de observações em uma determinada área de interesse, além de possibilitar a visão estereoscópica (SILVA, 2008).

Entretanto, o imageamento de uma área localizada fora da visada vertical do sensor compromete o imageamento de uma área localizada fora da visada vertical do sensor, comprometendo o imageamento sistemático de uma área localizada na órbita original. Em decorrência, tais sensores não fazem a cobertura sistemática do globo terrestre, pois adquirem imagens em locais pré-determinados por solicitações do usuário final. (RIZZI; RUDORFF, 2005) (IPPOLITI-RAMILO; EPIPHANIO; SHIMABUKURO, 2003).

3.8.2 Resolução espacial

A resolução espacial relaciona-se com à área da superfície terrestre imageada instantaneamente pelo sistema sensor Instantaneous Fieldof- View (IFOV), que após ser reamostrada é representada por um elemento na imagem digital denominado pixel. A radiância vinda dessa área é detectada pelo sensor em uma determinada banda espectral e posteriormente transformada em nível de cinza do pixel da imagem digital. Assim, quanto menor for a área da superfície terrestre individualizada pelo sistema sensor, maior será sua resolução espacial e, conseqüentemente, menor será o objeto possível de ser individualizado. No entanto, é possível distinguir objetos que são consideravelmente menores que a resolução espacial, em função do contraste destes em relação aos objetos adjacentes, embora muitas vezes, tais objetos só possam ser reconhecidos em função do contexto geral da imagem (SCHOWENGERDT, 1997).

3.8.3 Resolução radiométrica

A resolução radiométrica está relacionada à capacidade de um sistema sensor em discriminar pequenas variações na quantidade de radiância refletida ou emitida pelos alvos. Para representar essas variações no formato de uma imagem digital, os diferentes valores do sinal são quantizados em uma escala binária e representados através de uma escala monocromática, onde o sinal com intensidade zero é atribuído o preto e o sinal de máxima intensidade é atribuído o branco. A variável resolução radiométrica refere-se a menor variação de intensidade possível de ser detectada pelo sistema sensor. A resolução

radiométrica intrínseca de um sistema de sensoriamento remoto depende da relação sinal/ruído do detector. Em uma imagem digital, a resolução radiométrica é limitada pelo número discreto de níveis de quantização utilizado para digitalizar um valor de intensidade contínuo (CRISP, 2001).

A resolução radiométrica emprega-se a expressão 2^n , sendo “n” o nível de quantização da imagem, ou seja, o número de bits utilizado na geração da imagem digital. A maioria das imagens geradas a partir de sensores remotos utiliza uma quantização de 8 bits. Desta forma, a quantidade de níveis de cinza possível de ser representada na imagem é dada por 2^8 , ou seja, 256 níveis de cinza. (MATHER; KOCH, 2011).

3.8.4 Resolução espectral

A resolução espectral define-se como o número de bandas e a dimensão do intervalo de comprimentos de onda dessas bandas, usualmente denominada de largura da banda. A resolução espectral será tanto maior, quanto maior o número e mais estreitas forem as bandas posicionadas numa faixa espectral em que opera o sistema sensor. O posicionamento e a resolução espectral das bandas são características muito importantes, pois determinarão em conjunto com as resoluções espacial e radiométrica, a capacidade de um sensor em discriminar ou representar os alvos em uma área imageada (MATHER; KOCH, 2011).

Os diferentes alvos ou objetos da superfície apresentam comportamentos distintos e específicos em relação as interações com radiação eletromagnética e, portanto, tais comportamentos podem servir para distingui-los quando se utilizam de imagens obtidas por sensores remotos. Alvos, como água, solos e vegetação, podem, a princípio serem discriminados no espectro eletromagnético com certa facilidade, mesmo usado intervalos amplos de comprimento de ondas, denominados também como bandas espectrais ou canais espectrais (FORMAGGIO; SANCHES, 2017).

3.8.5 Landsat 08

Após o lançamento do satélite LANDSAT, em 1972, surgiu uma nova perspectiva com relação ao uso de sensores remotos na agricultura, dado o seu caráter espectral, temporal e, principalmente, o preço de aquisição das imagens (custo mais baixo em comparação com as fotografias aéreas).

O programa LANDSAT é composto de seis satélites que foram desenvolvidos pela National Aeronautics and Space Administration (NASA). A missão do Landsat-8 foi lançada pela NASA em 11 de fevereiro de 2013. A plataforma opera com dois instrumentos imageadores, Operational Land Imager (OLI) que consistem em nove bandas espectrais com uma resolução espacial de 30 metros para Bandas 1 a 7 e 9.

A resolução para a faixa 08 (pancromática) é de 15 metros e o Thermal Infrared Sensor (TIRS) com as bandas térmicas 10 e 11 que são úteis para obtenção de temperaturas de superfície mais precisas e com resolução espacial de 100 metros. O tamanho aproximado da cena é 170 km norte-sul por 183 km Leste-Oeste (USGS, 2016).

Os satélites da série LANDSAT são os mais empregados para fins agrícolas, e com o uso de dados provenientes desses equipamentos foi possível obter grandes avanços na identificação, avaliação e mapeamento dessas áreas. Apesar disto, vários fatores ainda limitam a utilização das imagens de satélites em aplicações como o monitoramento, a estimativa de área plantada e a previsão de safras. Dentre eles, destacam-se: a resolução espacial, a resolução temporal, a cobertura de nuvens em regiões tropicais, principalmente em épocas de chuva, o custo e o tempo de recebimento das imagens. No caso específico da resolução espacial, a sua melhoria reduz o efeito negativo provocado pela mistura de pixels que contêm vários temas distintos, aumentando a precisão dos processos de classificação automática das imagens e permitindo um controle contínuo e atualizado de grandes áreas agrícolas (RAMIREZ, 2002).

Os satélites utilizados para avaliação dos recursos naturais sofreram sensíveis mudanças tecnológicas ao longo do tempo, principalmente no que se refere às resoluções espacial e espectral dos sensores. Diversos trabalhos foram desenvolvidos com o objetivo de avaliar o potencial de dados obtidos por satélites, a fim de detectar, identificar e mapear áreas de culturas e, mais recentemente, estimar o rendimento agrícola das culturas (BATISTA; TARDIN et al, 1990).

3.8.6 Índices de Vegetação

Os índices de vegetação podem ser definidos como formulações matemáticas desenvolvidas a partir de dados espectrais obtidos por sensores remotos, principalmente nas bandas do vermelho e do infravermelho próximo, visando permitir avaliações e estimativas da cobertura vegetal de uma área, em termos de parâmetros como área foliar, fitomassa, porcentagem de cobertura do solo e atividade fotossintética. Essas transformações matemáticas têm sido largamente utilizadas em razão da obtenção fidedigna das variações da folhagem verde, não apenas em caráter sazonal, mas também ao longo da superfície terrestre, com o objetivo de detectar variabilidades espacializadas (FORMAGGIO; SANCHES, 2017).

Um índice de vegetação (IV) resulta da combinação dos valores de reflectância em dois ou mais intervalos de comprimento de onda, possuindo uma certa relação com a quantidade e o estado da vegetação em uma dada área da superfície terrestre. Em função disto, uma característica inerente aos IVs é a redução no volume dos dados a serem analisados, pois praticamente toda a informação referente a vegetação fica resumida a somente um valor numérico, ou seja, a informação registrada em algumas bandas (geralmente duas) passa a ser contida em apenas um índice de vegetação, permitindo modelar mais facilmente os dados espectrais em conjunto com as variáveis biofísicas da vegetação (RIZZI, 2005).

O potencial dos IV's para agricultura é extenso em razão de proporcionarem a possibilidade de avaliar a quantidade e as condições da vegetação em áreas extensas de forma rápida e com fundamentação física. Esses índices são uteis, também, para a estimativa de variáveis biofísicas como cobertura verde sobre o solo, o índice de área foliar (IAF), o conteúdo de água e de componentes bioquímicos, a produtividade, e a fração da radiação fotossinteticamente ativa. Além dessas possibilidades, os IV's se correlacionam entre a radiação solar e os tecidos fotossinteticamente ativos das plantas, tornando-se, então, indicativos das propriedades biofísicas dinâmicas relacionadas com a produtividade e o balanço de energia da vegetação (FORMAGGIO; SANCHES, 2017).

Os dados das imagens orbitais oriundo da fitomassa verde refletida são usualmente armazenados em valores de números digitais (ND). O Landsat 08, por exemplo, armazena em valores de 08 bits e, portanto, podem variar entre 0 e 255 níveis de cinza. A energia que chega ao sensor em órbita é quantificada radiometricamente por meio de uma transformação matemática. Posteriormente, os valores ND's podem ser

transformados em valores de radiância de maneira adequada em software de sensoriamento remoto. Essa energia é denominada radiância no topo da atmosfera. Com esses valores de radiância, é necessário remover a influência atmosférica, já que, no momento da coleta dos dados existe a camada da atmosfera entre o sensor orbital e a superfície terrestre (FORMAGGIO; SANCHES, 2017).

Após as correções atmosféricas tem-se a reflectância ao nível da superfície podendo variar de 0 a 1, sendo este o melhor tipo de dado para cálculo dos índices de vegetação (TEILLET; STAENZ; WILIAMS, 1997).

Ao observar o ciclo de crescimento de uma cultura, é possível verificar a sucessão de fases a partir do plantio, seguindo para o desenvolvimento vegetativo, com o aumento gradual do IAF, a maturação dos grãos, e por fim, a colheita sendo o momento em que as folhas secam em razão da transferência de energia para o enchimento dos grãos. Por isso, os índices de vegetação devem ter a capacidade de captar as mudanças de fitomassa ao longo do ciclo, simultaneamente a capacidade de serem minimamente sensíveis aos ruídos causados pelos solos subjacentes (FORMAGGIO; SANCHES, 2017).

3.8.6.1 Índice de Área Foliar (IAF)

Em se tratando de agricultura, as pesquisas com IVs se concentram na estimativa das propriedades biofísicas da vegetação. Grande parte dos modelos de produtividade agrícola parte do princípio de que a produtividade final de uma cultura é extremamente dependente das condições climáticas (precipitação pluvial, temperatura, umidade, insolação etc.) e de cultivo (manejo e fertilidade do solo, sanidade etc.). E que algumas variáveis biofísicas são determináveis através de IVs, como o IAF, refletindo as condições de crescimento impostas pelo clima e pelo manejo (RIZZI, 2005).

O IAF pode ser estimado em campo com métodos diretos ou indiretos como também utilizando imagens orbitais de maneira indireta. No entanto, as medidas representam valores pontuais e a sua espacialização é onerosa e necessita de métodos matemáticos de interpolação. O sensoriamento remoto é uma ferramenta que permite estimar o IAF utilizando radiância espectral registrada pelos sensores orbitais, sem a necessidade de métodos de interpolação. A radiância espectral é influenciada pela disponibilidade de pigmentos fotossintetizantes na região do visível, pela quantidade de água na região do infravermelho médio e pelo espalhamento múltiplo entre as folhas na região do infravermelho próximo. Desta forma, de maneira geral, quanto maior o IAF,

menor os valores de radiância na região do visível e no infravermelho médio e maior na região do infravermelho próximo (BENEDITTI; QUERINO et al., 2015).

O IAF é um indicador da área da foliar em cada pixel da imagem (Eq. 03), definido pela razão entre a área foliar de toda a vegetação por unidade de área utilizado por essa vegetação (JENSEN 2009).

$$IAF = \frac{\ln \left(0,69 - \frac{SAVI}{0,69} \right)}{0,91} \quad Eq (01)$$

3.8.6.2 Índice de Vegetação por Diferença Normalizada (NDVI)

O índice de vegetação (IV) ideal deve ser capaz de responder a pequenas variações no estado fenológico da vegetação e não pode ser muito influenciado por variações das condições e tipos de solo, da geometria da cena e das condições atmosféricas. O índice de vegetação mais utilizado em pesquisas relacionadas à dinâmica da cobertura vegetal é o Normalized Difference Vegetation Index (NDVI) (JACKSON; HUETE, 1991).

Embora numericamente os valores do NDVI variarem entre -1 e 1, a vegetação está associada aos valores positivos. Materiais que refletem mais intensamente na porção do vermelho em comparação com o infravermelho próximo (nuvens, água e neve) apresentam NDVI negativo, pois solos descobertos e rochas refletem o vermelho e o infravermelho próximo quase na mesma intensidade, por conseguinte, seu NDVI aproxima-se de zero (LILLESAND; KIEFER; CHIPMAN, 2015).

Os valores de reflectância da radiação na banda do Infravermelho Próximo feita pelas folhagens são altos e a absorção existe, mas é muito pequena. Ao nível de dossel, esses altos valores de reflectância estão relacionados com o Índice de Área Foliar e ao nível de folhas tomadas individualmente estão relacionados com a estrutura constituinte das folhagens (GITELSON; KAUFMAN et al, 2002).

Segundo (LIU, 2006), os valores de NDVI quanto a folhagens de coloração verde, possuem faixa de variação entre 0 e 0,84, sendo 0 solo exposto. Essas características também existirão em dosséis de culturas que estejam em estado de maturidade ou de senescência ou que estejam sob déficit hídrico ou de nutrientes (GITELSON; KAUFMAN et al, 2002).

O NDVI é utilizado em averiguações do estado das vegetações quanto à nutrição, crescimento, produtividade, estresses ou deficiências, presença de ervas daninhas e quanto a danos causados por agentes químicos (ORTIZ; THOMSOM et al., 2011).

Índice de Vegetação por Diferença Normalizada (NDVI) utiliza a diferença da reflectância entre a faixa do infravermelho próximo e a reflectância da faixa do visível (ROUSE, et al 1973). Dada a fórmula:

$$NDVI = \frac{nir - red}{nir + red} \quad Eq (02)$$

Onde:

nir = Reflectância no Infravermelho Próximo;

red = Reflectância no vermelho.

3.8.6.3 Índice de Vegetação Ajustado ao Solo (SAVI)

Os índices de vegetação são influenciados pelo solo até que o mesmo esteja completamente coberto pela vegetação. Nos estádios iniciais de desenvolvimento e em culturas que não cobrem uniformemente a superfície, essa influência deve ser considerada (HUETE; JACKSON; POST, 1985). Por esse motivo, adicionou uma constante denominada “L” à equação que produz o NDVI, criando assim o Soil Adjusted Vegetation Index (SAVI) Essa constante é um fator de correção que varia gradualmente de 0, para dosséis com alta cobertura vegetal, a 1, para baixa cobertura de vegetação. O valor de 0,5 para essa constante reduz consideravelmente a interferência do solo em dosséis vegetais com diferentes densidades, sendo passível de ser utilizado em pesquisas onde o índice de área foliar do dossel é desconhecido (HUETE, 1988).

O fator “L” da fórmula pode assumir valores de 0,25 (vegetação densa), 0,5 (densidade intermediária) a 1,0 (baixa intensidade), a depender da quantidade de cobertura do solo, sendo 0,5 o valor mais utilizado. Ainda sobre o fator “L” vale ressaltar que foi encontrado por tentativa e erro, até ser identificado um fator satisfatório com iguais IV’s tanto para solos claros quanto para solos escuros (FORMAGGIO; SANCHES, 2017).

O Índice de Vegetação Ajustado ao Solo (SAVI) desenvolvido por Huete (1988) que minimiza os efeitos da interferência da presença do solo na caracterização do dossel das plantas.

Dada a fórmula:

$$SAVI = \frac{(1 + L)(nir - red)}{nir + red + L} \quad Eq (03)$$

Onde:

nir = Reflectância no Infravermelho Próximo;

red = Reflectância no vermelho;

L = O fator de ajuste para o substrato do dossel.

Neste caso 0,5 para vegetação com densidade média. Outros valores são configurados para vegetação muito densa 0,25 e densidade mínima igual 1,0.

3.8.7 Estimativa da Temperatura

De acordo com (JENSEN, 2009), as informações sobre a temperatura superficial podem ser obtidas por sensoriamento remoto, tendo em vista que o calor interno de um alvo é convertido em energia radiante. E para a maioria dos alvos existe uma alta correlação positiva entre a temperatura cinética verdadeira do alvo e o fluxo radiante proveniente dos mesmos.

Uma das vantagens do sensoriamento remoto termal é de proporcionar em tempo sincronizado uma densa rede de dados de temperatura de áreas sobre a superfície terrestre, além de permitir o monitoramento e o estudo multitemporal das mesmas, (PIRES; FERREIRA, 2015). Sob essa ótica os autores Chander; Markham; Helder, (2009) afirmam que para obter informações remotamente aplicam-se fórmulas de coeficientes de calibração radiométrica e obtenção de temperaturas Kelvin para imagens de satélite Earth Observer-1(EO-1) e da série Landsat 1 a 7. Com relação ao uso de modelagem os autores Ideião; Cunha et al., (2008) fizeram uma estimativa e análise da temperatura da superfície por intermédio de imagens THEMATIC MAPPER abordo do LANDSAT 05 para o Estado da Paraíba aplicando o algoritmo baseado no METRIC (Mapping Evapotranspiration at high Resolution and Internalized Calibrato) e o SEBAL (Surface Energy Balance Algorithm for Land) para obter temperatura da superfície como resultado mapas de temperatura.

Leite; Oliveira; Borges, (2015) analisaram o comportamento de temperatura de superfície na malha urbana de Araxá – MG utilizando a banda termal do LANDSAT 08 com resultados satisfatórios. Outro estudo realizado foi dos autores (JESUS; COELHO,

2013) que realizaram o mapeamento do campo térmico do município de Cariacica – ES, interpolando com os dados referentes às áreas com cobertura vegetal coletados em campo.

Em estudo de (MACHADO; GALVÍNCIO; PEREIRA, 2010) detectou-se mudanças ambientais com a utilização do Índice de Vegetação Ajustado ao Solo (IVAS) em conjunto com a temperatura da superfície processadas de imagens LANDSAT 05, sensor TM.

A obtenção da temperatura é calculada com a utilização das bandas 10 e 11 das imagens do Landsat 08 referentes a área de estudo. Os cálculos fizeram-se necessários para correção das imagens e extração da Land Surface Emissivity (LSE), traduzido para o português: Emissividade da Superfície da Terrestre.

Inicialmente converteu-se os números digitais (ND) representados pelos pixels das imagens para Radiância Espectral no Topo da Atmosfera ($L\lambda$) das bandas 10 e 11

Dado a fórmula:

$$L\lambda = M_L Q_{cal} + A_L \quad Eq (04)$$

Onde:

$L\lambda$ = Radiância espectral no topo da atmosfera ($W/m^2srad \mu m$);

M_L = Fator multiplicativo reescalonado da Radiância para a banda específica;

Q_{cal} = Número digital do pixel;

A_L = Fator aditivo reescalonado da Radiância para a banda específica.

Após esse procedimento, a temperatura estimou-se pela conversão do brilho de temperatura com os valores em Kelvin, subtraídos pelo seu valor absoluto (272,15), para obtenção do valor em graus celsius gerando o raster de Temperatura da Superfície da Terra (LSE) em graus Celsius ($^{\circ}C$) das Bandas 10 e 11.

Dado a fórmula:

$$T(Kelvin) = \frac{K_2}{\ln\left(\frac{K_1}{L\lambda} + 1\right)} \quad Eq (05)$$

Onde:

T = Temperatura efetiva do satélite em Kelvin (K);

K_2 = Constante de calibração 2 = 1.321.08 (Banda 10);

K_1 = Constante de calibração 1 = 774.89 (Banda 10);

K_2 = Constante de calibração 2 = 1.201.14 (Banda 11);

K_1 = Constante de calibração 1 = 480.89 (Banda 11);

L_λ = Radiância espectral em Watts/ (m²srad μm)

Assim como:

$$LSE = T(kelvin) - 272,15 \quad Eq (06)$$

Os resultados alcançados da temperatura nas Bandas 10 e 11 foram submetidos à conversão de Radiância no topo da atmosfera (L_λ) para reflectância planetária sem correção para as bandas 10 e 11 dos instrumentos imageadores Thermal Infrared Sensor (TIRS).

Dado a fórmula:

$$\rho_\lambda = M_\rho Q_{cal} + A_\rho \quad Eq (07)$$

Em que,

ρ_λ = Reflectância planetária no topo da atmosfera sem correção do ângulo solar;

M_ρ = Fator multiplicativo reescalado da reflectância para a banda específica;

Q_{cal} = Número digital do pixel;

A_ρ = Fator aditivo reescalado da reflectância para a banda específica;

Todos os passos descritos na metodologia realizaram-se por meio de ferramenta de geoprocessamento, software Arc Gis 10.6.

3.8.8 Modelos de Estimativas

Estimativas da produção agrícola são de grande importância para a economia do país, uma vez que fornecem suporte aos formuladores de políticas agrícolas e aos tomadores de decisão do setor privado ligados a atividades agropecuárias. Informações precisas e em tempo hábil e custo baixo sobre commodities agrícolas, como o caso do café, sobre a extensão e o rendimento da cultura são instrumentos valiosos para o planejamento e comercialização das safras. (VICENTE; OLIVETTE et al., 1990)

3.8.8.1 Estimativa área plantada

A estimativa de área plantada com culturas diferentes presentes em uma determinada área ou região são extremamente importantes para um sistema de levantamento de safra (PAX-LENNEY; WOODCOCK, 1997). A classificação de imagens de sensoriamento remoto para identificação de áreas ocupadas pelas culturas, parte do princípio que as culturas, em função de suas características intrínsecas, possuem comportamento espectral distintos, os quais são revelados em uma imagem digital. Além da possibilidade da identificação e quantificação da área ocupada, uma imagem classificada possibilita a localização espacial dos talhões, o que facilita uma aferição diretamente no campo, bem como a estimativa/previsão em anos subsequentes (RIZZI, 2005).

Medeiros; Rudolf; Shimabukuro, (1996) usufruíram de uma imagem Landsat TM na estimativa da área plantada com as culturas da cana-de-açúcar, milho e soja, em nível municipal, na região norte de São Paulo. Os resultados apontaram grandes divergências entre a estimativa de área plantada, obtida através da classificação digital da imagem e a estimativa pelo Levantamento Sistemático da Produção Agrícolas (LSPA). Apesar de não apontarem a origem dessas divergências, os autores destacam que as imagens de satélite podem fornecer informações objetivas e confiáveis de estimativa de área plantada.

Ippoliti-Ramilo; Epiphanyo; Shimabukuro, (2003) utilizaram imagens multitemporais de junho, setembro e outubro, meses com maior possibilidade de obtenção de imagens livres de nuvens, em uma área caracterizada por culturas de ciclo curto e cana-de-açúcar. Em virtude dessas imagens coincidirem com o período que antecede o plantio, as culturas foram classificadas em função do uso provável dos talhões no verão.

3.8.8.2 Estimativa produtividade

Os modelos de estimativa de produtividade que relacionam as plantas e o seu ambiente são divididos em três categorias: modelos estatísticos empíricos, modelos de simulação de crescimento e modelos de análise da cultura e seu meio (BAIER, 1979).

Os modelos estatísticos empíricos utilizam séries históricas de dados climáticos e de produtividade, relativos a uma mesma região. Através de técnicas estatísticas de regressão linear, esses modelos produzem equações que podem ser usadas para a estimativa da produtividade. Sua grande desvantagem é que, muito frequentemente, estes modelos são localizados, pois as variáveis agrometeorológicas, definidoras da

produtividade são espacialmente homogêneas, somente, em áreas limitadas com o mesmo tipo de solo, relevo, clima, práticas de cultivo etc (BRAGA, 1995).

Os modelos de simulação de crescimento são uma representação simplificada dos mecanismos físicos, químicos e fisiológicos que interferem no crescimento e desenvolvimento das plantas. Esses modelos partem do princípio que uma vez conhecidos esses mecanismos, o impacto das variáveis meteorológicas em processos específicos (fotossíntese, respiração e transpiração) pode ser simulado por equações matemáticas. Entretanto, do ponto de vista da aplicação prática, tais modelos apresentam severas restrições pela falta de informações detalhadas, tanto de fisiologia das plantas, quanto do ambiente (BERLATO, 1987).

Os modelos de análise da cultura e seu meio, ou modelos agrometeorológicos, visam representar, também de forma simplificada, as relações existentes entre a resposta da planta e as variáveis ambientais durante todo o ciclo da cultura. Esses modelos requerem um detalhado conhecimento sobre o que ocorre na interação entre a planta, o solo e o meio atmosférico, tais como: fluxo de água no solo e na planta, evapotranspiração, radiação solar etc. Essa interação é então transferida para sistemas de equações que permitem analisar as contribuições das variáveis agrometeorológicas na expressão da produtividade final da cultura (BERLATO, 1987).

Alguns métodos têm sido propostos para incorporar uma variável espectral na estimativa da produtividade. Esses métodos relacionam os índices de vegetação à produtividade das culturas através de equações de regressão, sendo denominados modelos espectrais. Esses modelos também podem ser associados a modelos agrometeorológicos (RIZZI, 2005).

Uma etapa crucial no desenvolvimento de modelos de produtividade em escala municipal ou estadual é a sua parametrização em relação aos dados oficiais históricos. Em outras palavras, o cálculo da produtividade é realizado para alguns anos-safra, onde pequenas alterações são realizadas em alguns parâmetros agronômicos do modelo na tentativa de aproximar ao máximo os dados calculados aos dados oficiais. Após a parametrização, o modelo é utilizado no cálculo da produtividade dos demais anos. Contudo, os dados oficiais de produtividade (kg ha^{-1}) são estimados em função da produção (kg) observada no final da safra e da área plantada (ha), subjetivamente estimada por ocasião da semeadura da cultura. (RIZZI, 2005).

3.8.9 Lógica *fuzzy*

O reconhecimento de padrões é a técnica que tem por objetivo procurar, detectar e explicitar estruturas associadas às regularidades ou propriedades presentes em um conjunto de dados, por meio da análise de classes (BEZDEK; PAL, 1992). A classificação automática de imagens multiespectrais de sensoriamento remoto significa associar cada pixel da imagem a um rótulo, descrevendo um objeto real da superfície. Os valores de ND associados a cada pixel, definidos pela reflectância dos materiais que compõem esse pixel, são identificados em termos de um tipo de cobertura da superfície terrestre, determinando as classes (ANTUNES, 2005).

Existem duas abordagens na classificação de imagens. A primeira denomina-se classificação supervisionada onde o usuário identifica alguns dos pixels pertencentes às classes desejadas e o método localiza todos os demais pixels pertencentes àquelas classes, baseado em alguma regra estatística pré-estabelecida. A segunda chama-se classificação não supervisionada, onde o próprio método decide, por análise de agrupamento, quais as classes a serem separadas e quais os pixels pertencentes a cada uma (RICHARD; JIA, 1999).

Os classificadores dicotômicos permitem construir um mapa com pixels sim-não e que envolvem operações lógicas (E, OU, NÃO), isto é, cada pixel contém a informação relativa à existência de determinado atributo ou de sua não existência. A informação está representada no método um-pixel-uma-classe que pode não descrever adequadamente a mistura de objetos de distintas classes. Dessa forma, essa limitação pode reduzir o nível de precisão da classificação devido à pobre extração de informações da imagem (WANG, 1990).

Desenvolvida por Zadeh, (1965), a lógica *fuzzy* é uma extensão da teoria de conjuntos clássicos e está associada aos conceitos básicos de funções de pertinência. A sua utilização é apropriada em sistemas que se caracterizam pela generalidade, ambiguidade e imprecisão para a extração de informações vagas

A lógica *fuzzy* pode ser definida como a parte da lógica matemática dedicada aos princípios formais do raciocínio incerto ou aproximado, portanto mais próxima do pensamento humano e da linguagem natural. Devido a esta propriedade e à capacidade de realizar inferências, a lógica *fuzzy* tem encontrado grandes aplicações em várias áreas como modelagem de sistemas e reconhecimento de padrões (BEZDEK; PAL, 1992).

A integração de Sistemas de Informação Geográfica (SIG) com lógica *fuzzy* no mapeamento do uso do solo, segundo (ZHENG; KAINZ; GROTEN, 2000) Concluíram que as regras da lógica *fuzzy* têm, indubitavelmente, um grande potencial a ser considerado como um modelo inteligente para operações espaciais num SIG, mostrando que não somente o objetivo de classificação foi alcançado, mas também os dados puderam perfeitamente simular a variação de classes e inferir o resultado da classificação.

A estimativa de área baseada em classificação *fuzzy* utilizou o NDVI e o NDMI gerados a partir das imagens diárias e gratuitas AVHRR-NOAA, mostrando viabilidade, uma vez que é realizada de forma objetiva, possuindo menor custo o que pode ser realizada com antecedência em relação às estimativas de área oficiais. Portanto, essa metodologia pode ser empregada com o objetivo de auxiliar os métodos convencionais. No caso da cultura de soja no oeste do Paraná foi possível estimar as áreas cultiváveis nos oito municípios até o final de janeiro de 2004, período de maior vigor vegetativo da soja na região em estudo, com antecedência em relação à época da colheita (ANTUNES, 2005).

3.9 Geoestatística

3.9.1 Histórico

Krige, (1951) fez uso inicial da geoestatística, na distribuição de amostras de ouro em minas exploradas no passado, constituindo-se uma abordagem para previsão de existência do minério em locais ainda não explorados. Dessa forma, sabia que era necessário ter em consideração a distância entre as amostras. E nesse sentido, provou apresentando melhores resultados que os métodos usados anteriormente.

Matheron, (1963) formalizou a teoria de Krige e introduziu a teoria das variáveis regionalizadas e o variograma (ou semivariograma), reforçando que a modelação espacial de minas não podia assentar numa variável aleatória no sentido da estatística tradicional. O autor traz que as variáveis regionalizadas se definem como funções espaciais numéricas, variando de localização e apresentando continuidade.

As variáveis regionalizadas apresentam um caráter aleatório, traduzido pela irregularidade e variação imprevisível de ponto para ponto. Assim como, apresentam também um caráter estruturado, representando as relações existentes entre os valores nos diferentes pontos no espaço. É importante salientar que, em pontos mais próximos os

valores das variáveis se relacionam mais do que em pontos mais afastados (CRESSIE, 1990).

A autocorrelação é uma função de distância, sendo uma característica da geoestatística. Na estatística clássica, as amostras são consideradas independentes, ou seja, não há relação entre elas. Na geoestatística, a informação da localização espacial permite calcular as distâncias entre as observações e modelar a autocorrelação em função da distância (GONÇALVES, 2015)

3.9.2 Modelos geoestatísticos

Modelos geoestatísticos são aplicados para analisar e prever processos espaciais e também para caracterizar a sua variação de fenômenos relacionados a vegetação (WOODCOCK; STRAHLER; JUPP, 1988) e também as propriedades dos solos segundo (ROGOWSKI, 1993). Mediante a visualização de dados de recursos naturais obtidos em pontos georrerenciados, a geoestatística é utilizada para interpolação ou extrapolação espacial (GRIFFITH, 1993).

Os modelos Kriging fornecem soluções para o problema das estimativas baseadas em modelos aleatórios contínuos de variação espacial, fazendo o melhor uso da informação existente. Isso ocorre por levar em conta a forma como uma propriedade varia no espaço através do modelo de semivariograma. Cálculos kriging são elaborados para enfrentar problemas cada vez mais complexos em diversos seguimentos como: em minas, engenharia do petróleo, controle e diminuição de poluição e na saúde pública e meio ambiente (GONÇALVES, 2015).

O termo kriging atualmente abrange diversos tipos de kriging distintos entre eles como os lineares que podem produzir previsões livres de “ruído” sob a forma de um valor “novo” em cada local de medição. Nesses métodos é possível especificar a proporção do nugget que é a variação em micro-escala do erro de previsão, como também não-lineares que são métodos de interpolação exatos e não levam em conta a incerteza da previsão nos locais de previsão, ou seja, o nugget (KRIVORUCHKO, 2001). Nesta dissertação foram utilizados Krigings lineares.

Os métodos geoestatísticos são conciliados com êxito para investigar a variabilidade espacial de variáveis ambientais e para incorporar esta informação na cartografia. Quanto a outras metodologias, a geoestatística oferece a facilidade para a quantificação da variabilidade espacial e para interpolação espacial. A geoestatística é

amplamente aplicada para analisar a heterogeneidade espacial da distribuição das florestas e dos solos (DAI; ZHAO et al., 2018).

A variabilidade espacial é necessária a verificação quanto a distribuição dos dados. O histograma é a forma mais comum de mostrar graficamente essa distribuição em um gráfico de barras onde as respectivas alturas representam a frequência de cada classe após o agrupamento realizado (FERREIRA; PANAGOPOULOS et al., 2015).

3.9.3 Kriging

O kriging é considerado como um modelo, onde é estimada uma matriz de covariância espacial que determina os pesos atribuídos às diferentes amostras, no que diz respeito o tratamento da redundância dos dados, a vizinhança a ser considerada no procedimento inferencial e o erro associado ao valor estimado. Os métodos de kriging dependem de modelos matemáticos e estatísticos. A adição de um modelo estatístico que inclui probabilidades separa os métodos de kriging dos métodos determinísticos. Nestes métodos, associa-se alguma probabilidade às previsões porque os valores não são perfeitamente previsíveis com modelos estatísticos (GONÇALVES, 2015).

Com os modelos kriging tenta-se não só prever os valores não medidos como também se tem acesso ao erro da previsão. Os métodos de kriging recaem na noção de autocorrelação. A correlação é normalmente pensada na tendência de dois tipos de variáveis se relacionarem. (TOBLER, 1970) aponta que o princípio básico da geografia são que fenômenos próximos possuem maior tendência para se relacionarem que fenômenos distantes. Portanto, a taxa de correlação entre variáveis pode ser expressa em função da distância.

A possibilidade de haver mais do que um tipo de variáveis, em que cada variável pode ter uma tendência diferente. Os modelos baseados em mais do que uma variável são a base do cokriging. Pode-se formar uma variável indicadora, e se a prevermos usando o valor original não transformado num modelo de cokriging, obtemos um kriging probabilístico (GONÇALVES, 2015).

3.9.4 Tipos de kriging

Ordinary Kriging (OK) é o método mais utilizado com mais frequência, é considerado a versão padrão de kriging denominada de Kriging Normal. As previsões são baseadas no modelo.

$$Z(s) = \mu + \varepsilon'(s)$$

Onde μ é a função constante estacionária (média global) e $\varepsilon'(s)$ é a parte da correlação espacial aleatória da variação.

O objetivo do kriging é estimar o valor de uma variável aleatória, Z , em um ou mais pontos sem amostra ou em largos blocos, a partir de mais ou menos dados de exemplo. O estimador é formado como um somatório ponderado dos dados,

$$\hat{Z}(s_0) = \sum_{i=1}^N \lambda_i Z(s_i)$$

Onde $Z(s_i)$ é o valor medido na localização S_i ; λ_i é um peso desconhecido para valor medido na localização S_i ; S_0 é a localização de predição.

No Ordinary Kriging o peso, λ_i , depende do semivariograma, a distância para a localização de predição, e as relações espaciais entre os valores medidos ao redor da localização de predição. Ao fazer estimativas para várias localizações, podemos esperar encontrar alguns valores acima e outros abaixo. Em média, a diferença entre as previsões e os valores medidos deveria ser zero. Isto é referido de modo a que a previsão seja imparcial.

Para certificar que o estimador é imparcial para os valores desconhecidos, o somatório dos pesos, λ_i , deve ser igual a um. Usando esta restrição, certifica-se que a diferença entre o valor real, $Z(s_0)$, e o estimador, $\sum \lambda_i Z(S_i)$, é tão pequena quanto possível. Ou seja, minimizar a expectativa estatística da fórmula de onde as equações do kriging foram obtidas:


$$\left(Z(s_0) - \sum_{i=1}^N \lambda_i Z(s_i) \right)$$

Ao minimizar a expectativa, em média, o estimador de kriging é o mais próximo possível do valor desconhecido. Conceptualmente o Ordinary Kriging é uma predição ou interpolação espacial que usa os modelos do semivariograma ou da covariância que assumem as relações espaciais entre os dados. Fazendo algumas suposições sobre o modelo, como a estacionariedade intrínseca e que a média real dos dados é constante, mas desconhecida (GONÇALVES, 2015). Nesta dissertação foi utilizado o Ordinary Kriging (Krigagem ordinária).

3.9.5 Semivariogramas

(MATHERON, 1963) introduziu para a análise de dados espaciais o traçado e derivação das chamadas semivariâncias – as diferenças entre os valores vizinhos. No semivariograma todos os pares de pontos possíveis são observados. Quando a distância do par é zero, a semivariância também é zero. Se a distância (h) entre pontos é pequena, os pares de pontos têm uma grande relação entre si e o valor da semivariância é reduzido.

Figura 10 – Anatomia de um semivariograma



Fonte: Johnston, et al, 2001

Sill é o valor de semivariância que nivela o semivariograma, é a altura máxima que este atinge. Pode também ser designado como a amplitude de uma determinada componente do semivariograma. O sill é composto por duas partes: uma descontinuidade no início, chamado de nugget (ou efeito pepita) e o partial sill. O nugget pode ser dividido em erro de medição e microescala de variação, mas como qualquer um dos componentes pode ser zero, o nugget pode ser composto inteiramente de uma ou de outra. Range é a distância de lag na qual o Semivariograma (ou a componente do semivariograma) atinge o valor de sill. Sendo presumível que a autocorrelação seja nula depois de alcançado o valor de range (ISAAKS; SRIVASTAVA, 1989)

Teoricamente o valor de nugget no início do semivariograma deveria ser zero. Se este for significativamente diferente de zero, para lags muito próximos de zero, então o valor do Semivariograma é referido como nugget. O nugget revela a descontinuidade do semivariograma para distâncias menores do que a menor distância entre as amostras. Parte desta descontinuidade pode dever-se a erros de medição, mas é impossível quantificar se a maior contribuição provém dos erros de medição ou da variabilidade de pequena escala não captada pela amostragem (ISAAKS; SRIVASTAVA, 1989).

Há diversos tipos de modelos de semivariograma como o esférico, exponencial, circular, entre outros, sendo para este estudo considerado o método Gaussiano.

3.9.5.1 Modelo gaussiano

O modelo gaussiano, com o seu comportamento parabólico na origem, representa eficazmente propriedades muito variadas. Os modelos exponencial e esférico apresentam um comportamento linear na origem apropriado para a representação de propriedades de curto range com um nível mais elevado de variabilidade (BOHLING, 2005). A seleção do modelo influencia as previsões dos valores não medidos, particularmente quando a forma da curva perto da origem difere significativamente. Quanto mais íngreme for a curva no seu início, maior é a influência dos vizinhos mais próximos na previsão. Cada modelo é desenhado para melhor se adequar aos diferentes tipos de fenómenos em estudo (GONÇALVES, 2015).

$$\gamma(h; \theta) = \theta_s \left[1 - \exp \left(-3 \left(\frac{\|h\|}{\theta_r} \right)^2 \right) \right] \text{ para todo o } h$$

Onde $\theta_s \geq 0$ é o parâmetro parcial *sill* e $\theta_r \geq 0$ é o parâmetro *range*.

Vários métodos são utilizados para verificar a qualidade do ajuste do semivariograma aos dados experimentais bem como da interpolação resultante deles. (VIEIRA; HATFIELD et al, 1983) sugerem o método de ajuste por tentativa e erro (ajuste a critério do observador) associado à avaliação do modelo pela técnica de validação cruzada ou autovalidação (“jack-Knifing”).

Ao grau de confiança dos modelos ajustados pode ser medida pelo erro médio absoluto, calculado por meio da média das diferenças entre o valor estimado e o valor real dos dados, e quanto mais próximo de zero seu resultado, melhor análise (CARVALHO, SILVEIRA; VIEIRA, 2002). O coeficiente de determinação (R^2) mensura a variação dos dados de acordo com o modelo ajustado em relação à variação total. Constata-se que em quanto mais próximo de 01 (um) estiver o valor, melhor será o ajuste do modelo (BIASE; SANTANA, 2012). É importante ressaltar que há também o coeficiente de correlação de Pearson (r), que mede a intensidade da associação linear existente entre as variáveis, através da divisão entre os valores reais sobre os prediletos (ou estimados), com seu índice variando de -1 (menos um) a 1(um).

A validação cruzada dos dados permite escolher o modelo que apresenta as melhores estimativas através da análise de gráficos e valores medidos confrontados com valores previstos, assim como valores estatísticos resumidos dos erros de previsão da krigagem, sendo a base da escolha da krigagem com os seguintes critérios:

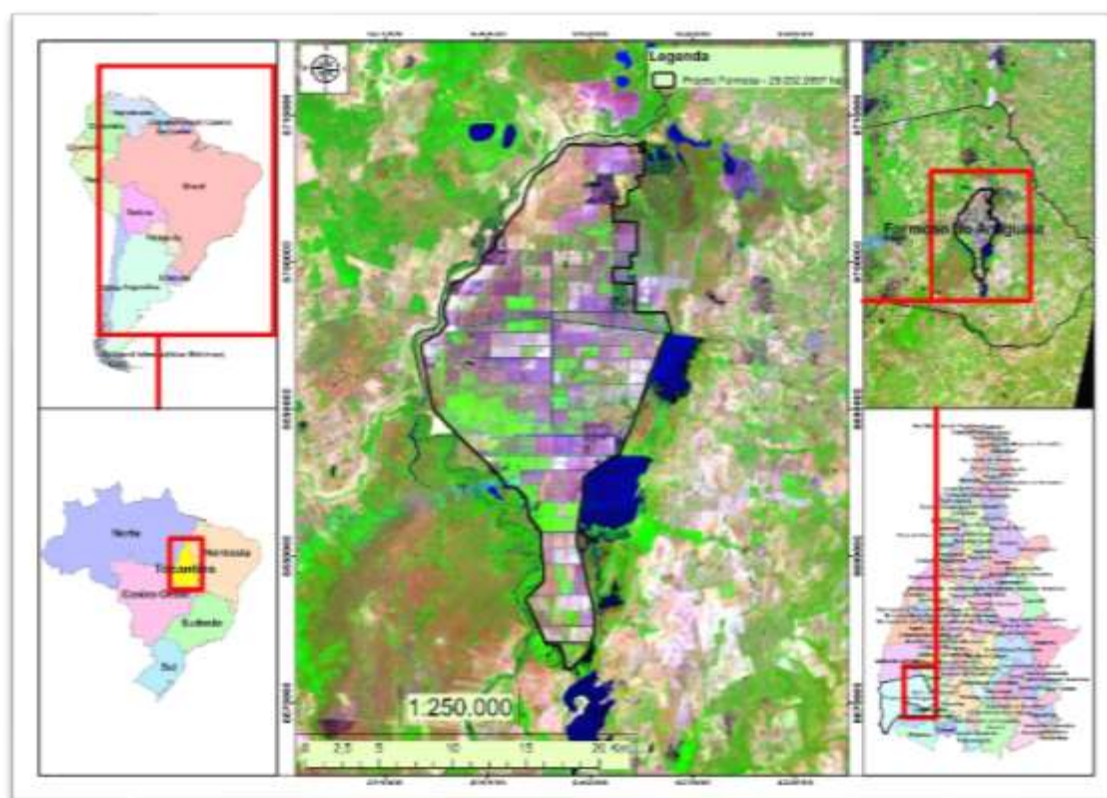
- O valor de *mean prediction error* (MPE) deveria estar perto de zero, de modo a que os erros de previsão sejam imparciais;
- Quanto menor o *Root-mean-square prediction* (RMSP) *error* melhor, para que as previsões tenham valores mais próximos possível dos valores medidos;
- O valor de *average standard error* (ASE) deve estar próximo do valor de *root-mean-square prediction errors* para que a avaliação da variabilidade da previsão seja correta;
- O valor *Root-mean-square standardized error* (RMSSE) deve ser próximo de 01(um) (JONHSTON; HOEF et al., 2001).

4. MATERIAL E MÉTODOS

4.1 Área de estudo

Formoso do Araguaia é o maior município em extensão territorial do Estado do Tocantins com 13.423,378 Km². É localizado na região sudoeste do estado e encontra-se a aproximadamente 260 km da capital Palmas. Esse município possui o maior projeto de arroz irrigado em área contínua do mundo, totalizando 27.787 ha de várzea, constituída de solos hidromórficos e/ou aluviais, bem como todas as condições climáticas para a obtenção de excelentes produtividades (IBGE, 2018). Segue mapa de localização do município de Formoso do Araguaia na figura 03.

Figura 04 – Mapa de Localização Formoso do Araguaia/Projeto Formoso do Araguaia



O Projeto Rio Formoso localiza-se no município de Formoso do Araguaia – TO, entre os paralelos 11 graus 30' e 12 graus 15' S e os meridianos 49 graus e 30' e 49 graus e 50' W. O acesso é dado pela rodovia BR 242 a partir do entroncamento com a rodovia BR-153 distante aproximadamente 290 km da capital Palmas – TO. A altitude média da área do projeto é de 200 metros, com relevo plano e declividades baixas.

O Projeto Formoso em Formoso do Araguaia possui destaque na produção de sementes de soja no estado do Tocantins. A área mede em torno de 28 mil hectares dividida em 03 etapas coordenadas por cooperativas e empresas produtoras de sementes. A empresa Talismã com aproximadamente 3 mil hectares, participa desse cenário na produção de sementes.

A empresa Talismã Sementes possui uma unidade localizada em Formoso do Araguaia, na rodovia BR-242, próximo ao Projeto Rio Formoso. No ano de 2016, a empresa realizou a produção de sementes em uma área de aproximadamente 1260 hectares dividida em 17 talhões com uma média de 44 sacas/hectares, sendo a produção de aproximadamente 46 toneladas em uma produtividade média de 2.751 kg/ha.

Segundo relatório técnico do Projeto Rio Formoso elaborado por empresa contratada, as unidades de solos encontradas na região do Projeto Rio Formoso são, entre elas, Plintossolos em maior parte da área, Gleissolos nas Ipucas e Neossolos em uma área de abrangência menor. (FARENCENA, 2011). É importante ressaltar que o presente estudo não realizou a quantificação das unidades de solos no interior da área do Projeto Rio Formoso.

Os plintossolos compreendem solos minerais formados sob condições de restrição à percolação da água sujeitos ao efeito temporário de excesso de umidade, de maneira geral imperfeitamente ou mal drenados. Isso caracterizam fundamentalmente por apresentar expressiva plintitização com ou sem petroplintita na condição de que não satisfaçam os requisitos estipulados para as classes dos Neossolos, Cambissolos, Luvisolos, Argissolos, Latossolos, Planossolos ou Gleissolos (EMBRAPA, 2014).

4.2 Estimativa de área plantada

4.2.1 Seleção das variedades ano 2016

A primeira parte da metodologia envolveu a escolha dos talhões com o maior número de área plantada em hectares, pois no projeto em alguns talhões foram desenvolvidas pesquisas com a implantação em pequenas áreas no interior dos talhões e por serem dados de 2016 não foi possível dimensionar as pequenas áreas. Com esse critério foram identificadas as seguintes variedades com os seus respectivos talhões, com a informação da data de plantio, colheita, ciclo das variedades e o grau de maturação relativo (GMR) de acordo com a tabela 01.

Figura 05 –Área de plantio das variedades de ciclo curto (CC) e ciclo médio (CM) – 2016




Tabela 03 – Variedades de 2016 e as datas de plantio, colheita e o ciclo

VARIEDADE	TALHÃO	HECTARES	PLANTIO	COLHEITA	CICLO	GMR
M8349 IPRO	A12-3	104	28/04/2016	04/08/2016	98	8,3
M8349 IPRO	E3-3	53,3	18/05/2016	20/08/2016	94	8,3
ST860 RR	A7-3	62,3	05/05/2016	12/08/2016	99	8,6
ST860 RR	A9-3	79,1	05/05/2016	17/08/2016	104	8,6
ST860 RR	B7-3	97,7	05/05/2016	18/08/2016	105	8,6
M8808 IPRO	B2-3	86	12/05/2016	05/09/2016	116	8,8
M8808 IPRO	C2-3	82	12/05/2016	06/09/2016	117	8,8
M8808 IPRO	G10-2	68,5	07/05/2016	19/08/2016	104	8,8
M8808 IPRO	G12-2	83,2	10/05/2016	30/08/2016	112	8,8
M8210IPRO	E6-2	72,5	21/04/2016	28/07/2016	98	8,2
M8210IPRO	E4-2	65,3	22/04/2016	28/07/2016	97	8,2
M8210IPRO	I9-2	76,2	25/04/2016	04/08/2016	101	8,2
M8210IPRO	I11-2	78	23/04/2016	06/08/2016	105	8,2

Fonte: Talismã Sementes (2016)


Nota-se que por meio da tabela acima, os talhões B2-3, C2-3, G10-2 e G12-2 com a variedade M8808 IPRO com GMR 8,8, ou seja, de ciclo médio (CM), as demais são consideradas de ciclo curto (CC). Assim os talhões foram separados em variedades de ciclo curto (CC) e ciclo médio (CM) como mostra a figura 06.

Não houve estimativa de área plantada para o ano de 2017 por haver apenas 04 talhões como amostragem o que impossibilitou a análise estatística.

4.2.2 Identificação e obtenção das imagens Landsat 08, ano 2016

Após a identificação dos talhões como (CC) e (CM), tornou-se possível a escolha das imagens Landsat 08 disponibilizadas pelo portal do Sistema Geológico do Estados Unidos (USGS) baseada nas datas de plantio e colheita das variedades implantadas nos talhões em 2016. As imagens atualmente são bastante utilizadas na obtenção de informações da superfície terrestre, possuindo resolução espacial de 30 metros e temporal de 16 dias. As faixas do espectro e as respectivas bandas espectrais seguem abaixo.

Figura 06 – Características das Bandas Espectrais do Landsat 08

SENSORES LANDSAT 08	
Operational Land Imager (OLI)	Thermal Infrared Sensor (TIRS)
Band 1 Visible (0.43 - 0.45 μm) 30 m	Band 10 TIRS 1 (10.6 - 11.19 μm) 100 m
Band 2 Visible (0.450 - 0.51 μm) 30 m	Band 11 TIRS 2 (11.5 - 12.51 μm) 100 m
Band 3 Visible (0.53 - 0.59 μm) 30 m	
Band 4 Red (0.64 - 0.67 μm) 30 m	
Band 5 Near-Infrared (0.85 - 0.88 μm) 30 m	
Band 6 SWIR 1 (1.57 - 1.65 μm) 30 m	
Band 7 SWIR 2 (2.11 - 2.29 μm) 30 m	
Band 8 Panchromatic (PAN) (0.50 - 0.68 μm) 15 m	
Band 9 Cirrus (1.36 - 1.38 μm) 30 m	

Fonte: USGS, 2013

Durante a escolha das imagens entre junho e setembro atentou-se para aquelas que não possuíssem grandes interferências quanto à presença de nuvens. Fato esse não encontrado em razão do período seco vigorar durante os meses de junho e setembro o que possibilitou maior facilidade na escolha das imagens.

De acordo com as datas estabelecidas entre o plantio, os estádios R1 a R7 e a data da colheita buscou-se imagens em dias aproximados aos decêndios compreendidos entre R1 e R7. Dessa forma, foram usadas 07 imagens para realização do estudo (Tabela 04).

Tabela 04 – Imagens Landsat 08/2016 entre junho e setembro e os estádios reprodutivos.

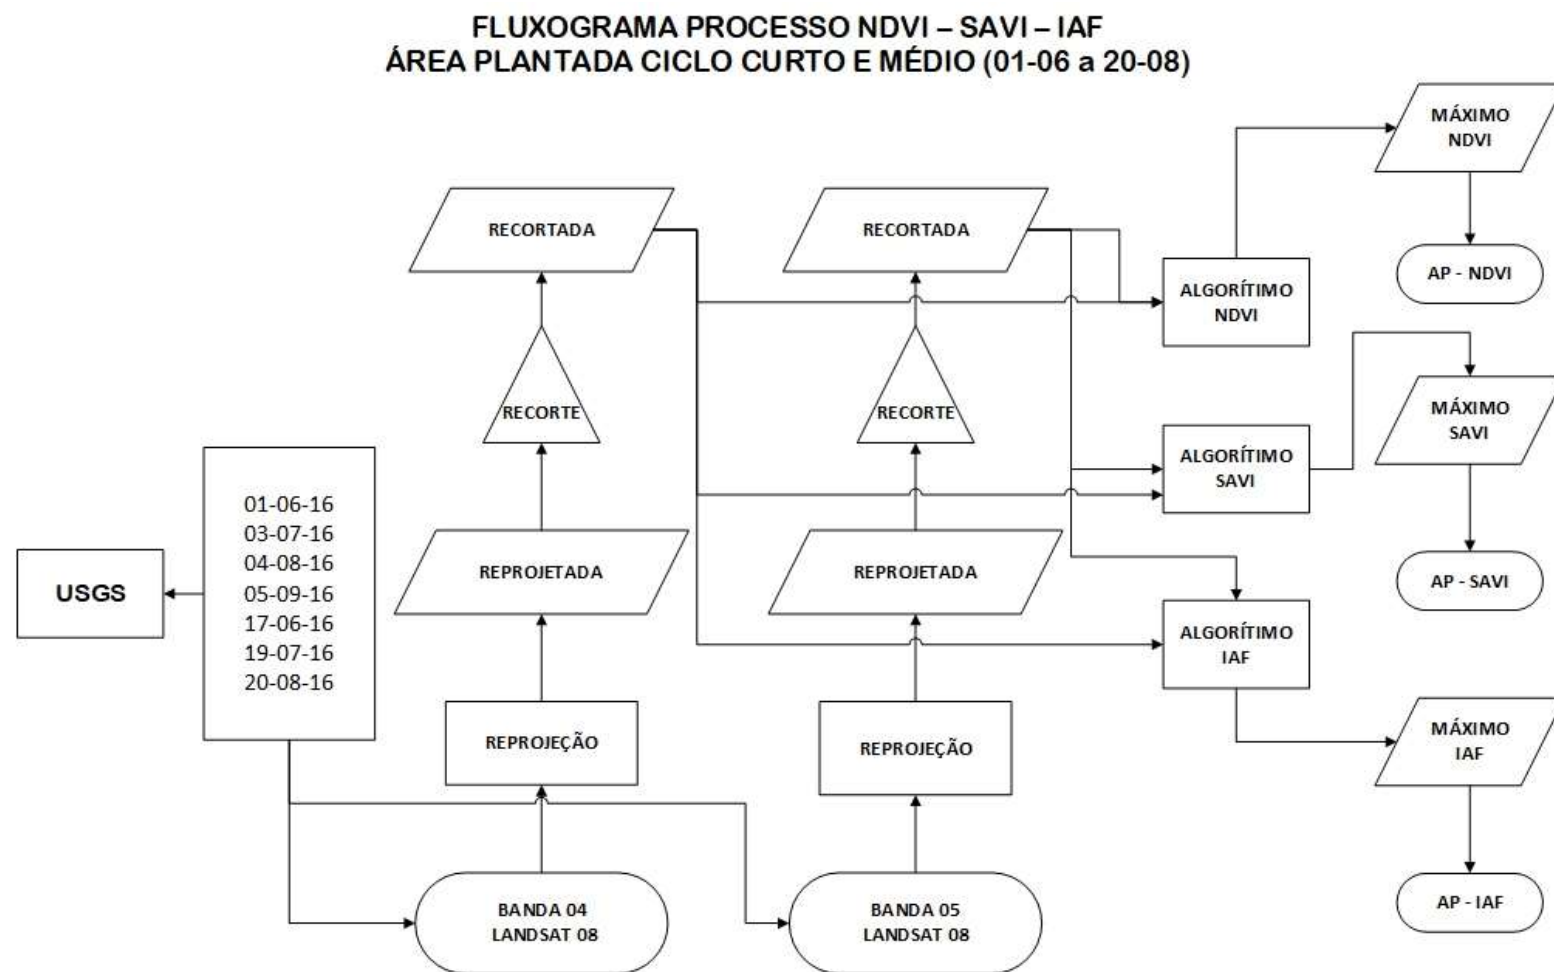
ESTÁDIOS REPRODUTIVOS	R1	R2	R3	R4	R5	R6	R7
IMAGENS LANDSAT 08 2016	(01/06)	(17/06)	(03/07)	(19/07)	(04/08)	(20/08)	(05/09)
DATAS QUINZENAIS	(28/05)	(12/06)	(27/06)	(12/07)	(27/07)	(12/08)	(27/08)

4.2.3 Procedimentos para estimativa de área plantada ano 2016

Na segunda parte da metodologia para a obtenção das informações pertinentes a área plantada, fez-se necessário o uso de algoritmos e rotinas que se realizaram no software Arc Gis versão 10.6. Além dos mapas de localização, as rotinas específicas para obter os resultados esperados, tanto para os talhões com variedades (CC) quanto às variedades (CM), destacam-se:

- As imagens Landsat 08 são projetadas para hemisfério norte, sistema de coordenadas geográfico. Neste caso, as imagens escolhidas foram reprojatadas para o hemisfério sul Datum WGS 84 Sistema de Coordenadas UTM, fuso 22s;
- O tamanho da área imageada das imagens Landsat 08 é de 185 Km² o que dificulta o processamento da imagem como um todo. Devido a isso realizou o recorte das bandas utilizadas para aplicação dos algoritmos de acordo com a área de estudo, referente aos talhões escolhidos do Projeto Formoso;
- Conversão dos números digitais (ND) da imagem para reflectância da parte superior da atmosfera;
- Geração do NDVI a partir bandas 04 e 05 do satélite Landsat 08 referentes as 07 imagens escolhidas dentro do período identificados entre o plantio e a colheita;
- Geração do SAVI a partir das bandas 04 e 05 do satélite Landsat 08 referentes as 07 imagens escolhidas dentro do período identificados entre o plantio e a colheita;
- Geração do IAF a partir das bandas 04 e 05 do satélite Landsat 08 referentes as 07 imagens escolhidas dentro do período identificados entre o plantio e a colheita;
- Aplicação lógica *fuzzy* para os índices NDVI, SAVI e IAF com o tipo de sobreposição escolhido no Arc Gis “OR” com a classificação do máximo em relação aos dados de entrada do raster para cada talhão. A Logica *fuzzy* adotada na metodologia, fez-se necessário mediante a intenção em classificar os dados raster’s no período de maior vigor da soja nos estádios reprodutivos de R1 a R7, nas 07 imagens do satélite Landsat 08 escolhidas para o período de entressafra em 2016 (junho a setembro);
- Reclassificação dos resultados da lógica *fuzzy* com a definição do fator *fuzzy* adotado a partir dos pixels maiores que 0,30 sendo definido como resultado da área colhida estimada (Figura 08).

Figura 07 – Fluxo do processo de obtenção da área estimada plantada para o ano de 2016



4.2.4 Correlação estatística entre área colhida e área estimada ano 2016

Todos os índices SAVI, IAF e NDVI dos talhões de ciclo médio e ciclo curto foram submetidos à Correlação e Regressão com a área colhida em campo através do Software SigmaPlot V 12.0. A análise dos resultados fez-se na leitura do coeficiente de correlação e coeficiente de determinação. E a partir desses dados analisar os resultados e a eficiência da metodologia.

4.3 Estimativa da Produtividade

As informações de produtividade georreferenciadas no ano de 2017 da variedade M8644IPRO (variedade de ciclo curto) foram coletadas junto a empresa num total de 140 pontos, considerando áreas menores inseridas dentro dos talhões. A decisão pelo ano de 2017 foi devido a amostragem realizada em campo, tanto para obtenção do teor de óleo quanto para registro da temperatura foram realizadas em 2017.

Os dados de produtividade foram tabulados em planilha e espacializados por meio do software ArcGIS® 10.6, assim como os talhões. Com as informações sobrepostas, talhões e pontos, com as produtividades foi possível identificá-los onde se desenvolveu a cultura em um total de 10 talhões denominados como, E1-03, E6-03, D5-03, C2-03, C8-03, C12-03, B5-03, G12-02, G14-02 e B2-02. Foi considerado apenas o interior dos talhões onde há cultura da soja, retirando as áreas entre as parcelas, como área de acesso, estradas, locais pedregosos, entre outros.

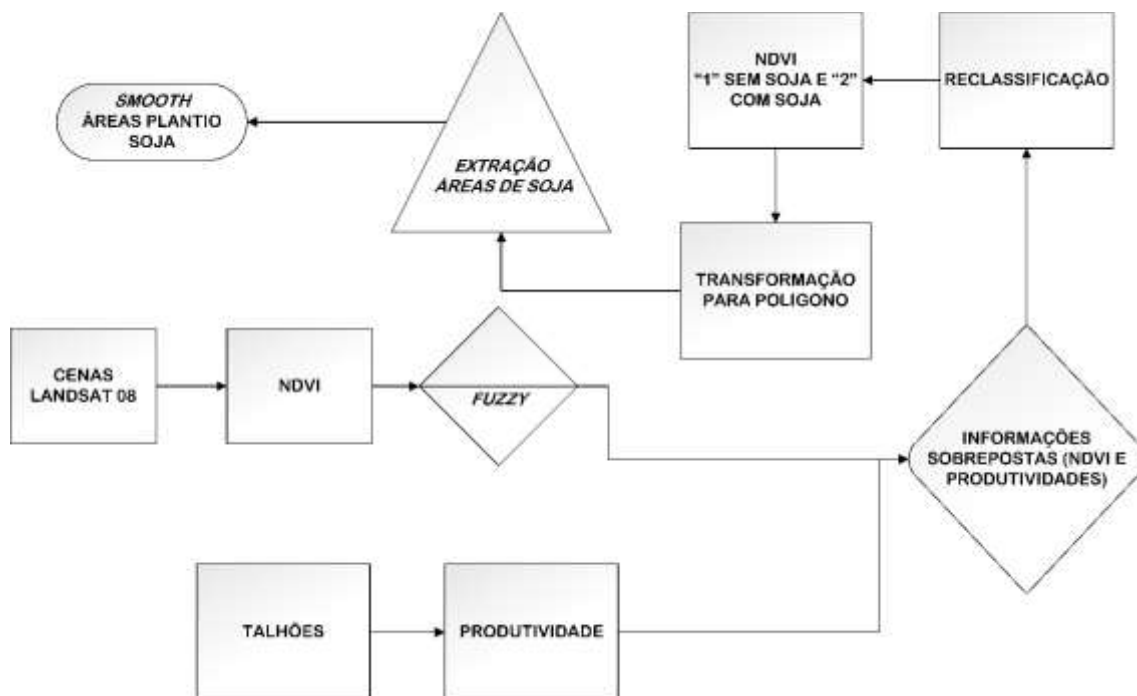
A identificação das áreas foi possível com o auxílio das imagens Landsat 08 no período da entressafra, entre os meses de junho e outubro de 2017 conforme a Tabela 05. Esses dados foram processados com o algoritmo NDVI e classificados inicialmente em 05 classes, com a representação dos valores mínimos e máximos e com a aplicação da lógica *fuzzy* de classificação para extrair das imagens o momento de maior vigor da cultura no período.

Tabela 05 – Imagens Landsat 08/2017 entre junho e outubro e os estádios reprodutivos

ESTÁDIOS REPRODUTIVOS	R1	R2	R3	R4	R5	R6	R7
IMAGENS LANDSAT 08 2017	(30/06)	(16/07)	(28/07)	(13/08)	(12/09)	(26/09)	(13/10)
DATAS QUINZENAIS	(28/05)	(12/06)	(27/06)	(12/07)	(27/07)	(12/08)	(27/08)

Os resultados obtidos a partir da lógica *fuzzy* permitiram uma análise visual por talhão com a eliminação dos pixels representativos das áreas onde não se desenvolveu a cultura e as áreas com plantio através da reclassificação dos rasters dos talhões individualizados em duas classes separadas sendo “1” para área sem soja e “2” para área com soja. Os rasters passaram por transformação em polígono e, em seguida, por um processo de suavização das bordas por meio da ferramenta *smooth* do Arc Gis 10.6 (Figura 09) com a separação da área de plantio em arquivos separados por talhão respeitando os limites do talhão.

Figura 08 – Classificação fuzzy – NDVI e identificação das áreas de plantio de soja



4.3.1 Interpolação dos dados

A interpolação dos dados foi realizada por meio do software ArcGIS® 10.6 realizando-se uma análise exploratória das produtividades em campo do ano 2017. Assim, foi possível verificar a normalidade e a tendência dos dados pelo histograma na ferramenta *Geostatistical Analyst*, sendo que não houve necessidade de proceder com nenhuma transformação dos dados tendo em vista a sua distribuição dentro das normalidades.

Após essa etapa, foi aplicado o método de interpolação da Krigagem Ordinária, obtendo-se os melhores resultados de semivariogramas, com a averiguação do melhor modelo ajustado. Utilizou-se também, a escolha do modelo Gaussiano no qual apresentou melhores previsões para os dados analisados. Os resultados das interpolações foram

aplicados apenas nas áreas de cultivo da soja, oriundos do processo anterior com a identificação das áreas com o uso do NDVI e separados por talhão no ano de 2017 facilitando a análise das informações.

Os valores do raster NDVI (2017) classificados pela lógica *fuzzy* foram extraídos com o plugin *point sample tool* do software QGIS 2.18.12, exatamente na área do pixel que é sobreposto pelos pontos georreferenciados com os dados de produtividade fornecidos pela empresa Talismã Sementes. E em seguida, por meio do software SigmaPlot Versão 12.0, que são correlacionados e analisados os resultados do coeficiente de determinação (R^2), coeficiente de Pearson (R), a representação em gráfico com comportamento linear e sua equação de regressão com a estimativa da produtividade em relação aos valores do NDVI. A espacialização dos resultados das análises foi feita por talhão, o que facilitou a visualização das produtividades nas áreas de plantio dos talhões.

4.4 Teor de óleo e temperatura

No ano de 2017 segue a análise dos dados de área plantada e produtividade obtidos em campo, informações fornecidas pela empresa. Inicialmente, para coleta de temperatura e amostragem das sementes em campo, necessitou da identificação da quantidade de amostras necessárias para representar uma área de 102,1168 hectares (1.020.000 mil metros quadrados). Para isso, fez-se necessário a divisão da área em pequenas parcelas no intuito de representar os pixels da imagem.

Antes da construção do grid com as parcelas menores dividiu-se a área do E1-3 em quatro áreas seguindo a representação das estradas internas existentes entre as áreas do E01-3. Logo em seguida, no programa Arc Gis 10.6, criou-se as pequenas parcelas de 30x30 respeitando a resolução espacial da imagem Landstat 08, logo após excluiu-se áreas que não são usadas no plantio por haverem pedras, acessos e as áreas dos canais.


No mesmo programa realizou-se a amostragem por pontos baseados nas pequenas parcelas criadas de forma aleatória e randômica. Ao final desse procedimento, como resultado, foram criados grids com áreas de 900 metros quadrados num total aproximado de 840 grids, pois houve a retirada das bordas e áreas com tamanho diferenciados, assim como locais onde não há plantio. Também, foram inseridos pontos georreferenciados, espacializados e identificados no interior das parcelas em um total de 35 amostras.

De posse das coordenadas de cada amostra alocada anteriormente em uma grade amostral através do programa Arc Gis 10.6 possibilitou o rastreamento de cada ponto em campo por intermédio do receptor GPS. E dessa forma catalogar a temperatura de cada

ponto escolhido aleatoriamente dentro de cada talhão na altura do dossel e no solo próximo as plantas (Figura 10). As temperaturas foram coletadas por meio de termômetro infravermelho Minipa MT 395A.

O uso da amostragem facilitou também a coleta das sementes para as respectivas informações de teor de óleo mediante as análises realizadas nos laboratórios da Universidade Federal do Tocantins (UFT) e Faculdade Católica do Tocantins (FACTO).

Figura 09 – Talhão E1-03 e malha de pontos para coleta de teor de óleo e temperatura



Fonte: Imagem Google Earth

A extração do óleo das sementes de soja coletadas em campo procedeu-se segundo o método de Bligh e Dyer, com clorofórmio, metanol e água destilada (BLIGH; DYER, 1959). Os dados de teor de óleo foram interpolados utilizando o software ArcGIS 10.6 onde realizou-se a análise exploratória dos resultados de teor de óleo e a temperatura coletados em campo no talhão E01-3 no ano 2017. Em seguida, foram verificados os dados quanto a normalidade e a suas tendências. Isso se deu pelo histograma na ferramenta *Geoestatistical Analyst*, não havendo necessidade de proceder com nenhuma transformação dos dados, tendo em vista a distribuição no normal.

Após essa etapa foi aplicado o método de interpolação da Krigagem Ordinária, que obteve os melhores resultados de semivariogramas com a averiguação do melhor modelo ajustado, após a escolha do modelo Gaussiano que apresentou melhores previsões

para os dados analisados e, em seguida, estimado para a área total do talhão E01-3, talhão escolhido para coleta das amostras de teor de óleo e temperatura.

A temperatura do dossel e o teor de óleo de 2017, ambos coletados em campo, foram correlacionados entre si, por meio do software SigmaPlot Versão 12.0 e analisados os resultados do coeficiente de determinação (R^2), coeficiente de Pearson (R), representação em gráfico com comportamento linear e sua equação de regressão com a estimativa do teor de óleo em relação aos valores da temperatura do dossel.

O teor de óleo amostrado para o talhão E01-3 estimado pela interpolação com resultados em percentuais foi multiplicado pelo raster originado da interpolação dos dados de produtividade para os talhões de 2017, através do ArcGIS® 10.6, pela ferramenta *Raster Calculator* localizada no ArcToolBox. Dessa forma, foi possível alcançar o rendimento de óleo nos talhões de 2017 desenvolvidos pela empresa Talismã Sementes para a variedade M8644IPRO. A espacialização dos resultados das análises foi feita por talhão, o que facilitou a visualização dos rendimentos de óleo nas áreas de plantio dos mesmos.

5. RESULTADOS E DISCUSSÃO

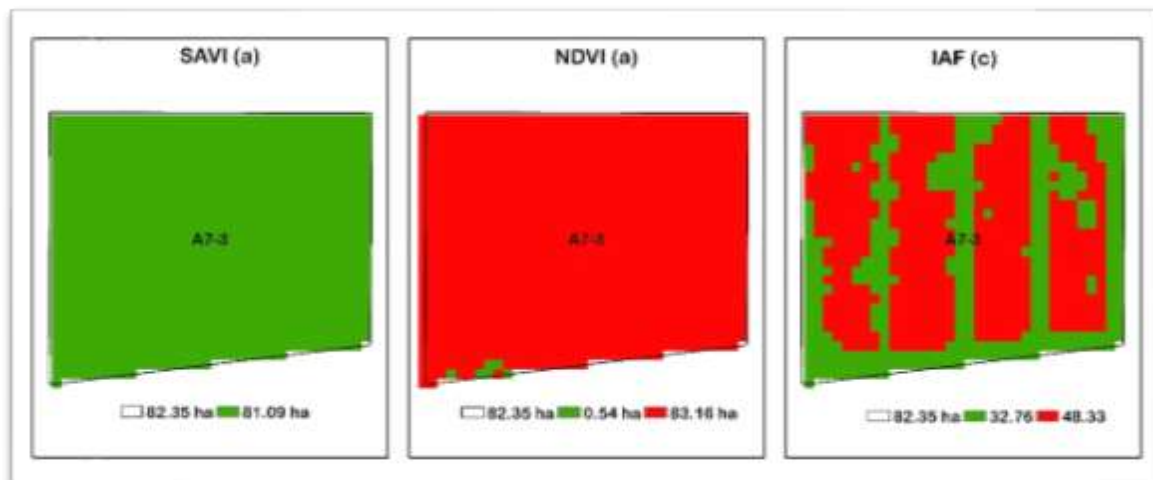
Os índices NDVI, SAVI e IAF foram extraídos das bandas 04 e 05 das imagens Landsat 8 de 2016 no período da entressafra com a aplicação da lógica *fuzzy* considerando o ótimo da vegetação. Obteve-se os resultados individualizados para cada talhão entre as variedades de ciclo curto e ciclo médio, com estimativa de área plantada para o ano de 2016. As informações de área colhida *in loco* foram fornecidas pela empresa Talismã Sementes e correlacionadas com os valores estimados obtidos dos índices.

5.1 Estimativa de área plantada de variedades de ciclo curto, ano 2016

A estimativa da área plantada por meio do NDVI foi realizada por algoritmo que é determinado pela razão entre a diferença da faixa do espectro do infravermelho próximo e o vermelho pela soma do infravermelho próximo com a faixa do vermelho. O Índice SAVI é calculado de forma semelhante ao NDVI, mas com a adição do fator de ajuste ao solo com valores entre 0,25 a 1,0 onde 0,25 é representado pela alta densidade da vegetação, 0,5 densidade intermediária, sendo este o mais utilizado, e 1,0 para densidade baixa. O IAF é definido pela razão entre a área foliar de uma vegetação por uma unidade de área utilizada por esta vegetação. Os 03 (três) índices foram obtidos por meio da ferramenta *raster calculator* do programa Arc Gis 10.6 e os resultados representados por mapas individuais para cada talhão.

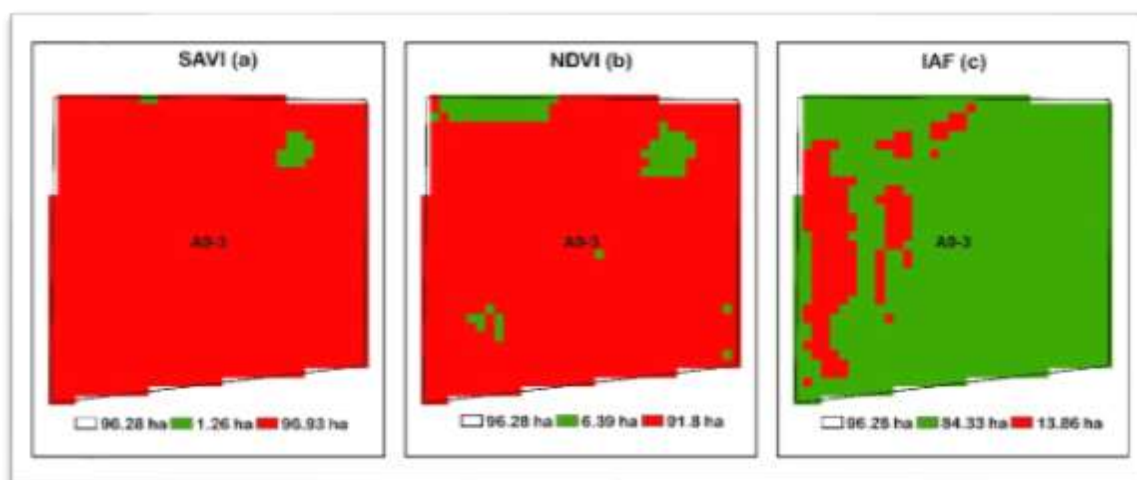
A Figura 10 com o talhão A7-03 possui uma área de 82,35 ha, a variedade implantada é a ST860RR de ciclo curto (CC). A área estimada colhida no talhão foi subestimada, comparada aos resultados obtidos em campo da colheita com 62,30 ha no índice **SAVI (a)** não havendo identificação das áreas de plantio e diferenciação entre os talhões. E no índice **NDVI (b)** foi maior que a área colhida com 83,16 ha, aumento de 16,06% não havendo separação das áreas de plantio e vias de circulação. O índice **IAF (c)** subestimou com área estimada de 48,33 ha, com percentual de diferença de -22,42%, abaixo da área colhida em campo.

Figura 10 – Área estimada colhida para o talhão A7-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 11 com o talhão A9-03 possui uma área de 96,28 ha, a variedade implantada é a ST860RR de ciclo curto (CC). A área estimada colhida no talhão foi superestimada, comparada aos resultados obtidos em campo da colheita com 79,10 ha no índice **SAVI (a)** com 96,93 ha, aumento de 22,54% e no índice **NDVI (b)** foi maior que área colhida com 91,80 ha, aumento de 16,06% não havendo separação das áreas de plantio e vias de circulação em ambos os índices e com pouca diferença quanto a área colhida em campo, sendo o destaque para o NDVI (b). O índice **IAF (c)** subestimou bastante com área estimada de 13,86 ha, com percentual de diferença de -82,48%, bem abaixo da área colhida em campo.

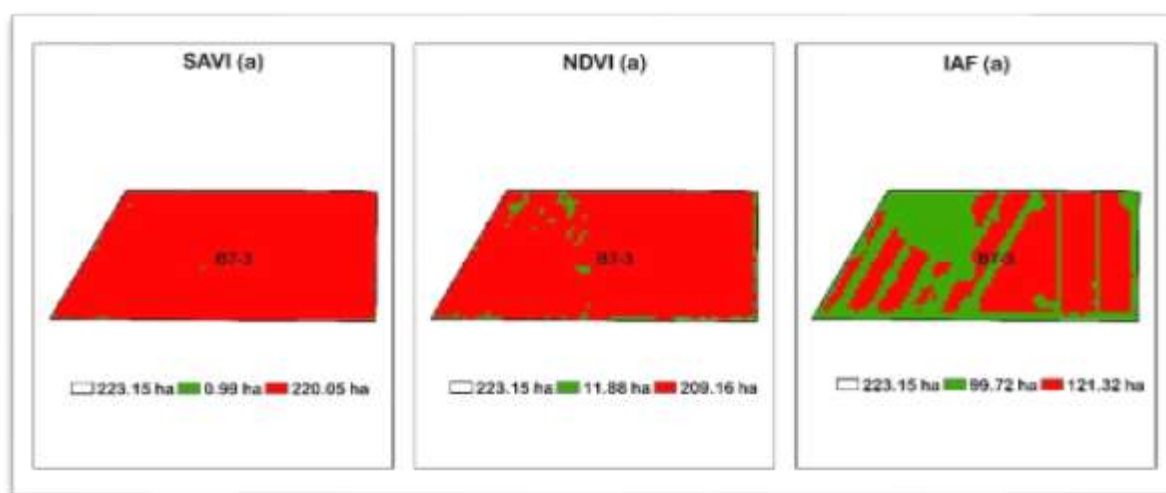
Figura 11 – Área estimada colhida para o talhão A9-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 12 com o talhão B7-03 possui uma área de 223,15 ha, a variedade implantada é a ST860RR de ciclo curto (CC). Nesse talhão não houve plantio em sua área

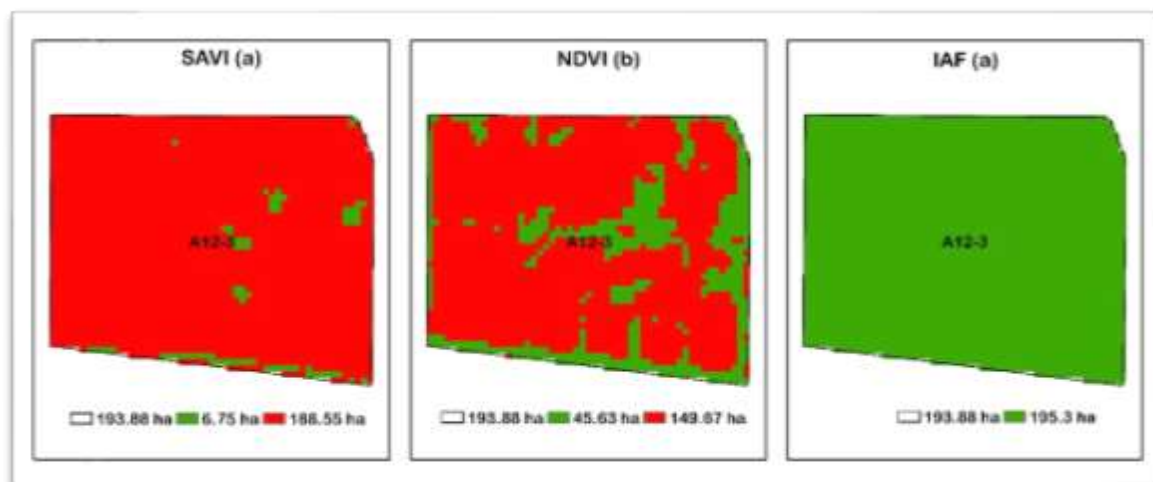
total. A área estimada colhida no talhão foi superestimada, comparada aos resultados obtidos em campo da colheita com 120,40 ha no índice **SAVI (a)** com 220,05 ha, aumento de 82,77% e no índice **NDVI (b)** foi maior que área colhida com 209,16 ha, aumento de 73,72%. Dessa forma, observou-se que não houve distinção entre as áreas de plantio e as vias de circulação em ambos os índices, com excessiva diferença quanto a área colhida em campo. O índice **IAF (c)** superestimou com área estimada de 121,32 ha, aumento percentual de 0,76%, bem próximo da área colhida em campo demonstrando um comportamento melhor em relação aos outros índices.

Figura 12 – Área estimada colhida para o talhão B7-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



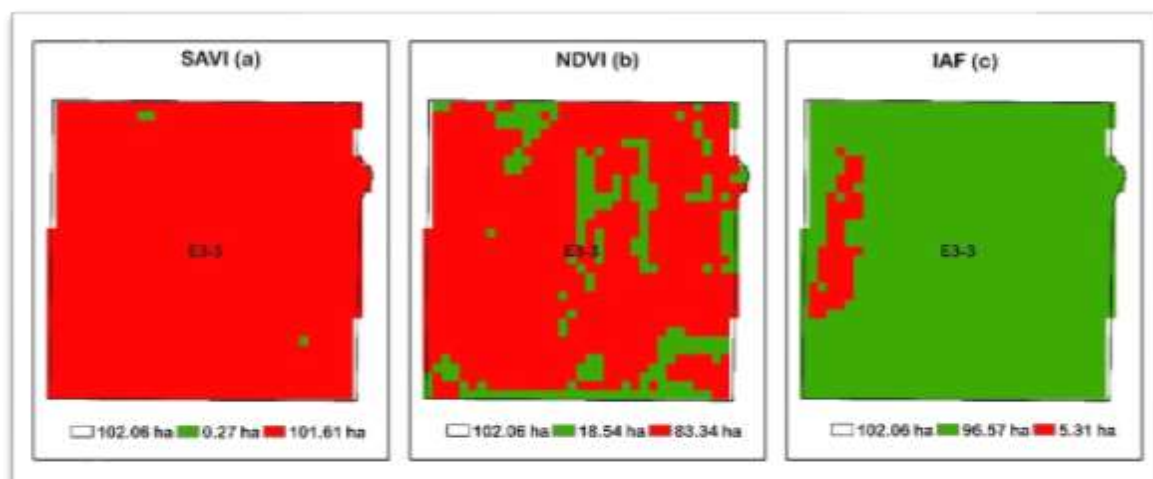
A Figura 13 com o talhão A12-03 possui uma área de 193,88 ha, a variedade implantada é a M8349IPRO de ciclo curto (CC) grupo de maturação (GM) 8,3 com ciclo médio de 119 dias para grãos recomendada para plantio na segunda semana de outubro e colheita na primeira semana de novembro. Nesse talhão não houve plantio em sua área total. A área estimada colhida no talhão foi superestimada comparada aos resultados obtidos em campo da colheita com 104,00 ha no índice **SAVI (a)** com 188,55 ha, aumento de 81,30% ao passo que no índice **NDVI (b)** foi maior que área colhida com 149,67 ha, aumento de 43,91%, sem distinção entre as áreas de plantio e as vias de circulação maiores no índice SAVI (a) e no NDVI (b) demonstrando alguma distinção entre as áreas de plantio e os acessos entre os talhões. O índice **IAF (c)** subestimou com área estimada de 0,0 ha, baixa percentual de -100%, onde não houve identificação de plantio no interior do talhão por meio do índice.

Figura 13 – Área estimada colhida para o talhão A12-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 14 com o talhão E03-03 possui uma área de 102,06 ha, a variedade implantada foi a M8349IPRO de ciclo curto (CC). Nesse talhão não houve plantio em sua área total. A área estimada colhida no talhão foi superestimada, comparada aos resultados obtidos em campo da colheita com 53,30 ha no índice **SAVI (a)** com 101,61 ha, aumento de 90,64%. E no índice **NDVI (b)** foi maior que área colhida com 83,34 ha, aumento de 56,36%, sem distinção entre as áreas de plantio e as vias de circulação. O índice **IAF (c)** subestimou com área estimada de 5,31 ha, baixa percentual de -90,04%, valor representado pelo índice bem abaixo em relação à área colhida em campo.

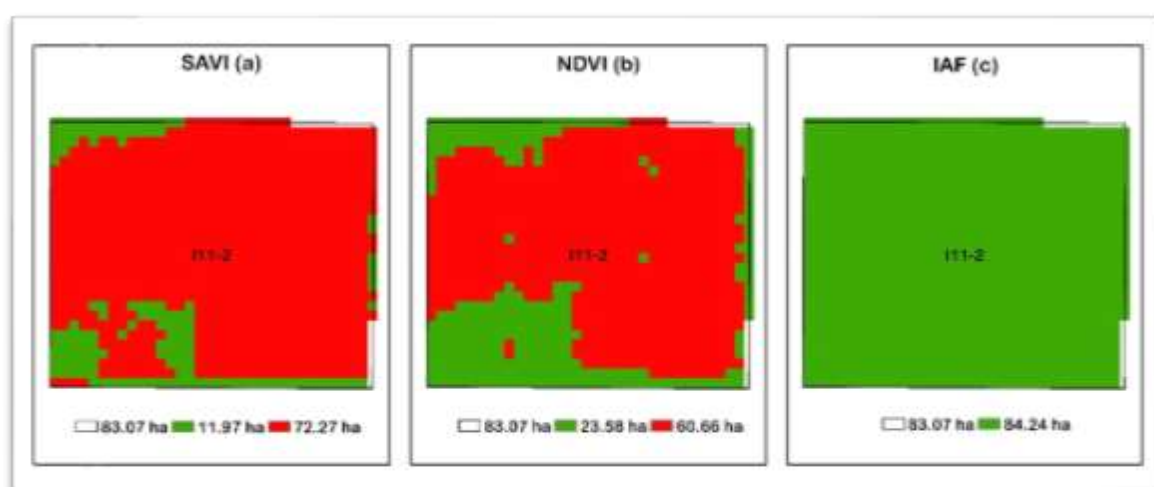
Figura 14 – Área estimada colhida para o talhão E03-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 15 com o talhão I11-02 possui uma área de 83,07 ha, a variedade implantada é a M8210IPRO de ciclo curto (CC) grupo de maturação (GM) 8,2 com ciclo médio de 114 dias para grãos recomendada para plantio na segunda semana de outubro e

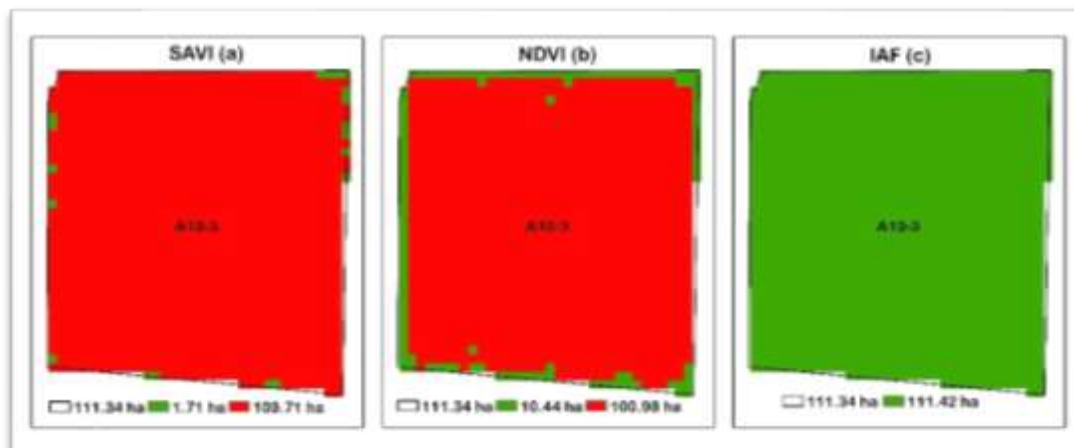
colheita na primeira semana de novembro. A área estimada colhida no talhão foi subestimada e comparada aos resultados obtidos em campo da colheita com 78,00 ha no índice **SAVI (a)** com 72,27 ha, diminuição de -7,35%. E no índice **NDVI (b)** foi menor que a área colhida com 60,66 ha, baixa percentual de -22,23%, sem distinção entre as áreas de plantio e as vias de circulação. O índice **IAF (c)** subestimou com área estimada de 0,0 ha, baixa percentual de -100%, onde não houve identificação de plantio no interior do talhão por meio do índice.

Figura 15 – Área estimada colhida para o talhão I11-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



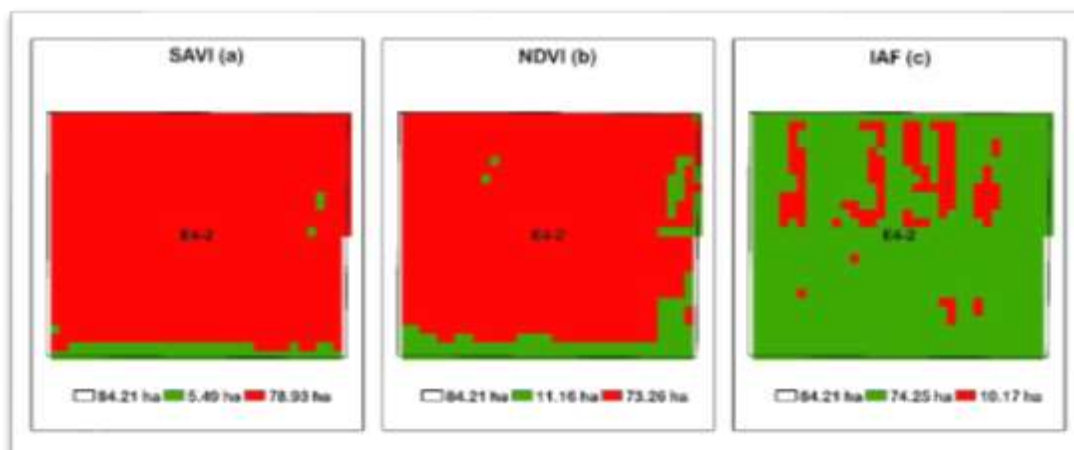
A Figura 16 com o talhão A10-03 possui uma área de 111,34 ha, a variedade implantada é a M8210IPRO de ciclo curto (CC). A área estimada colhida no talhão foi superestimada comparada aos resultados obtidos em campo da colheita com 66,80 ha no índice **SAVI (a)** com 109,71 ha, aumento de 64,24%. E no índice **NDVI (b)** foi maior que a área colhida com 100,98 ha, aumento percentual de 51,17%, sem distinção entre as áreas de plantio e as vias de circulação em ambos os índices, apenas um destaque com a representação das bordas do talhão, além de elevada diferença em relação a área colhida em campo. O índice **IAF (c)** subestimou com área estimada de 0,0 ha, baixa percentual de -100%, onde não houve identificação de plantio no interior do talhão por meio do índice.

Figura 16 – Área estimada colhida para o talhão A10-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 17 com o talhão E04-02 possui uma área de 84,21 ha, a variedade implantada é a M8210IPRO de ciclo curto (CC). A área estimada colhida no talhão foi superestimada comparada aos resultados obtidos em campo da colheita com 65,30 ha no índice **SAVI (a)** com 78,93 ha, acréscimo de 20,87% e no índice **NDVI (b)** foi maior que área colhida com 73,26 ha, aumento percentual de 12,19%, sem distinção entre as áreas de plantio e as vias de circulação em ambos os índices, apenas um destaque para a representação de algumas bordas do talhão. O índice **IAF (c)** subestimou a área colhida com 0,0 ha, baixa percentual de -100%, onde não houve identificação de plantio no interior do talhão por meio do índice.


Figura 17 – Área estimada colhida para o talhão E04-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 18 com o talhão E06-02 possui uma área de 85,40 ha, a variedade implantada é a M8210IPRO de ciclo curto (CC). A área estimada colhida no talhão foi superestimada comparada aos resultados obtidos em campo da colheita com 72,50 ha no


índice **SAVI (a)** com 82,17 ha, acréscimo de 13,34%. E no índice **NDVI (b)** foi maior que a área colhida com 80,55 ha, aumento percentual de 11,10%, sem distinção entre as áreas de plantio e as vias de circulação em ambos os índices. Portanto, observou-se apenas um destaque para a representação de algumas bordas do talhão. O índice **IAF (c)** subestimou com área estimada de 5,04 ha, baixa percentual de -93,05%, valor estimado pelo índice bem abaixo da área colhida em campo.

Figura 18 – Área estimada colhida para o talhão E06-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 19 com o talhão I09-02 possui uma área de 82,74 ha, a variedade implantada é a M8210IPRO de ciclo curto (CC). A área estimada colhida no talhão foi superestimada, comparada aos resultados obtidos em campo da colheita com 76,20 há, no índice **SAVI (a)** com 81,54 ha, acréscimo de 7,01%. Observou-se, também, que no índice **NDVI (b)** foi maior que área colhida com 76,95 ha, aumento percentual de 0,98%. Portanto, sem distinção entre as áreas de plantio e as vias de circulação em ambos os índices, apenas um destaque para a representação de algumas bordas do talhão. O índice **IAF (c)** subestimou com área estimada de 47,34 ha, baixa percentual de -37,87%, valor estimado pelo índice bem abaixo da área colhida em campo.

Figura 19 – Área estimada colhida para o talhão I09-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



5.1.1 Análise estatística ciclo curto

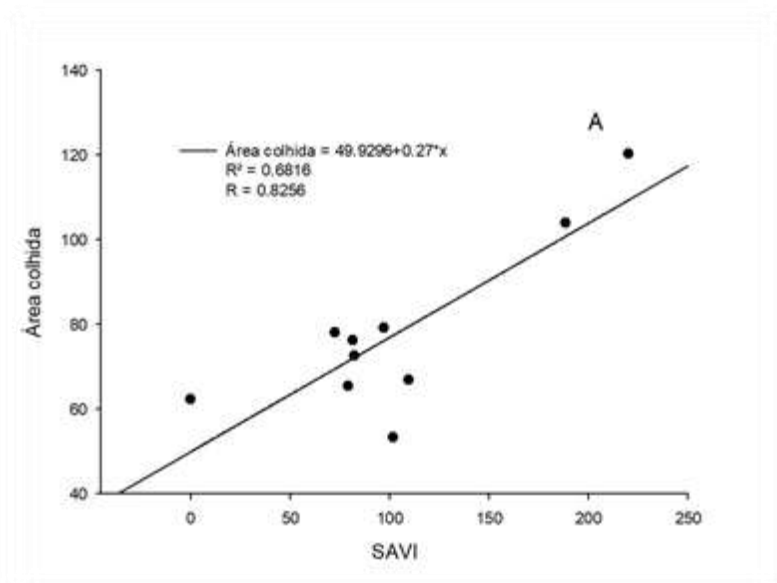
A Tabela 06 mostra os dados estimados por meio dos índices NDVI, SAVI e IAF de área colhida para o ano de 2016 que foram tabulados em planilha Excel com os resultados separados por talhões para as variedades de ciclo curto, ano de 2016.

Tabela 06 – Áreas colhidas e estimadas a partir do NDVI, IAF e SAVI – ciclo curto 2016.

VARIEDADE	TALHÃO	SAVI	NDVI	IAF	ÁREA COLHIDA
ST860RR	A7-03	0	83.16	48.33	62.3
ST860RR	A9-03	96.93	91.8	13.86	79.1
ST860RR	B7-03	220.05	209.16	121.32	120.4
M8349IPRO	A12-03	188.55	149.67	0	104
M8349IPRO	E03-03	101.61	83.34	5.31	53.3
M8210IPRO	I11-02	72.27	60.66	0	78
M8210IPRO	A10-03	109.71	100.98	0	66.8
M8210IPRO	E04-02	78.93	73.26	10.17	65.3
M8210IPRO	E06-02	82.17	80.55	5.04	72.5
M8210IPRO	I09-02	81.54	76.95	47.34	76.2


O Gráfico 01 traz os resultados da análise regressão representada através do coeficiente de determinação (R^2) e o coeficiente de correlação de Pearson (R), com resultados significativos a 5% ($p < 0,05$) nas condições do projeto e mediante o uso do índice SAVI com R^2 0,6816 e R igual a 0,8256 com um crescimento linear conforme o aumento do índice SAVI, em relação as áreas colhidas em campo pela colheitadeira. A análise estatística foi realizada com as variedades de ciclo curto no ano de 2016 obtidos através do software SigmaPlot versão 12.0.

Gráfico 01 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) pelo índice SAVI para variedades de ciclo curto (CC) ano de 2016




O Gráfico 02 expõe os resultados da análise regressão representada através do coeficiente de determinação (R^2) e o coeficiente de correlação de Pearson (R), com resultados significativos a 5% ($p < 0,05$) conforme as características da área de estudo mediante o uso do índice NDVI com R^2 0,7523 e R igual a 0,8673 com crescimento linear conforme o aumento do índice NDVI, em relação as áreas colhidas obtidas em campo.

Gráfico 02 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) pelo índice NDVI para variedades de ciclo curto (CC) ano de 2016



O Gráfico 03 expõe os resultados da análise regressão representada através do coeficiente de determinação (R^2) e o coeficiente de correlação de Pearson (R), com resultados significativos a 5% ($p < 0,05$) conforme as características da área de estudo mediante o uso do índice IAF com R^2 0,3421 e R igual a 0,5849 com um crescimento linear conforme o aumento do índice IAF, em relação as áreas colhidas obtidas em campo.

Gráfico 03 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) pelo índice IAF para variedades de ciclo curto (CC) ano de 2016

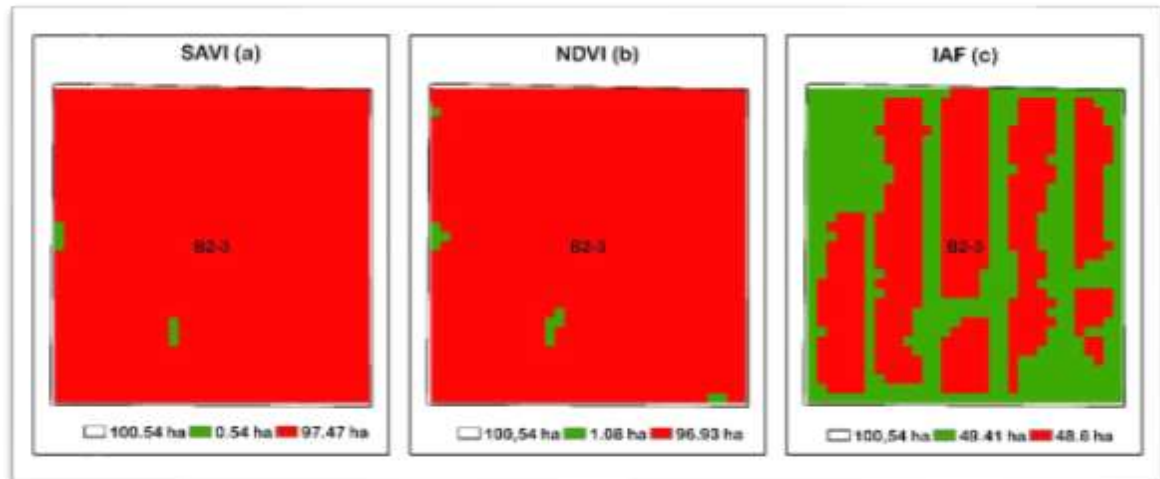


5.2 Estimativa de área plantada de variedades de ciclo médio, ano 2016

A Figura 20 com o talhão B2-03 possui uma área de 100,54 ha, a variedade implantada é a M8808IPRO de ciclo médio (CM). A área estimada colhida no talhão foi superestimada, comparada aos resultados obtidos em campo da colheita com 86,00 ha no índice **SAVI (a)** com 97,47 há e com acréscimo de 13,34%. Já no índice **NDVI (b)** foi maior que área colhida com 96,93 ha, aumento percentual de 12,71%, sem distinção entre as áreas de plantio e as vias de circulação em ambos os índices. O índice **IAF (c)**

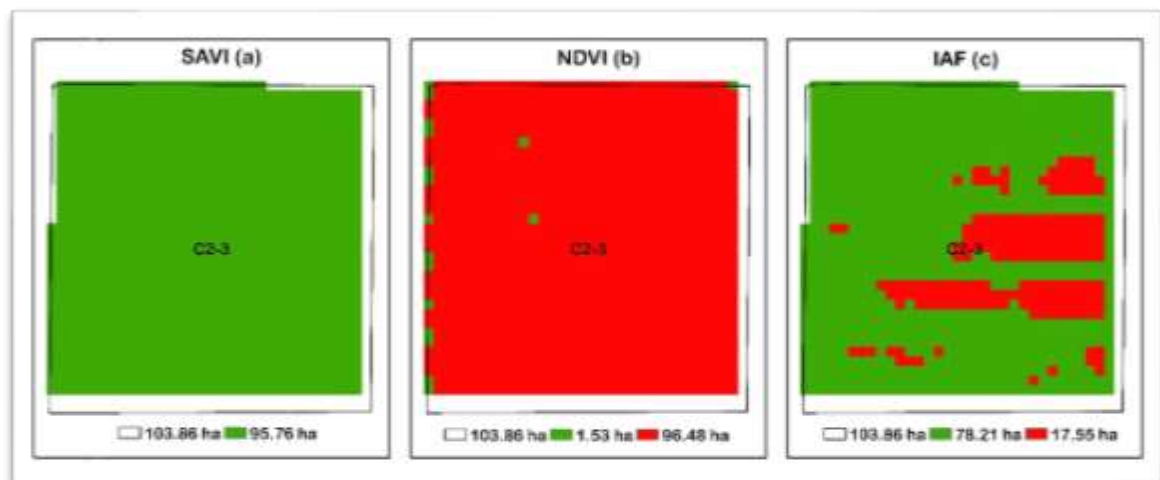
subestimou com área estimada de 48,46 ha, baixa percentual de -43,49%, mas com boa distinção entre as áreas de plantio e as vias de acesso entre os talhões.

Figura 20 – Área estimada colhida para o talhão B02-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)




A Figura 21 com o talhão C2-03 possui uma área de 103,86 ha, a variedade implantada é a M8808IPRO de ciclo médio (CM). A área estimada colhida no talhão foi subestimada, comparada aos resultados obtidos em campo da colheita com 82,00 ha no índice **SAVI (a)** sem identificação das áreas de plantio. E o índice **NDVI (b)** com valor superestimado para área colhida com 96,48 ha, aumento percentual de 17,66%, sem distinção entre as áreas de plantio e as vias de circulação. O índice **IAF (c)** subestimou com área estimada de 17,55 ha, baixa percentual de -78,60% com pequena distinção entre as áreas de plantio e as vias de acesso entre os talhões.

Figura 21 – Área estimada colhida para o talhão C2-03 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)




A Figura 22 com o talhão G10-02 possui uma área de 76,29 ha, a variedade implantada é a M8808IPRO de ciclo médio (CM). A área estimada colhida no talhão foi superestimada comparada aos resultados obtidos em campo da colheita com 68,50 ha no índice **SAVI (a)** com 71,10 ha com acréscimo de 3,80%. E o índice **NDVI (b)** foi menor que a área colhida com 67,50 ha, baixa percentual de -1,46%, com distinção entre as áreas de plantio e as vias de circulação na parte central em ambos os índices. O índice **IAF (c)** subestimou com área estimada de 26,91 ha, baixa percentual de -60,72%, mas com boa distinção entre as áreas de plantio e as vias de acesso entre os talhões.

Figura 22 – Área estimada colhida para o talhão G10-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



A Figura 23 com o talhão G12-02 possui uma área de 89,17 ha, a variedade implantada é a M8808IPRO de ciclo médio (CM). A área estimada colhida no talhão foi superestimada comparada aos resultados obtidos em campo da colheita com 83,20 ha no índice **SAVI (a)** com 85,50 ha com acréscimo de 3,80%. E o índice **NDVI (b)** foi menor que a área colhida com 67,50 ha, baixa percentual de -1,46%, com distinção entre as áreas de plantio e as vias de circulação na parte central em ambos os índices. O índice **IAF (c)** subestimou com área estimada de 49,45 ha, baixa percentual de -40,56%, mas com boa distinção entre as áreas de plantio e as vias de acesso entre os talhões.

Figura 23 – Área estimada colhida para o talhão G12-02 determinada pelos índices SAVI (a), NDVI (b) e IAF (c)



5.2.1 Análise estatística ciclo médio

A Tabela 07 mostra os dados estimados por meio dos índices NDVI, SAVI e IAF de área colhida para o ano de 2016 que foram tabulados em planilha Excel com os resultados separados por talhões para as variedades de ciclo médio, ano de 2016.

Tabela 07 – Áreas colhida e estimadas a partir do NDVI, IAF e SAVI – ciclo médio 2016.


VARIETADE	GM	TALHÃO	NDVI	IAF	SAVI	ÁREA COLHIDA
M8808IPRO	CM	B2-3	81,45	54,36	90,00	86,00
M8808IPRO	CM	C2-3	78,39	22,68	94,50	82,00
M8808IPRO	CM	G10-2	62,82	32,58	67,23	68,50
M8808IPRO	CM	G12-2	80,10	55,98	83,70	83,20

Nas variedades de ciclo médio com 04 talhões analisados no estudo, os coeficientes de determinação e de correlação onde o NDVI (Gráfico 04) obteve $R^2=0,9922$ e o $r(\text{Pearson}) 0,9961$. O SAVI (Gráfico 05) com valor de $R^2 0,69$ e $r(\text{Pearson}) 0,89$.

O Gráfico 04 traz os resultados da análise regressão representada através do coeficiente de determinação (R^2) e o coeficiente de correlação de Pearson (R), com resultados não significativos a 5% ($p>0,05$) nas condições do projeto e mediante o uso do


índice SAVI com R^2 0,0034 e R igual a 0,0585 em relação as áreas colhidas em campo pela colheitadeira. A análise estatística foi realizada com as variedades de ciclo médio no ano de 2016 obtidos através do software SigmaPlot versão 12.0.

Gráfico 04 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice SAVI para variedades de ciclo médio (CM) ano de 2016




O Gráfico 05 expõe os resultados da análise regressão representada através do coeficiente de determinação (R^2) e o coeficiente de correlação de Pearson (R), com resultados significativos a 5% ($p < 0,05$) conforme as características da área de estudo mediante o uso do índice NDVI com R^2 0,7523 e R igual a 0,8673 com crescimento linear conforme o aumento do índice NDVI, em relação as áreas colhidas obtidas em campo.

Gráfico 05 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice NDVI para variedades de ciclo médio (CM) ano de 2016



O Gráfico 06 expõe os resultados da análise regressão representada através do coeficiente de determinação (R^2) e o coeficiente de correlação de Pearson (R), com resultados não significativos a 5% ($p < 0,05$) conforme as características da área de estudo mediante o uso do índice IAF com R^2 0,3421 e R igual a 0,5849 com um crescimento linear conforme o aumento do índice IAF, em relação as áreas colhidas obtidas em campo.

Gráfico 06 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice IAF para variedades de ciclo médio (CM) ano de 2016



As análises estatísticas dos talhões de 2016 com variedade de ciclo curto e médio demonstraram que o melhor comportamento espectral comparado as informações da área colhida em campo é o índice NDVI com $R^2 = 0,82$ e $R = 0,90$ com resultados significativos a 5% com $p < 0,05$ para variedades de ciclo curto e $R^2 = 0,75$ e $R = 0,86$ resultados significativos a 5% com $p < 0,05$ para variedades de ciclo médio.

A análise dos valores estimados que representam o NDVI, de forma geral, indicam na maioria dos talhões superestimação das áreas plantada, mas com valores bem próximo ao realizado na colheita sendo abaixo de 20% nos talhões: E4-02, E6-02 e I9-02 com a variedade de ciclo curto M8210IPRO e os talhões G10-2 e G12-02 com a variedade de ciclo médio M8808IPRO. A análise visual dos rasters claramente mostra que há pouca distinção entre as áreas de plantio havendo mistura espectral com as áreas que representam os acessos entre os talhões com solo exposto.

O índice SAVI apresentou resultados para os talhões com variedades de ciclo curto com $R^2 = 0,68$ e $R = 0,82$, significativos a 5% com $p < 0,05$ e os talhões com a variedade de ciclo médio com $R^2 = 0,0034$ e $R = 0,0585$, resultados não significativos a 5% com $p > 0,05$.

A análise dos valores estimados que representam o SAVI, de forma geral, indicam na maioria dos talhões superestimação da área plantada, assim como no NDVI, mas com valores bem próximo ao realizado na colheita sendo abaixo de 20% nos talhões: I11-02, E6-02 e I9-02 com a variedade de ciclo curto M8210IPRO e os talhões G10-2 e G12-02 com a variedade de ciclo médio M8808IPRO.

A análise visual dos rasters claramente mostra que há pouca distinção entre as áreas de plantio estimadas com o índice SAVI havendo mistura espectral com as áreas que representam os acessos entre os talhões com solo exposto, igualmente ao NDVI. Os talhões A7-03 com a variedade de ciclo curto ST860RR e o C2-3 com a variedade de ciclo médio M8808IPRO não apresentaram nenhum resultado de área de plantio.

O índice IAF apresentou resultados significativos para os talhões com variedades de ciclo curto com $R^2 = 0,34$ e $R = 0,58$, resultados significativos a 5% com $p < 0,05$ e para a variedade de ciclo médio com $R^2 = 0,24$ e $R = 0,49$, resultados não significativos a 5% com $p > 0,05$. Todos os valores de estimativa com o IAF foram subestimados com exceção do talhão B7-03 com a variedade de ciclo curto ST860RR.

Vale ressaltar todos os índices de vegetação foram reclassificados a partir dos pixels maiores que 0,30 com os resultados sendo considerados as estimativas das áreas colhidas para todos os índices de vegetação. Segundo Beneditti; Querino et al., (2015). Desta forma, de maneira geral, quanto menor o IAF, maior os valores de radiância na região do visível e no infravermelho médio e menor na região do infravermelho próximo.

Na análise visual dos rasters que representam o índice IAF, apesar de subestimados, houve melhor distinção entre as áreas de plantio e os acessos entre elas. Os talhões A10-03, I11-02 (M8210IPRO) e A12-03 (M8349IPRO) com variedades de ciclo curto não apresentaram nenhum resultado de área de plantio.

Segundo Silva, (2009) o mapeamento das áreas de soja em baixa escala não torna possível a separação das áreas, destacando a necessidade da validação das informações em campo, com a elaboração de matriz de erro para determinação do nível de confiança do mapeamento. No estudo realizado, não houve a possibilidade da constatação dos motivos das discrepâncias.

Para os autores Berka; Rudorff, (2003) a estimativa realizada com imagens do Landsat 05 e 07 subestimou em 2,4% a relação entre aos dados fornecidos pelo órgão responsável do Estado do Paraná, com as suspeitas de que as imagens tenham subestimado significativamente a área dos plantios de soja tardia que ainda não se apresentavam de forma típica nas imagens, podendo ser confundidas com áreas de pousio ou solo exposto.

Na área do projeto Formoso observou-se grandes irregularidades nos talhões com desuniformidade quanto às diferenças topográficas existentes, tipos de solos variados e ainda segundo relatos de algumas falhas no sistema de irrigação. Além disso, o ano de 2016 apresentou grande instabilidade climática com variações de temperatura e precipitações, o que possivelmente interferiu nas estimativas do IAF que estabelece uma relação funcional entre a área foliar e a área do terreno ocupada pela variedades (WATSON, 1952).

O índice de vegetação por diferença normalizada (NDVI) é o índice mais amplamente utilizado por ser qualitativamente relacionado com vários parâmetros da cobertura vegetal, como índice de área foliar (IAF), fração de cobertura vegetal, radiação fotossintética ativa (PAR), biomassa verde (ASRAR; KANEMASU; YOSHIDA, 1985). Também é sensível a fatores externos como o “solo de fundo” e a geometria de visada e solar, bem como as condições atmosféricas. As influências externas são mais intensas no caso de superfícies esparsamente distribuídas.

Em estudo desenvolvido em Santa Cruz do Rio Pardo (SP) o NDVI aumentou a área cultivada com cana-de-açúcar, de 22,3 % para 29,0 %, e variação muito pequena na área cultivada com variedades anuais (26,3 % a 24,2 %). Também no NDVI, as áreas ocupadas por soja no início da floração, de aspecto verde amarelado, foram substituídas por solo exposto (DEMARCHI; PIROLI; ZIMBACK, 2011). Isso pode possivelmente justificar a homogeneização das áreas de plantio sem destacar os acessos entre os talhões no Projeto Formoso. Segundo (DEMARCHI; PIROLI; ZIMBACK, 2011), o Índice de Vegetação por Diferença Normalizada (NDVI) apresentou para as culturas anuais, classe de intervalo de NDVI 0,2 a <0,4. No projeto Formoso em Formoso do Araguaia -TO, objeto desse estudo, a estimativa de área plantada estabeleceu-se pela lógica *fuzzy* com a opção pelo máximo de vigor na junção dos índices no período da entressafra e em seguida houve uma reclassificação em busca de índices maiores que 0,30 tanto para IAF, NDVI e SAVI.

O índice de vegetação ajustado ao solo (SAVI) pode ser ajustado por intermédio de fator de ajuste para o substrato do doce variando de 0,0 a 1,0, normalmente utilizado para áreas de vegetação densa. No Projeto Formoso, o fator utilizado é de 0,5 recomendado para cobertura vegetal com densidade média.

Segundo Esquerdo; Junior; Antunes, (2009) em estudo comparativo com as imagens do NOAA e as produtividades obtidas no Paraná, nas correlações entre a produtividades da soja e o NDVI chegou a coeficiente de determinação dentre 0,61 e 0,70 respectivamente e com antecedência da colheita esses índices foram menos significativos.

Essa realidade ocorreu no presente estudo estando relacionado ao atraso na colheita devido às diferenças de temperatura que ocasionaram uma maturação desuniforme das sementes. A realidade desse estudo desenvolvido pode haver algumas inconsistências em alguns dados coletados, bem como a necessidade de uma maior amostragem no interior dos talhões.

No fatiamento, as imagens NDVI e SAVI são suficientes para a avaliação da aplicação desses índices, mas agrupa alvos diferentes, de respostas espectrais próximas, na mesma classe (DEMARCHI; PIROLI; ZIMBACK, 2011).

Segundo Vanzela; Braz et al., (2015) na obtenção de produtividades de variedades diferentes de cana-de-açúcar, também obteve resultados diferentes coeficiente de determinação entre 0,02 e 0,21 ($p > 0,05$) e 0,9377 ($p < 0,01$).

Na estimativa da produtividade da soja no Rio Grande do Sul, o produto IAF apresentou valores inválidos para a soja em toda fase, de máximo desenvolvimento da cultura o que inviabilizou a estimativa (RIZZI, 2005).

Em estudo desenvolvido no Rio Grande Sul em área de soja, na estimativa de área plantada com as imagens obtidas do Landsat e MODIS subestimaram as áreas. Isso pode ser explicada pela resolução espacial das imagens MODIS em que pequenas áreas de soja vizinhas, podendo ter sido agregadas a uma grande área de soja no mapeamento. Diante desse resultado, compreende-se que a subestimativa das áreas pode ter ocorrido pela presença de pequenas áreas de soja que não podem ser detectadas pelo sensor MODIS, em virtude da resolução espacial das imagens de 250 m, e que também por não apresentar padrão de agregação espacial (SANTOS; GEHARDT; FONTANA, 2009).

Baseando-se em Santos; Gehardt; Fontana, (2009) obtiveram para a maioria dos métodos os valores do coeficiente de determinação (R^2) superiores a 0,85. Resultados semelhantes a esses, também, foram encontrados por autores que estimaram, a partir de diferentes métodos, a área cultivada com soja na mesma região de estudo.

5.3 Estimativa da produtividade para o ano de 2017

Antes processo de interpolação foi realizada uma análise preliminar com as 140 amostras anteriormente a interpolação dos dados verificando a distribuição através do histograma.

A Tabela 08 traz os resultados após a realização de vários testes e aplicação de vários outros modelos com as amostras de produtividade e a escolha do método Gaussiano que demonstrou melhor disposição dos dados, tendo em vista, o menor erro (*Major range*), após essa etapa procedeu-se a execução da Krigagem ordinária no software ArcGIS 10.6 através ferramenta *Geoestatistical Analyst*.

Tabela 08 – Análise exploratória dos dados de produtividade obtidos em campo no ano de 2017

<u>Parâmetros</u>	<u>Valores</u>
Mensurement Error	100
Nugget	9761,31
Major range	900
Partial still	5415
Large size	12,46
Number of lags	12

A Tabela 09 mostra os resultados do processo da Krigagem realizada para as 140 amostras de produtividade com os valores da média padronizada igual a 0,003, sendo que, quanto mais próximo do zero, menor erro apresentado e o valor do quadrado médio padronizado que com valor de 0,98 demonstrou eficiência para prever os valores em relação aos medidos estando próximo de 1,0. A análise realizada demonstrou que existe uma correlação entre os valores de produtividade medidos e os valores previstos ao final do processo da Krigagem Ordinária.

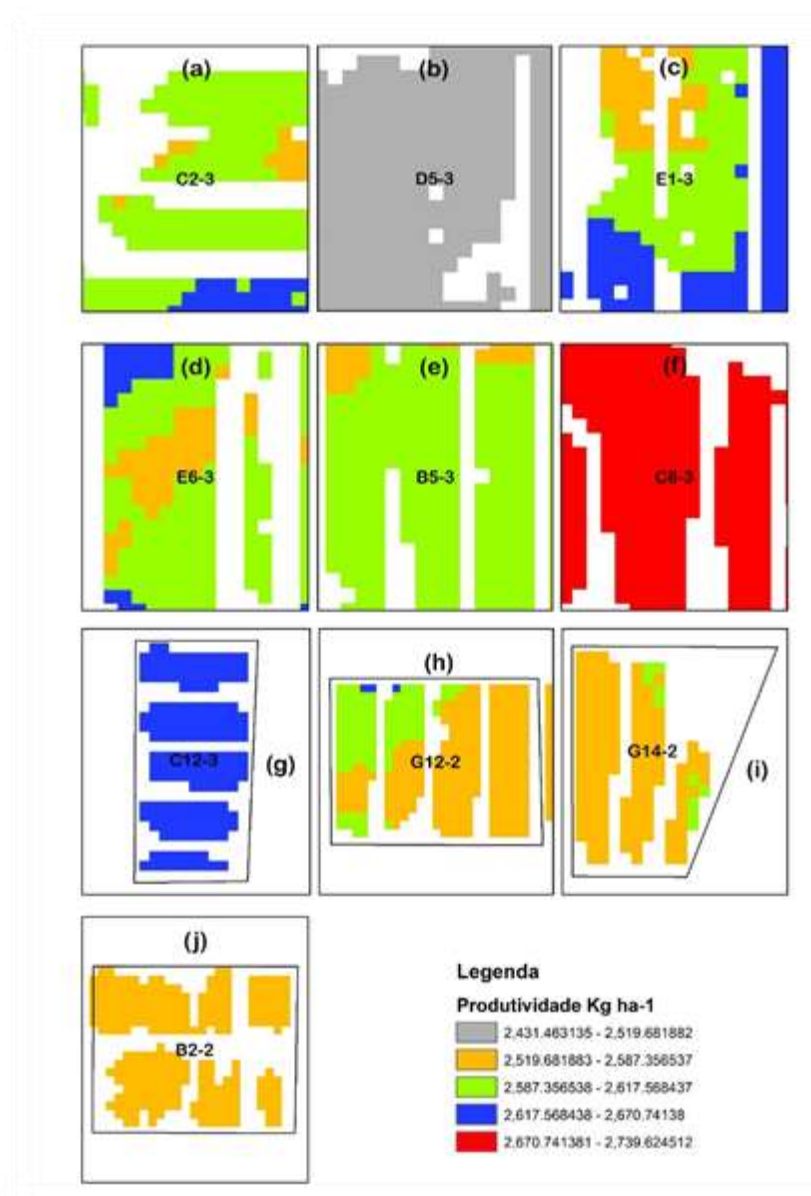
Tabela 09 – Valores da validação cruzada para os dados de produtividade para finalização do processo de Krigagem ordinária

Parâmetros	Valores
Função de regressão (<i>Regression function</i>)	$0.1580 * x + 2188.9309$
Média (<i>Mean</i>);	0.0693
Valor do quadrado médio (<i>Root Mean Square</i>)	106.0267
Média padronizada (<i>Mean Standardized</i>)	0.0003;
Valor do quadrado médio padronizado (<i>Root Mean Square Standardized</i>)	0.9851
Erro padrão médio (<i>Average Standard Error</i>)	109.7112.

A Figura 24 é o resultado do processo de Krigagem com a apresentação de um mapa de previsão que resultou na espacialização para toda área, inclusive as áreas de outros talhões que não fazem parte do estudo, assim como estradas de acesso e áreas alagadas. Devido a isso, foi realizado o recorte do raster no software Arc Gis 10.6 com a representação das informações dos talhões do presente estudo e apenas nas áreas de plantio excluindo áreas de acesso.

O resultado das produtividades entre os 10 talhões apresentados na Figura 30 variaram com valores variando entre 2.431 kg ha^{-1} e 2.739 ha^{-1} para a variedade M8644IPRO (variedade de ciclo curto) implantada nos talhões. O talhão C8-03 (f) apresentou o maior valor de produtividade entre os talhões e o talhão D5-03 (b) com a menor produtividade entre os talhões plantados em 2017 pela empresa Talismã. Segundo relatos da empresa, a desuniformidade existente entre os talhões promove essa diferenciação existente nas produtividades.


Figura 24 – Produtividade estimada para variedade M8644IPRO (CC), para os talhões com plantio do ano 2017



Após esta etapa, o próximo passo foi obter os valores de NDVI a nível do pixel sobreposto pelo ponto georreferenciado com os dados de produtividade das 140 amostras com o uso da ferramenta *Point sample tool* do programa QGIS 2.18.12. Os dados foram tabulados em planilha e correlacionados por meio do programa estatístico SigmaPlot 12.0.

O Gráfico 07 apresenta os resultados da análise estatística entre os dados do NDVI e as produtividades dispostos em um gráfico de dispersão e o resultado da função de regressão linear para estimar a produtividade em relação ao NDVI, com o valor do coeficiente de determinação (R^2) igual a 0,70 e o coeficiente de correlação de Pearson (R) igual a 0,84.

Gráfico 07 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre as áreas colhidas e estimadas pelo índice IAF para variedades de ciclo médio (CM) ano de 2016



Os resultados da análise estatística demonstraram uma boa representação do comportamento dos dados, uma vez que seus valores de R^2 0,70 estão bem próximos a 1, indicando que a medida descritiva da qualidade do ajuste está satisfatória (SANTOS; FRANCO et al, 2017) O coeficiente de determinação (R^2) mensura a variação dos dados de acordo com o modelo ajustado em relação à variação total dos dados e quanto mais próximo de 1 (um) estiver o valor de R^2 melhor será o ajuste do modelo.

Em estudo com imagens empregando dados de máximo NDVI semanais, oriundos de imagens NOAA/AVHRR com resolução espacial degradada para 15 x 15 km, em um modelo agrometeorológico-espectral visando estimar a produtividade da cultura da soja no Estado do Rio Grande do Sul. Os autores afirmam que este modelo explicou 55,2% da variação da produtividade, contra 54% do modelo sem a variável espectral. Mesmo tendo apresentado resultados muito próximos, a diferença entre a produtividade observada e estimada foi estatisticamente menor no modelo que inclui a variável espectral (FONTANA; BERLATO, 1998).

Em análise desenvolvida com dados operacionais de inventário florestal em Botucatu – SP, foi aplicada geoestatística para analisar a variabilidade espacial da produtividade e da qualidade de plantações florestais comerciais. Os parâmetros variográficos foram utilizados para elaborar mapas geoestatísticos (krigagem ordinária), com o uso do programa ArcMap v.9.2. Os semivariogramas experimentais foram melhores representados pelo semivariograma, sendo ajuste dos modelos com resultados (R^2) próximo de 1,0 com o valor de 0,98 (ALVARES; GONÇALVES et al., 2009).

Coefficiente de correlação de Pearson (R) indica a intensidade da associação linear existente entre as variáveis através da divisão entre os valores reais sobre os preditos (ou estimados), seu índice varia de -1 (menos um) a 1 (um) (SOUZA, 2016). O Coeficiente de Determinação (R^2), que mensura a variação dos dados de acordo com o modelo ajustado em relação à variação total dos dados e quanto mais próximo de 1 (um) estiver o valor de R^2 melhor será o ajuste do modelo (BIASE; SANTANA, 2012).

Em experimento realizado a nível de talhão entre os anos de 2006 e 2007 para estimar soja no estado do Rio Grande do Sul, foram obtidos índice de vegetação da diferença normalizada do verde (GNDVI) em imagens CBERS 2 com o valor de R^2 igual 0,34 aos 47 dias 0,45 aos 73 dias. Fernandes; Veiverberg; Elódio, (2009) no presente estudo o valor de R^2 é igual a 0,7 na correlação entre o NDVI e as produtividades de 140 pontos nos talhões no ano de 2017 com a aplicação da krigagem que trouxe o mapa de previsão com as estimativas de produtividade para as áreas dos talhões individualmente.

5.4 Teor de óleo

As sementes de soja foram coletadas em campo no dia 29 de agosto de 2017 com 98 dias após a semeadura (DAS) no estágio R7, onde as sementes encontravam-se totalmente desenvolvidas iniciando o processo de maturação (FEHR; CAVINESS, 1977). Nesse caso, a realização da colheita das amostras antes da colheita do talhão não comprometeu o teor de óleo por estar em R7 porque a semente já estava desenvolvida. Segundo (DURIGAN; DURIGAN; CARVALHO, 1980) existe um período de intensa formação de óleo durante o ciclo o qual corresponderia a metade do período do florescimento e a maturação final das sementes. A colheita dessa foi realizada no dia 10 de setembro de 2017 com 111 dias após a semeadura (DAS), decisão tomada pelo gestor da empresa, por conta da alta umidade no talhão.

A Tabela 10 expõe os resultados do processo de extração do óleo obtidos conforme o método de (BLIGH; DYER, 1959) em 64 amostras sendo que 36 não

apresentaram resultados satisfatórios com um total de 28 amostras com resultados de teor de óleo do talhão E1-03, variedade M8644IPRO de ciclo médio GMR 8,6.


Tabela 10 – Amostragem de teor de óleo realizada em campo – Talhão E1-03, ano 2017.

X	Y	AMOSTRAS	Teor de Óleo %
642282.42	8700348	E1_A45	15.47
641675.99	8700288	E1_A53	15.55
641579	8699954	E1_A54	15.60
641496	8700462	E1_A60	15.69
642130.75	8700275.8	E1_A62	16.23
641924.95	8700748.4	E1_A33	16.25
642251.14	8700121	E1_A63	16.35
641969.43	8699848.8	E1_A22	16.41
641689.34	8699819.4	E1_A50	16.78
641996.62	8700173.5	E1_A37	16.80
642176.03	8700391.1	E1_A42	17.24
642255.02	8700023.5	E1_A48	17.38
642009.4	8699945.8	E1_A51	17.53
641572.43	8700464.6	E1_A10	17.65
641689	8700118	E1_A57	17.82
642056.68	8699834.9	E1_A6	17.90
641622.66	8699970.1	E1_A2	18.37
641993.3	8700707	E1_A14	18.65
641712	8700471	E1_A58	19.35
641534.75	8699893.5	E1_A18	19.44
641703.97	8699966.4	E1_A9	20.03
641649.19	8700126.1	E1_A44	20.31
641551.12	8700131.5	E1_A23	20.90
641334	8699794	E1_A55	22.78
641505.72	8700088.8	E1_A28	23.31
641401.93	8700059.3	E1_A47	23.94
641718.25	8699947.9	E1_A43	24.93

A Figura 25 apresenta os dados de teor de óleo que foram tabulados e interpolados utilizando o software ArcGIS 10.6 com a análise exploratória e a verificação da

normalidade e a tendência dos dados através do histograma não houve nenhuma transformação.

Figura 25 – Histograma com a representação da análise das 28 amostras de teor de óleo amostradas no talhão E1-03



A Tabela 11 traz os resultados após a realização de vários testes e aplicação de vários outros modelos nas amostras de teor de óleo e a escolha do método Exponencial que demonstrou melhor disposição dos dados, tendo em vista, o menor erro (*Major range*), após essa etapa procedeu-se a execução da Krigagem ordinária no software ArcGIS 10.6 através ferramenta *Geostatistical Analyst*.

Tabela 11 – Análise exploratória dos dados de teor de óleo obtidos em campo no ano de 2017

<u>Parâmetros</u>	<u>Valores</u>
Masurement Error	100
Nugget	10.68
Major range	90
Partial sill	0,00
Large size	24
Number of lags	14

A Tabela 12 mostra os resultados do processo da Krigagem realizada para as 28 amostras de teor de óleo com os valores da média padronizada igual a -0,0488, sendo que, quanto mais próximo do zero, menor erro apresentado e o valor do quadrado médio padronizado que com valor de 0,8946 o que demonstrou eficiência para prever os valores em relação aos medidos estando próximo de 1,0. A análise realizada demonstrou que existe uma correlação entre os valores de teor de óleo medidos e os valores previstos ao final do processo da Krigagem Ordinária.

Tabela 12 – Valores da validação cruzada para os dados de teor de óleo para finalização do processo de Krigagem ordinária

Parâmetros	Valores
Função de regressão (<i>Regression function</i>)	$0.2169 * x + 14.2969$
Média (<i>Mean</i>);	-0,1661
Valor do quadrado médio (<i>Root Mean Square</i>)	3,1458
Média padronizada (<i>Mean Standardized</i>)	-0,0488
Valor do quadrado médio padronizado (<i>Root Mean Square Standardized</i>)	0,8946
Erro padrão médio (<i>Average Standard Error</i>)	3,5286

Estudo realizado em Uberaba (MG) alcançou teores médio de óleo nos grãos de 16,75%, sendo o maior teor médio encontrado na linhagem UFU-101 (21,59%), que não diferiu estatisticamente das linhagens UFU-106, UFU-115, UFU-118, UFU-117 e das cultivares MSOY 8008 e MSOY 8000. Por outro lado, o menor teor médio foi encontrado na linhagem UFU-109 (13,51%) (CAVALCANTE; SOUSA; HAMAWAKI, 2011).

Também em Minas Gerais na cidade de Frutal, dados semelhantes foram obtidos durante a avaliação de 15 genótipos de soja, cuja a média de teor de óleo de 16,01%, variando de 13,01% a 20,12%. (FINOTO; SEDIYAMA et al., 2008).

Ao caracterizar bioquimicamente duas linhagens de soja com alto teor de proteína, oriundas do Programa de Melhoramento Genético do Bioagro/UFV, observaram uma variação no teor de óleo de 18,56% a 24,03% (MORAES; JOSÉ et al, 2006).

Em experimento conduzido em Palmas TO, foi possível alcançar na análise de variância das características teor de óleo (%) em 15 cultivares de soja, um valor médio de 20,43%, nas vagens na haste das plantas localizadas na parte superior, entre os anos agrícolas 2011/12 e 2012/13. No presente estudo o valor médio é de 16% (SALES, 2014).

O percentual de óleo na semente de soja está em torno de 20%, podendo variar entre 13 e 28% (SEDIYAMA, 2009). O teor de óleo das sementes de soja é o resultado da interação cultivar e época de semeadura em função da temperatura durante o

desenvolvimento das sementes. De forma geral, a soja apresenta teor de óleo mais elevado quando é cultivada em ambientes mais quentes (BARROS; SEDIYAMA, 2009).

A relação entre o teor de óleo e a produtividade é positiva, o que torna possível manter a produtividade quando se pratica a seleção para alto teor de óleo. No entanto, o aumento no potencial produtivo ou no teor de óleo pode causar redução no teor de proteína, o que também traz dificuldades ao melhoramento (RODRIGUES; ARRUDA, *et al.*, 2013).

5.5 Temperatura

A Tabela 16 informa sobre os dados de temperatura coletados em campo junto as plantas que foram destinadas ao laboratório para obtenção do teor de óleo. A temperatura foi registrada com termômetro infravermelho na altura do dossel e na metade (1/2) da altura da planta e com termômetro digital a temperatura do solo.


Tabela 13 – Temperaturas coletadas em campo no talhão E1-03 na altura do dossel, na 1/2 da planta e no solo, ano de 2017.

AMOSTRAS	Solo °C	Dossel °C	1/2 °C	Média °C
E1_A2	28	34.6	25.5	28
E1_A3	25	27.8	0	25
E1_A10	28	33.5	31.3	31.3
E1_A13	29	40.5	33.3	33.3
E1_A16	25	29.7	28.2	28.2
E1_A17	24	27.7	29.4	27.7
E1_A19	24	29.7	29.6	29.6
E1_A21	27	29.6	31	29.6
E1_A23	29	36.2	33.9	33.9
E1_A24	25	30	28.7	28.7
E1_A25	25	28.2	26.6	26.6
E1_A28	28	37	39.4	37
E1_A29	25	30	27.4	27.4
E1_A31	24	28	29	28
E1_A32	24	29.6	28.6	28.6
E1_A33	25	31.4	32.9	31.4
E1_A35	26	23.3	30.8	26
E1_A37	24	32.4	31.1	31.1
E1_A39	26	30	36	30
E1_A40	24	31	30.9	30.9
E1_A41	29	29.6	32.3	29.6

AMOSTRAS	Solo °C	Dossel °C	1/2 °C	Média °C
E1_A42	24	32.5	29.9	29.9
E1_A43	28	39.5	41.3	39.5
E1_A44	26	36.1	35.7	35.7
E1_A46	26	30.9	35.6	30.9
E1_A47	27	37.9	36.2	36.2
E1_A48	25	32.9	33.3	32.9
E1_A49	25	30	28	28
E1_A50	27	32.2	42.3	32.2
E1_A51	25	32.9	33.3	32.9
E1_A52	24	30.1	28.4	28.4
E1_A55	28	36.7	37	36.7
E1_A56	27	29.7	33.8	29.7
E1_A61	28	30.5	30.2	30.2
E1_A62	27	31.3	29.8	29.8

A Figura 26 apresenta os dados temperatura do dossel com a análise da verificação quanto a normalidade e a tendência dos dados através do histograma com valores de média (34,13) e mediana (33,6) bem próximos e que apresentaram melhor simetria nas classes de frequência. Os dados foram interpolados utilizando o software ArcGIS 10.6 não havendo a necessidade de proceder com nenhuma transformação dos dados tendo em vista de sua distribuição normal.

Figura 26 – Histograma com a representação da análise das 35 amostras de temperatura do dossel amostradas no talhão E1-03



A Tabela 14 traz os resultados após a realização de vários testes e aplicação de vários outros modelos nas amostras de temperatura do dossel e a escolha do método Gaussiano que demonstrou melhor disposição dos dados, tendo em vista, o menor erro (*Major range*), após essa etapa procedeu-se a execução da Krigagem ordinária no software ArcGIS 10.6 através ferramenta *Geoestatistical Analyst*.

Tabela 14 – Análise exploratória dos dados de temperatura do dossel obtidos em campo no ano de 2017

<u>Parâmetros</u>	<u>Valores</u>
Mensurement Error	100
Nugget	6,65
Major range	10
Partial sill	0,0
Large size	30,37
Number of lags	12

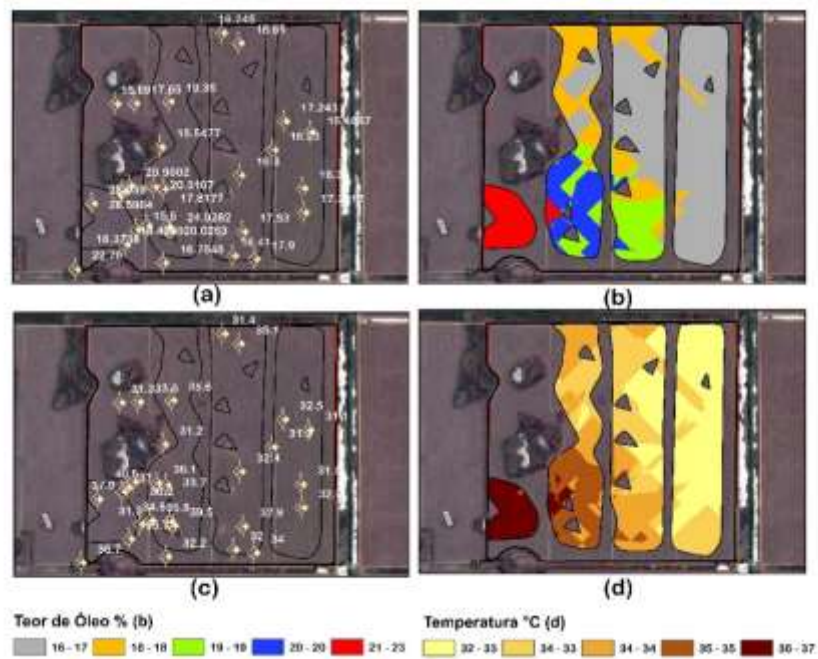
A Tabela 15 mostra os resultados do processo da Krigagem realizada para as amostras de temperatura do solo com os valores da média padronizada igual a -0,0206, sendo que, quanto mais próximo do zero, menor erro apresentado e o valor do quadrado médio padronizado que com valor de 0,9989 que demonstrou a eficiência para prever os valores em relação aos medidos estando próximo de 1,0. A análise realizada demonstrou que existe uma correlação entre os valores de temperatura de dossel medidos e os valores previstos ao final do processo da Krigagem Ordinária.

Tabela 15 – Valores da validação cruzada para os dados de temperatura do dossel para finalização do processo de Krigagem ordinária

<u>Parâmetros</u>	<u>Valores</u>
Função de regressão (<i>Regression function</i>)	$0.2020 * x + 26.8836$
Média (<i>Mean</i>);	-0,1320
Valor do quadrado médio (<i>Root Mean Square</i>)	2,6118
Média padronizada (<i>Mean Standardized</i>)	-0,0488
Valor do quadrado médio padronizado (<i>Root Mean Square Standardized</i>)	0,9392
Erro padrão médio (<i>Average Standard Error</i>)	2,7857


A Figura 27 apresenta a espacialização do processo de Krigagem ordinária no Geostatistical Analyst Wizard no talhão E01-03. Os teores de óleo variaram entre 16% e 23% (b) mesmo sendo a mesma variedade, M8644IPRO (variedade de ciclo curto) e as temperaturas do solo entre 32°C e 37°C (d).

Figura 27 – Valores de teor de óleo (a) e a espacialização dos teores de óleo para o talhão E1-03 (b) e valores de temperatura do solo (c) e a espacialização das temperaturas para o talhão E01-03 (d), ano 2017



O Gráfico 08 apresenta os resultados da análise estatística entre os dados da temperatura do dossel e os teores de óleo obtidos em campo dispostos com o valor do coeficiente de determinação (R^2) igual a 0,9394 e o coeficiente de correlação de Pearson (R) igual a 0,9692.

Gráfico 08 – Análise de regressão (R^2) e determinação da correlação de Pearson (R) entre os teores de óleo coletados em campo e as temperaturas do dossel



5.6 Rendimento de óleo

O cálculo do rendimento do óleo é dado em função da produtividade, ou seja, o produto entre a produtividade e o teor de óleo (Produtividade X Teor de Óleo X 100). A estimativa de rendimento para as áreas plantadas com a variedade M8644IPRO (variedade de ciclo curto) foi realizada com a aplicação da função de regressão dada pela correlação entre a temperatura do solo e o teor do óleo amostrado no talhão E01-03 com valores de $R = 0,9692$ (moderado) e $R^2 = 0,9394$.

A temperatura para os talhões de 2017 foi estimada por meio das imagens de satélite Landsat 08, bandas 10 e 11 inseridas no período entre o plantio e a colheita dos talhões e classificada através da lógica *fuzzy*. O cálculo para realização da estimativa foi realizado na ferramenta *Raster Calculator* do programa ArcGIS® 10.6 por meio da função de regressão obtido na análise estatística de correlação de Pearson dada pela equação:

$$y = -22,0854 + 1,1985 * x$$

Sendo:

$Y = \text{Teor de óleo } \%$

$X = \text{Temperatura } ^\circ\text{C}$


A Tabela 16 apresenta os dados de temperatura obtidos a partir das imagens Landsat 08 para período da entressafra em 2017 (junho a outubro) com um total de 07 imagens que foram reclassificadas pela lógica *fuzzy* e representadas em 05 classes com faixas determinadas para cada classe. As classes foram reclassificadas para valores únicos por meio da ferramenta *Reclassify* do software Arc Gis 10.6.

Tabela 16 – Reclassificação da temperatura dos talhões para valores únicos

Classes	Reclassificação °C
31 - 35	31
36 - 37	37
38	38
39	39
40	40

A Figura 28 apresenta os resultados da inclusão do raster temperatura obtido por meio das imagens Landsat 08 para o ano de 2017 que foi reclassificado e inserido como variável na função de regressão obtida para o rendimento de óleo como valor de “X”. O resultado para função de regressão apresentou dados estimados de teor de óleo para os talhões de 2017.

Figura 28 – Estimativa do teor de óleo para os talhões plantados em 2017 a partir das imagens Landsat 08 e o teor de óleo obtido para o talhão E1-03 para o ano de 2107



A Tabela 17 apresenta os dados de teor de óleo obtido a partir dos raster de temperatura obtidos por meio das imagens e representadas em 04 classes com faixas determinadas para cada classe. As classes também foram reclassificadas para valores únicos por meio da ferramenta Reclassify do software Arc Gis 10.6.

Tabela 17 – Reclassificação dos teores de óleo estimado para os talhões em valores únicos

Classes	Teor de óleo %
15	15
16 - 22	22
23	23
24 - 25	25
26	26

A Tabela 18 apresenta os dados de produtividade estimados para os talhões com plantio da variedade M8644IPRO em 2017 por meio dos dados fornecidos pela empresa e que foram representados em 05 classes com faixas determinadas para cada classe. As classes também foram reclassificadas para valores únicos por meio da ferramenta Reclassify do software Arc Gis 10.6.

Tabela 18 – Reclassificação das produtividades estimadas para os talhões em 2017 para valores únicos

Classes	Reclassificação Kg ha⁻¹
2,431.463135 - 2,519.681882	2431
2,519.681883 - 2,587.356537	2519
2,587.356538 - 2,617.568437	2587
2,617.568438 - 2,670.74138	2617
2,670.741381 - 2,739.624512	2739

A Figura 29 resultou na estimativa de rendimento de óleo para os talhões de 2017 foi obtido pelo produto entre o raster classificado da produtividade estimada para o ano de 2017 e o raster classificado do teor de óleo estimado também para o ano de 2017 dado pela fórmula:

$$Rend_{\text{óleo}} = prod \times Teor \text{ de óleo} \times 100$$


Sendo:

prod = produtividade estimada por talhão;

Teor de óleo = teor de óleo resultado da função de regressão.

Os valores variaram entre 380 e 710 Kg/ha e o teor de óleo variou entre 15% e 26% bem aproximados aos estudos apresentados por (FNP, 2005) que traz os valores de teor de óleo no grão é em torno de 18%, correspondendo, em média, a 600 Kg de óleo por hectare. Acredita-se que houve uma superestimativa devido a amostragem com 35 valores de teor de óleo ter sido realizada em apenas 01 talhão, pois não foi possível a amostragem nos 10 talhões onde houve plantio em 2017.

Figura 29 – Estimativa de rendimento de óleo para os talhões plantados em 2017 a partir do teor de óleo estimado e a produtividade estimada para o ano de 2017



6. CONCLUSÃO

Na análise entre os índices de vegetação para estimativa da área colhida em 2016 o que se sobressaiu nos resultados estatístico ao nível de significância $p < 0,05$ foi o índice de vegetação por diferença normalizada (NDVI), com valor do coeficiente de determinação (R^2) igual a 0,75 e coeficiente de correlação de Pearson (r) igual a 0,86 para variedades de ciclo curto (CC). As variedades de ciclo médio (CM) com coeficiente de determinação (R^2) igual 0,82 e coeficiente de correlação de Pearson (r) igual a 0,90.

O índice SAVI apresentou resultados estatísticos ao nível de significância $p < 0,05$ para as variedades ciclo curto (CC) com coeficiente de determinação (R^2) igual 0,68 e coeficiente de determinação de Pearson (r) igual a 0,82 e resultados estatísticos não significativos ao nível de significância $p > 0,05$ com coeficiente de determinação (R^2) igual a 0,0034 e coeficiente de determinação de Pearson (r) igual 0,0585.

O IAF apresentou resultados estatísticos ao nível de significância $p < 0,05$ para as variedades ciclo curto com coeficiente de determinação (R^2) igual a 0,34 e coeficiente de determinação de Pearson (r) igual a 0,58 e resultados estatísticos não significativos ao nível de significância $p > 0,05$ para variedades de ciclo médio (CM) com coeficiente de determinação (R^2) igual 0,24 e coeficiente de determinação de Pearson (r) igual a 0,49, mas com boa distinção entre as áreas de plantio e os acessos entre áreas comparados aos outros índices de vegetação.

Os dados de produtividade que foram amostrados na área em 2017 apresentaram bons resultados na aplicação da Krigagem ordinária e na correlação de Pearson entre os valores de produtividade e os valores médios do NDVI, com valores do coeficiente de determinação (R^2) = 0,70 e coeficiente de correlação de Pearson (r) = 0,84 com as produtividades variando entre 2431 kg ha⁻¹ e 2.739 kg ha.

Os dados de temperatura foram estimados para o talhão E1-03 em 2017 e apresentaram bons resultados na aplicação da Krigagem ordinária para as temperaturas obtidas em campo na altura do dossel com coeficiente de determinação (R^2) igual 0,9392 e temperaturas variando entre 32 e 37°C

Os teores de óleo foram estimados para o talhão E1-03 a partir da amostragem em campo com coeficiente de determinação (R^2) igual a 0,89 e ao final do processo correlacionado com as temperaturas do dossel com valores de coeficiente de determinação (R^2) igual a 0,93 e coeficiente de correlação de Pearson (r) igual 0,96 com valores de teor de óleo variando entre 15% e 26%.

A estimativa de rendimento de óleo para os talhões plantados em 2017 a partir do teor de óleo estimado em função da análise de regressão e a produtividade estimada para os talhões apresentaram bons resultados com a aplicação da metodologia variando entre 380 litros/ha e 710 litros/ha.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAPEC. adapec.to.gov.br. **Agente de Defesa Agropecuária do Tocantins**, 2017. Disponível em: <<https://adapec.to.gov.br/noticia/2017/4/24/plantio-de-sementes-nas-varzeas-tropicais-do-tocantins-esta-liberado/>>. Acesso em: 16 Abril 2018.

ALBRECHT, L. P. **Teores de óleo, proteínas e produtividade de soja em função da antecipação da semeadura na região oeste do Paraná**. Scielo, Campinas, p. 865-873, 2008. Disponível em: <<http://www.scielo.br/pdf/brag/v67n4/08.pdf>>.

ALBRECHT, L. P. et al. Scielo, 2008. Disponível em: <<http://www.scielo.br/pdf/brag/v67n4/08.pdf>>. Acesso em: 23 Maio 2018.

ALMEIDA, R. D.; PELUZIO, J. M.; AFFÉRI, F. S. **Divergência genética entre cultivares de soja, sob condições de várzea irrigada, no sul do estado do Tocantins**. Revista Ciência Agronômica, Fortaleza, v. 42, p. 108-115, jan-mar 2011. Disponível em: <<http://ccarevista.ufc.br/seer/index.php/ccarevista/article/view/1143/515>>. Acesso em: 15 maio 2018.

ALVARES, C. A. et al. **Geoestatística aplicada ao estudo da produtividade e qualidade de plantações florestais**. Simpósio de Geoestatística Aplicada a Ciências Agrárias, Botucatu - SP, 14-15 maio 2009. Disponível em: <https://www.researchgate.net/publication/301368376_Geoestatistica_Aplicada_ao_Estudo_da_Produtividade_e_Qualidade_de_Plantacoes_Florestais?enrichId=rgreq-dbf12263dc0133236d6a3122f182deaa-XXX&enrichSource=Y292ZXJQYWdlOzMwMTM2ODM3NjtBUzoZNTY1NTk4MDE2MDIwNDI>. Acesso em: 20 julho 2018.

ANP. anp.gov.br. **Agência Nacional do Petróleo, Gás Natural e Biocombustíveis**, 2016. Disponível em: <<http://www.anp.gov.br/biocombustiveis/biodiesel>>. Acesso em: 5 julho 2018.

ANP. anp.gov.br. **Agência Nacional do Petróleo, Gás Natural e Biocombustíveis**, 2017. Disponível em: <<http://www.anp.gov.br/publicacoes>>. Acesso em: 15 maio 2018.

ANTUNES, J. F. G. **Aplicação de Lógica Fuzzy**. Embrapa-Publicações, 2005. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/23664/1/35-42-1.pdf>>. Acesso em: 24 Maio 2018.

ASRAR, G.; KANEMASU, E. T.; YOSHIDA, M. **Estimates of leaf area index from spectral reflectance of wheat under different cultural practices and solar angle**. Remote Sensing of Environment, v. 17, n. 01, p. 01-11, 1985. Acesso em: 02 junho 2018.

ÁVILA, R. G. uft.edu. **Repositório Institucional - UFT**, 2013. Acesso em: 24 Maio 2018.

BAIER, W. **Note on the terminology of crop—weather models**. ScienceDirect, v. 20, n. 02, p. 137-145, abril 1979. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0002157179900323>>. Acesso em: 12 julho 2018.

BARBOSA, S. V. D. et al. **Comportamento de cultivares de soja, em diferentes épocas de semeaduras, visando produção de biocombustível**. Revista Ciência Agronômica, Fortaleza, v. 42, n. 3, p. 742-749, jul-set 2011.

BARROS, H. B.; SEDIYAMA, T. **Tecnologia de produção e usos da soja**. In: SEDIYAMA, T.; SILVA, F.; BORÉM, A. **Soja do plantio à colheita**. Viçosa: UFV, 2015. Cap. 03, p. 58-59.

BARROS, H. B.; SEDIYAMA, T. L. **Umidade e Temperatura**. In: SEDIYAMA, T. **Tecnologia de produção e uso da soja**. [S.l.]: Mecenas, 2009. p. 17-27.

BARROS, H. B.; TUNEO, S. Luz, **Umidade e Temperatura**. In: SEDIYAMA, T. **Tecnologias de produção e uso da soja**. Londrina, PR: Mecenas, 2009. p. 17-22.

BATISTA, G. T. et al. **Avaliação de produtos HRV/SPOT e TM/Landsat na discriminação de culturas**. Pesquisa Agropecuária Brasileira, Brasília, v. 25, n. 03, p. 379-386, março 1990. Disponível em: <<https://seer.sct.embrapa.br/index.php/pab/article/view/13418/7554>>. Acesso em: 11 julho 2018.

BAUER, M. E. et al. **Spectral properties of agricultural crops and soils measured from space, aerial field and laboratory sensors**. NTRS - Nasa Technical Reports Server, Hamburgo, 01 novembro 1981. 22. Disponível em: <<https://ntrs.nasa.gov/search.jsp?R=19820014749>>. Acesso em: 12 julho 2018.

BELLALOU, N.; GILLEN, A. M. **Soybean seed protein, oil, fatty acids, N, and S partitioning as affected by node position and cultivar differences**. Agricultura Sciences, 2010. Acesso em: 15 maio 2018.

BENEDITTI, C. A. et al. **Comparação do índice de área foliar (IAF) estimado por sensoriamento remoto entre os anos de 1984 e 2011 na região central de Rondônia**. ResearchGate, Rondônia, 25 abril 2015. Disponível em: <https://www.researchgate.net/publication/275959737_Comparacao_do_indice_de_area_foliar_IAF_estimado_por_sensoriamento_remoto_entre_os_anos_de_1984_e_2011_na_regiao_central_de_Rondonia>. Acesso em: 15 junho 2018.

BERKA, L. M. S.; RUDORFF, B. F. T. **Anais XI Simpósio Brasileiro de Sensoriamento Remoto**, Belo Horizonte - MG, 05-10 abril 2003. 27-31. Disponível em: <http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2002/11.18.18.36/doc/01_469.pdf>. Acesso em: 18 junho 2018.

BERLATO, M. A. **Modelo de relação entre o rendimento de grãos de soja e o déficit hídrico para o Estado do Rio Grande do Sul**. Instituto Nacional de Pesquisas Espaciais, São José dos Campos - SP, 1987. 94. Acesso em: 02 julho 2018.

BEZDEK, J. C.; PAL, S. K. **Fuzzy Models for Pattern Recognition**. New York: IEEE Press, 1992.

BIASE, A. G.; SANTANA, T. V. F. **Geostatística Análise de dados em outro software Gamma Design GS+**. Escola Superior de Agricultura “Luiz de Queiroz” - Pós-graduação em Estatística e Experimentação, Piracicaba - SP, outubro 2012. 12. Disponível em: <http://leg.ufpr.br/lib/exe/fetch.php/disciplinas:geosalq:tiago_gamma_gs_.pdf>. Acesso em: 05 julho 2018.

BLIGH, E. G.; DYER, W. J. **A rapid method of total lipid extraction and purification**. Canadian Journal of Biochemistry and Physiology, v. 37, n. 08, p. 911-917, agosto 1959. Disponível em: <<http://www.nrcresearchpress.com/doi/abs/10.1139/o59-099#citart1>>. Acesso em: 05 julho 2018.

BOHLING, G. kgs.ku.edu. **Kansas Geological Survey**, 17 outubro 2005. Disponível em: <<http://discoverspatial.in/wp-content/uploads/2018/04/Variograms.pdf>>. Acesso em: 25 maio 2018.

BRAGA, H. J. **Previsão agrícola : uma nova abordagem : uso de scanner aerotransportavel e redes neurais**. Repositório Institucional - Universidade Federal de Santa Catarina - UFSC, Florianópolis, março 1995. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/76346>>. Acesso em: 02 julho 2018.

BRASIL. Lei n. 11.097, de 13 de janeiro de 2005. **Dispõe sobre a introdução do biodiesel na matriz energética brasileira**, Brasília, 13 janeiro 2005. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2005/lei/111097.htm>. Acesso em: 20 julho 2018.

BRASIL. Lei n. 13.033, de 24 de setembro de 2014. **Dispõe sobre a adição obrigatória de biodiesel ao óleo diesel comercializado com o consumidor final**, Brasília, 24 setembro 2014. Disponível em: <<http://www2.camara.leg.br/legin/fed/lei/2014/lei-13033-24-setembro-2014-779372-publicacaooriginal-145039-pl.html>>. Acesso em: 25 maio 2018.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Anuário Estatístico da Agroenergia 2014**, 2014. Disponível em: <<http://www.agricultura.gov.br/assuntos/sustentabilidade/agroenergia/arquivos-publicacoes-agroenergia/anuario-estatistico-da-agroenergia-2014.pdf/view>>. Acesso em: 24 Maio 2018.

BRASIL. Ministério de Minas e Energia. **Boletim Mensal de Biocombustíveis**, Brasília, Dezembro 2015. Disponível em: <<http://www.mme.gov.br/documents/1138769/1732805/Boletim+DCR+n%C2%BA+95+-+dezembro+de+2015.pdf/3f3e833b-ef26-43a6-a65f-7c1a7918e6e3>>. Acesso em: 10 julho 2018.

BRASIL. Resolução ANP n. 30/2016. **Estabelece a especificação de óleo diesel BX a B30, em caráter autorizativo, nos termos dos incisos I, II e III do art. 1º da Resolução CNPE nº 03, de 21 de setembro de 2015.**, Rio de Janeiro, 16 agosto 2016. Disponível em: <<http://legislacao.anp.gov.br/?path=legislacao-anp/resol-anp/2016/junho&item=ranp-30--2016>>.

BRASIL. Ministério de Minas e Energia. **Boletim Mensal de Biocombustíveis**, Brasília, julho 2017. Disponível em: <<http://www.mme.gov.br/documents/1138769/0/Boletim+DBio+n%C2%BA+110+jul-ago+de+2017.pdf/e85a585c-10c7-4efc-bb8e-1779604f7487>>. Acesso em: 10 julho 2018.

BURKLEY, K. O.; WILSON, R. F.; WELLS, R. **Effects of canopy shade on the lipid composition of soybean leaves**. *Physiologia Planarum*, 1997. Acesso em: 05 maio 2018.

CAETANO, M. A. L. **Métodos Quantitativos**. São Paulo: [s.n.], 2016.

CÂMARA, G. M. D. S. Fenologia da Soja. **Informações Agrônomicas**, Piracicaba, Maio 1998.

CARVALHO, J. R. P. D.; SILVEIRA, P. M. D.; VIEIRA, S. R. **Geoestatística na determinação da variabilidade espacial de características químicas do solo sob diferentes preparos**. *Pesquisa Agropecuária Brasileira*, Brasília, 37, n. 08, agosto 2002.

1151-1159. Disponível em: <<http://www.scielo.br/pdf/pab/v37n8/11675.pdf>>. Acesso em: 11 junho 2018.

CASTEEL, S. N. **Estimating Soybean Yields – Simplified**. Soybean Station, Indiana - EUA, p. 4, 14 ago. 2012.

CAVALCANTE, A. K.; SOUSA, L. B.; HAMAWAKI, O. T. **Determinação e avaliação do teor de óleo em sementes de soja pelos métodos de ressonância magnética nuclear soxhlet**. Biosci. J, Uberlândia, v. 27, n. 01, p. 8-15, janeiro 2011. Disponível em: <<http://www.seer.ufu.br/index.php/biosciencejournal/article/download/7353/6835>>. Acesso em: 18 julho 2018.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. **Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors**. ResearchGate, p. 893-903, 2009. Disponível em: <https://www.researchgate.net/publication/223280469_Summary_of_current_radiometric_calibration_coefficients_for_Landsat_MSS_TM_ETM_and_EO-1_ALI_sensors>. Acesso em: 12 junho 2018.

CLEMENTE, T. E.; CAHON, E. B. plantphysiol. **plantphysiol**, 2009. Disponível em: <<http://www.plantphysiol.org/content/plantphysiol/151/3/1030.full.pdf>>. Acesso em: 24 Maio 2018.

CONAB. conab.org.br. **Boletim da Safra de Grãos**, 2017. Acesso em: 24 Maio 2018.

CRESSIE, N. **The origins of Kriging**. Mathematical Geosciences, v. 22, n. 03, p. 239-252, abril 1990. Disponível em: <<https://link.springer.com/article/10.1007/BF00889887>>. Acesso em: 15 junho 2018.

CRISP. crisp.nus.edu.sg. **Centre for Remote Imaging, Sensing & Processing**, 2001. Disponível em: <<https://crisp.nus.edu.sg/~research/tutorial/appendix.htm>>. Acesso em: 10 julho 2018.

CRUZ, T. V.; PEIXOTO, C. P.; MARTINS, M. C. **Teores de óleo, proteínas e produtividade de soja em diferentes épocas de semeadura. V Congresso Brasileiro de Soja - Anais**, Goiânia - GO, 2009.

DAI, W. et al. **Spatial variation of organic carbon density in topsoils of a typical subtropical forest, southeastern China**. Catena, 167, n. 08, maio 2018. Disponível em: <https://www.researchgate.net/publication/325140697_Spatial_variation_of_organic_carbon_density_in_topsoils_of_a_typical_subtropical_forest_southeastern_China>. Acesso em: 03 julho 2018.

DALE, V. H. **The Relationship Between Land-use Change and Climate Change**. ReserchGate, v. 7, n. 3, p. 753-769, August 1997. Disponível em: <https://www.researchgate.net/publication/270265733_The_Relationship_Between_Land-Use_Change_and_Climate_Change>. Acesso em: 03 julho 2018.

DALLEMAND, J. F.; TARDIN, A. T.; BATISTA, G. T. **Sensoriamento Remoto e agricultura**. Ciência Hoje, v. 08, p. 44-51, 1988. Disponível em: <<http://cienciahoje.org.br/edicao/08/>>. Acesso em: 12 maio 2018.

DEER; COMPANY. Jonh Deere. **deere.com.br**, 2018. Disponível em: <<https://www.deere.com.br/pt/colheitadeiras/s%C3%A9rie-s/s690/>>. Acesso em: 01 julho 2018.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. **Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo - SP usando imagens Landsat 05**. RAEGA, Paraná, v. 21, p. 234-271, 2011. Disponível em: <<https://revistas.ufpr.br/raega/article/download/17416/14028>>. Acesso em: 02 junho 2018.

DURIGAN, J.; DURIGAN, J. F.; CARVALHO, N. M. **Aplicação, em pré-colheita, de dessecante em duas cultivares de soja (Glycine max (L.) Merrill) III - Efeitos sobre a composição química (proteína, óleo e cinzas) e resíduos nas sementes**. ResearchGate, 1980. 122-126. Disponível em: <https://www.researchgate.net/publication/262715260_Aplicacao_em_pre-colheita_de_dessecante_em_duas_cultivares_de_soja_Glycine_max_L_Merril_III_-_Efeitos_sobre_a_composicao_quimica_proteina_oleo_e_cinzas_e_residuos_nas_sementes>. Acesso em: 28 junho 2018.

EMBRAPA. ainfo.cnptia.embrapa.br. **Embrapa**, 2010. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/23225/1/Sistema-Producao14-VE.pdf>>. Acesso em: 24 Maio 2018.

EMBRAPA. **Sistema Brasileiro de Classificação dos Solos**. 4. ed. Brasília: [s.n.], 2014.

EMBRAPA. embrapa.br. **Empresa Brasileira de Pesquisa Agropecuária**, 2016. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/23225/1/Sistema-Producao14-VE.pdf>>. Acesso em: 24 Maio 2018.

EMPRAPA. Emprapa Monitoramento por Satélie. **Satélites de monitoramento**, 2013. Disponível em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: 10 maio 2018.

EIPHANIO, J. C. N. et al. **Índices de Vegetação no Sensoriamento Remoto da Cultura do Feijão**. Pesquisa Agropecuária Brasileira, Brasília, v. 31, n. 6, p. 445-454, junho 1996. Disponível em: <<https://seer.sct.embrapa.br/index.php/pab/article/view/4503/1789>>. Acesso em: 11 junho 2018.

EIPHANIO, J. C. N.; LEONARDI, L.; FORMAGGIO, A. R. **Relações entre parâmetros culturais e resposta espectral de cafezais**. Pesquisa Agropecuária Brasileira, Brasília, 29, n. 3, março 1994. Disponível em: <<https://seer.sct.embrapa.br/index.php/pab/article/view/4073/1364>>. Acesso em: 12 junho 2018.

EIPHANIO, J. C. N.; LUIZ, A. J. B.; FORMAGGIO, A. R. **Estimativa de áreas agrícolas municipais, utilizando sistema de amostragem simples sobre imagens de satélite**. Bragantia, Campinas - SP, v. 61, n. 2, p. 187-197, Agosto 2002. Disponível em: <http://www.scielo.br/scielo.php?pid=S0006-87052002000200012&script=sci_abstract&tIng=pt>. Acesso em: 11 junho 2018.

ESQUERDO, J. C. D. M.; JUNIOR, J. Z.; ANTUNES, J. F. G. **Uso de perfis multi-tempoais de NDVI/AVHRR no acompanhamento da cultura da soja no oeste do Paraná**. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, 25-30 abril 2009. 145-150. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.12.17.50/doc/145-150.pdf>>. Acesso em: 11 junho 2018.

EVANGELISTA, B. A. cpa.unicamp.br. **Universidade de Campinas**, 2011. Disponível em:

<<https://www.cpa.unicamp.br/alcsens/docs/publicacoes/Projecao%20de%20cenarios%20atuais%20e%20futuros%20de%20produtividade%20de%20cana-de-acucar%20em%20ambiente%20de%20cerrado.pdf>>. Acesso em: 16 junho 2018.

EVANGELISTA, B. A. **Projeção de cenários atuais e futuros de produtividade de cana-de-açúcar em ambiente de Cerrado**. Universidade Estadual de Campinas - Faculdade de Engenharia Agrícola, Campinas - SP, fevereiro 2011. Disponível em: <<https://www.cpa.unicamp.br/alcsens/docs/publicacoes/Projecao%20de%20cenarios%20atuais%20e%20futuros%20de%20produtividade%20de%20cana-de-acucar%20em%20ambiente%20de%20cerrado.pdf>>. Acesso em: 01 agosto 2018.

FARENCEANA, J. C. lume.ufrgs.br. **Repositório Digital**, 2011. Disponível em: <<https://lume.ufrgs.br/handle/10183/56855>>. Acesso em: 16 Abril 2018.

FARIAS, J. R. B.; ALMEIDA, I. R. D.; GARCIA, A. Repositório. **Agência EMBRAPA**, 1997. Disponível em: <https://www.agencia.cnptia.embrapa.br/Repositorio/zoneamento_000g4yaxz9u02wx5ok0dkla0s5yw0f9e.pdf>. Acesso em: 24 Maio 2018.

FARIAS, R.; NEPOMUCENO, A. L.; NEUMAIER, N. Agência Embrapa de Informação e Tecnologia. **Embrapa**, 2007. ISSN 48. Disponível em: <http://www.agencia.cnptia.embrapa.br/Repositorio/circtec48_000g3bkhmrq02wx5ok0r2ma0nxz1b1po.pdf>. Acesso em: 10 julho 2018. Circular Técnica.

FEHR, W. R.; CAVINESS, C. E. **Stages of soybean development**. Yowa State Univeristy - Digital Repository, 1977. 87. Disponível em: <<https://lib.dr.iastate.edu/cgi/viewcontent.cgi?article=1076&context=specialreports>>. Acesso em: 03 maio 2018.

FERNANDES, P.; VEIVERBERG, K. T.; ELÓDIO, S. **Determinação da produtividade de soja por sensoriamento remoto em nível de talhão**. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal - RN, 25-30 abril 2009. 2009-2015. Disponível em: <https://www.researchgate.net/publication/228831719_Determinacao_da_Produtividade_e_de_Soja_por_Sensoriamento_Remoto_em_Nivel_de_Talhao>. Acesso em: 12 maio 2018.

FERREIRA, V. et al. **Spatial variability of soil properties and soil erodibility in the Alqueva reservoir watershed**. Solid Earth, v. 06, p. 383-392, 2015. Disponível em: <<https://www.solid-earth.net/6/383/2015/>>. Acesso em: 12 junho 2018.

FINOTO, E. L. et al. **Teores de óleo e de proteína de genótipos de soja em duas épocas de plantio e dois tipos de solo em Frutal-MG**. XXX Reunião de pesquisa de soja da região central do Brasil, Rio Verde - GO, 2008. 53-55. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/handle/doc/470743>>. Acesso em: 05 agosto 2018.

FNP, I. Agriannual 2005: **Anuário da agricultura brasileira**. São Paulo: [s.n.], 2005. p. 520. Disponível em: <<https://biblioteca.incaper.es.gov.br/busca?b=ad&id=5649&biblioteca=vazio&busca=autoria:%22INSTITUTO%20FNP%22&qFacets=autoria:%22INSTITUTO%20FNP%22&sort=&paginaAtual=2>>. Acesso em: 10 junho 2018.

FONTANA, D. C.; BERLATO, M. A. **Modelo agrometeorológico-espectral para a estimativa do rendimento de soja no Rio Grande do Sul: um estudo preliminar.** Anais IX Simpósio Brasileiro de Sensoriamento Remoto, Santos SP, 11-18 setembro 1998. 17-24. Disponível em: <<https://www.researchgate.net/publication/240618923/download>>. Acesso em: 17 maio 2018.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em Agricultura.** Cubatão - SP: Oficina do Texto, 2017.

GARNER, W. W.; ALLARD, H. A. **Photoperiodic response of soybeans in relation to temperature and other environmental factors.** Coleções Digitais da Biblioteca Nacional Agrícola, v. 41, n. 10, p. 719-735, 15 novembro 1930. Disponível em: <<https://naldc-legacy.nal.usda.gov/naldc/search.xhtml>>. Acesso em: 18 maio 2018.

GITELSON, A. A. et al. **Novel algorithms for remote estimation of vegetation fraction.** Remote Sensing of Environment, v. 80, n. 01, p. 76-87, abril 2002. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0034425701002899>>. Acesso em: 15 junho 2018.

GONÇALVES, A. P. S. **Metodologia de Sistemas de Informação Geográfica em Sistemas de Produção Florestal.** Faculdade de Ciências Sociais e Humanas - Universidade Nova de Lisboa, Lisboa - Portugal, outubro 2015. 110. Disponível em: <<https://run.unl.pt/bitstream/10362/17388/1/APGONCALVES2015.pdf>>. Acesso em: 13 julho 2018.

GONZALES-ALONSO, F. et al. **Remote sensing and agricultural statistics: Crop area estimation in north-eastern Spain through diachronic Landsat TM and ground sample data, International Journal of Remote Sensing.** International Journal of Remote Sensing, 18, n. 2, 25 novembro 2015. 467-470. Disponível em: <<https://www.tandfonline.com/doi/citedby/10.1080/014311697219213?scroll=top&neededAccess=true>>. Acesso em: 12 junho 2018.

GRIFFITH, D. A. **Advanced spatial statistics for analysing and visualizing georeferenced data.** International Journal of Geographical Information Systems, v. 7, p. 107-123, 1993. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/02693799308901945>>. Acesso em: 12 maio 2018.

HARLAN, R. J. Crops and man. In: SEDIYAMA, T.; SILVA, F.; BORÉM, A. **Soja do plantio à colheita.** Viçosa: UFV, 2015. Cap. 01, p. 10.

HUETE, A. R. **A soil-adjusted vegetation index (SAVI).** ScienceDirect, v. 25, n. 03, p. 295-309, 1988. Disponível em: <<https://www.sciencedirect.com/science/article/pii/003442578890106X>>. Acesso em: 15 junho 2018.

HUETE, A. R.; JACKSON, R. D.; POST, D. F. **Spectral response of a plant canopy with different soil backgrounds.** ScienceDirect, v. 17, n. 01, p. 37-53, fevereiro 1985. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0034425785901117>>. Acesso em: 12 junho 2018.

HUNGRIA, M.; CAMPO, R. J.; MENDES, I. C. embrapa.br. **Embrapa - publicações**, 07 março 2002. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/564416/fixacao-biologica-do-nitrogenio-na-cultura-da-soja>>. Acesso em: 15 junho 2018.

HYMOWITZ, T. Economic Botany. In: SEDIYAMA, T.; SILVA, F.; BORÉM, A. **Soja do plantio à colheita**. Viçosa: UFV, 2015. Cap. 01, p. 10.

IBGE. sidra.ibge.gov.br. **SIDRA - Banco de tabelas estatísticas**, 2018. Disponível em: <<https://sidra.ibge.gov.br/home/lspa/tocantins>>. Acesso em: 10 maio 2018.

IDEIÃO, S. M. A. et al. **Determinação da temperatura de superfície no estado da Paraíba a partir de imagens LANDSAT 05 - TM**. II Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, Recife - PE, 11 setembro 2008. Disponível em: <https://www3.ufpe.br/cgtg/SIMGEOII_CD/Organizado/sens_foto/012.pdf>. Acesso em: 30 maio 2018.

IPPOLITI-RAMILO, G. A. et al. **Sensoriamento remoto orbital como meio auxiliar na previsão de safras**. Instituto Nacional de Pesquisas Espaciais, São Paulo, 1999. Disponível em: <<http://mtc-m12.sid.inpe.br/col/sid.inpe.br/iris@1912/2005/07.19.21.22.53/doc/INPE%207969.pdf>>. Acesso em: 12 maio 2018.

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. 07, p. 1521-1534, 2003. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01431160010007105?journalCode=tres20>>. Acesso em: 15 julho 2018.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied Geostatistics**. [S.l.]: University Oxford, v. 02, 1989.

JACKSON, R. D.; HUETE, A. R. **Interpreting vegetation indices**. ScienceDirect, v. 11, n. 3-4, p. 185-200, 1991. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167587705800042>>. Acesso em: 30 junho 2018.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Instituto Nacional de Pesquisas Espaciais, Carolina do Sul - EUA, 2009. 598. Disponível em: <<http://mtc-m16d.sid.inpe.br/col/sid.inpe.br/mtc-m19/2011/04.01.14.00/doc/jensen.pdf>>. Acesso em: 05 julho 2018.

JESUS, R. J.; COELHO, A. L. N. **Determinação da Temperatura de Superfície do Município de Cariacica – ES com emprego de Geotecnologias**. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu - PR, 13-18 abril 2013. 1053-1060. Disponível em: <<http://marte2.sid.inpe.br/col/dpi.inpe.br/marte2/2013/05.28.23.44.58/doc/p0581.pdf>>. Acesso em: 18 junho 2018.

JONHSTON, K. et al. **Using ArcGIS geostatistical analyst, 2001**. Disponível em: <http://dusk2.geo.orst.edu/gis/geostat_analyst.pdf>. Acesso em: 05 maio 2018.

KITAMURA, A. E. feis.unesp.br. **Universidade Estadual Paulista**, 2004. Disponível em:

<http://www.feis.unesp.br/Home/DTA/STPG/agro/dissertacoes2004/kitamura_ae_me_ilha.pdf>. Acesso em: 10 agosto 2018.

KRIGE, D. A **Statistical approach to some basic mine valuation problems on the Witwatersrand**. Journal of the Southern African Institute of Mining and Metallurgy, v. 52, n. 09, p. 201-203, 09 dezembro 1951. Disponível em: <<http://journals.co.za/content/journal/saimm>>. Acesso em: 12 maio 2018.

KRIVORUCHKO, K. **Using linear and non-linear kriging interpolators to produce probability maps**. Environmental Systems Research Institute, New York - EUA, 2001. Disponível em: <https://www.researchgate.net/profile/Vijith_H/post/How_deal_with_not_normal_distribution_data_for_Kriging_Interpolation/attachment/59d6262679197b80779846f9/AS%3A319459263221760%401453176431181/download/Using+linear+and+non-linear+kriging+interpolators.pdf>. Acesso em: 25 junho 2018.

KRUGUER, M. **Análise geoestatística de dados meteorológicos do estado do Paraná utilizando software livre**. da Vinci, Curitiba, 02, n. 01, 2005. 87-104. Disponível em: <<https://www.up.edu.br/davinci/2/07.pdf>>. Acesso em: 15 julho 2018.

LEE, C.; HERBEK, J. **Estimating Soybean Yield**. Cooperate Extension Service, Kentucky - EUA, dezembro 2005. Disponível em: <www.ca.uky.edu>. Acesso em: 05 maio 2018.

LEITE, E. S.; OLIVEIRA, L. A.; BORGES, W. C. **Análise do comportamento de temperatura de superfíciena malha urbana de Araxá/MG, utilizando-se banda termal do satélite Landsat 08**. I Simpósio Internacional de Águas, Solos e Geotecnologias - SASGEO, Guarapuava - PR, 2015. Acesso em: 15 maio 2018.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote Sensing and Image Interpretation**. Wiley, n. 07, p. 736, fevereiro 2015. Disponível em: <<https://www.wiley.com/en-us/Remote+Sensing+and+Image+Interpretation,+7th+Edition-p-9781118343289>>. Acesso em: 10 junho 2018.

LIMA, P. C. [camara.leg.br](http://www.camara.leg.br). **Câmara dos deputados**, 2004. Disponível em: <http://www2.camara.leg.br/a-camara/documentos-e-pesquisa/estudos-e-notas-tecnicas/arquivos-pdf/pdf/2004_676_Estudo.pdf>. Acesso em: 005 maio 2018.

LIU, W. T. H. **Aplicações de Sensoriamento Remoto**. 02. ed. [S.l.]: [s.n.], 2006.

MACHADO, C. C. C.; GALVÍNCIO, J. D.; PEREIRA, E. C. G. [uc.pt](http://www.uc.pt). **Universidade de Coimbra**, 2010. Disponível em: <<http://www.uc.pt/fluc/cegot/VISLAGF/actas/tema2/celia>>. Acesso em: 16 julho 2018.

MAPA. agricultura.gov.br. **Ministério da Agricultura, Pecuária e Abastecimento**, 2017. Disponível em: <<http://www.agricultura.gov.br/assuntos/insumos-agropecuarios/insumos-agricolas/protecao-de-cultivar/cultivares-protegidas>>. Acesso em: 01 maio 2018.

MATHER, P. M.; KOCH, M. **Computer Processing of Remotely-Sensed Images: An Introduction**. Wiley, n. 04, p. 460, janeiro 2011. Disponível em: <<https://www.wiley.com/en-us/Computer+Processing+of+Remotely+Sensed+Images%3A+An+Introduction%2C+4th+Edition-p-9780470742396>>. Acesso em: 12 junho 2018.

MATHERON, G. **Principles of geostatistics**. Economic Geology, v. 58, p. 1246-1266, dezembro 1963. Disponível em: <<https://pubs.geoscienceworld.org/segweb/economicgeology/article-abstract/58/8/1246/17275/principles-of-geostatistics?redirectedFrom=fulltext>>. Acesso em: 03 junho 2018.

MEDEIROS, A. M. P.; RUDORF, B. F. T.; SHIMABUKURO, Y. E. **Imagens Landsat na Estimativa de Áreas de Cana-de-Açúcar, Milho e Soja**. Anais VIII Simpósio Brasileiro de Sensoriamento Remoto, Salvador - BA, 14-19 abril 1996. 33-37. Disponível em: <<http://marte.sid.inpe.br/col/sid.inpe.br/deise/1999/02.01.11.30/doc/T85.pdf>>. Acesso em: 17 maio 2018.

MONTEITH, J. L. researchgate.net. **The Quest for Balance in Crop Modeling**, Setembro 1996. Disponível em: <https://www.researchgate.net/publication/221944067_The_Quest_for_Balance_in_Crop_Modeling>. Acesso em: 12 abril 2018.

MORAES, R. M. A. D. et al. **Caracterização bioquímica de linhagens de soja com alto teor de proteína**. Pesquisa Agropecuária Brasileira, Passo Fundo - RS, Brasília 2006. 725-729. Disponível em: <<https://seer.sct.embrapa.br/index.php/pab/article/view/7199/4244>>. Acesso em: 28 julho 2018.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologia de aplicação**. 3. ed. Viçosa: UFV, 2007. 307 p.

MULLER, L. **Taxonomia e morfologia**. In: MIYASAKA, S.; MEDINA, J. C. A Soja no Brasil. [S.l.]: [s.n.], 1981. p. 65-104.

NOON, C. E.; DALY, M. J. **Gis-based biomass resource assessment with BRAVo**. Science Direct, v. 10, p. 101-109, 1996. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0961953495000658>>. Acesso em: 15 junho 2018.

OLIVEIRA, A. J. D.; RAMALHO, J. agricultura.gov. **Ministério da Agricultura Pecuária e Abastecimento**, 2006. Disponível em: <<http://www.agricultura.gov.br/assuntos/sustentabilidade/agroenergia/arquivos/pna-2ed-portugues.pdf>>. Acesso em: 24 Maio 2018.

OLIVEIRA, R. B. portais4.ufes.br. **Universidade Federal do Espírito Santo**, 2007. Disponível em: <http://portais4.ufes.br/posgrad/teses/tese_3391_Rone%20Batista%20de%20Oliveira.pdf>. Acesso em: 05 agosto 2018.

ORTIZ, B. V. et al. **Determination of differences in crop injury from aerial application of glyphosate using vegetation indices**. Computers and Electronics in Agriculture, v. 77, n. 2, p. 204-213, julho 2011.

PAIXÃO, C. **Ministro da Agricultura destaca potencial do Tocantins em produção de grãos**. Portal do Tocantins, Palmas, 15 Fevereiro 2018. Disponível em: <<https://portal.to.gov.br/noticia/2018/2/15/ministro-da-agricultura-destaca-potencial-do-tocantins-em-producao-de-graos/>>. Acesso em: 15 maio 2018.

PARENTE, E. J. D. S. **Biodiesel: uma aventura tecnologica num país engraçado**. Base de Dados da Pesquisa Agropecuária, 2003. Disponível em:

<<https://www.bdpa.cnptia.embrapa.br/consulta/busca?b=ad&id=251414&biblioteca=vazio&busca=autoria:%22PARENTE,%20E.%20J.%20de%20S.%22&qFacets=autoria:%22PARENTE,%20E.%20J.%20de%20S.%22&sort=&paginacao=t&paginaAtual=1>>. Acesso em: 23 maio 2018.

PARTENIANI, E. **Ciência, agricultura e sociedade**. Brasília: Embrapa Informação Tecnológica, 2006. Acesso em: 13 junho 2018.

PAX-LENNEY, M.; WOODCOCK, C. E. **The effect of spatial resolution on the ability to monitor the status of agricultural lands**. ScienceDirect, v. 61, n. 2, p. 201-220, August 1997. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0034425797000035>>. Acesso em: 10 julho 2018.

PELUZIO, J. M. et al. **Adaptabilidade e estabilidade de cultivares de soja em várzea irrigada no Tocantins**. Revista Ciência Agronômica, Fortaleza, v. 41, n. 3, p. 427-434, jul-set 2010. Disponível em: <<http://ccarevista.ufc.br/seer/index.php/ccarevista/article/view/641/461>>. Acesso em: 20 maio 2018.

PELÚZIO, M. J. et al. seer.ufu. **Bioscience Journal**, 2005. Disponível em: <<http://www.seer.ufu.br/index.php/biosciencejournal/article/view/6734>>. Acesso em: 25 Maio 2018.

PÍPOLO, A. E. et al. embrapa.br. **Embrapa - Soja**, p. 15, 28 maio 2015. Disponível em: <<https://www.embrapa.br/soja/busca-de-publicacoes/-/publicacao/1025298/teores-de-oleo-e-proteina-em-soja-fatores-envolvidos-e-qualidade-para-a-industria>>. Acesso em: 10 abril 2018.

PIRES, E. G.; FERREIRA, J. L. G. **Mapeamento da Temperatura da superfície a partir de imagens termais dos satélites Landsat 07 e Landsat 08**. Anais VVII Simpósio Brasileiro de Sensoriamento Remoto, João Pessoa - PB, 2015. Acesso em: 12 julho 2018.

RAMACHANDRA, T. V. **Regional integrated energy plan**. Science Direct, v. 13, p. 285-317, February 2009. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032107001414>>.

RAMIREZ, G. M. **Comparação entre imagens pancromáticas do satélite IKONOS-II e LANDSAT/ETM+ na identificação de plantios de café (Coffea arabica)**. Unicamp, Campinas, novembro 2002. Disponível em: <https://www.cpa.unicamp.br/producao/dissertacoes-de-mestrado/2002/ramirez-_glauca_miranda_.pdf/download.pdf>. Acesso em: 25 maio 2018.

RAMOS, L. P. et al. resol.com.br. **Revista Biotecnologia Ciência e Desenvolvimento**, 2003. Disponível em: <<http://www.resol.com.br/textos/Biodiesel.pdf>>. Acesso em: 15 julho 2018.

RICHARD, J. A.; JIA, X. **Remote Sensing Digital Image Analysis**. 04. ed. [S.l.]: [s.n.], 1999. Disponível em: <http://148.206.53.84/tesiuami/S_pdfs/Remote%20Sensing%20Digital%20Image%20Analysis.pdf>. Acesso em: 12 junho 2018.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja: estudo de caso no Rio Grande do Sul**. Instituto Nacional de Pesquisas Espaciais, São José dos

Campos, 2005. Disponível em: <<http://mtc-m12.sid.inpe.br/col/sid.inpe.br/jeferson/2004/07.02.14.17/doc/publicacao.pdf>>. Acesso em: 15 junho 2018.

RIZZI, R. sid.inpe. **Geotecnologias em um Sistema de Estimativa da Produção da Soja: Estudo de Caso no Rio Grande do Sul, 2005**. Disponível em: <<http://mtc-m12.sid.inpe.br/col/sid.inpe.br/jeferson/2004/07.02.14.17/doc/publicacao.pdf>>. Acesso em: 10 Abril 2018.

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, São Jose dos Campos - SP, p. 226-234, 2005. Disponível em: <http://mtc-m12.sid.inpe.br/attachment.cgi/sid.inpe.br/iris@1912/2006/01.11.13.07/doc/rizzi_estimativa.pdf>. Acesso em: 03 julho 2018.

RODRIGUES, J. I. D. S. et al. **Associação de marcadores microsatélites com teores de óleo e proteína em soja**. Pesquisa Agropecuária Brasileira, Brasília, 48, n. 03, março 2013. 255-262. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2013000300003&lng=pt&tlng=pt>. Acesso em: 30 julho 2018.

RODRIGUES, O. et al. **Resposta quantitativa do florescimento da soja à temperatura e ao fotoperíodo**. Pesquisa Agropecuária Brasileira, Brasília, v. 36, n. 3, p. 431-437, março 2001. Disponível em: <<http://seer.sct.embrapa.br/index.php/pab/issue/view/160>>. Acesso em: 20 maio 2018.

RODRIGUES, T. S.; RIBEIRO, S. R. A.; VAZ, M. S. G. **Avaliação do desempenho de dois índices de vegetação (NDVI e SAVI) por meio de Índice de Qualidade de Imagens**. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto, Foz do Iguaçu, 13 abril 2013. Disponível em: <<http://marte2.sid.inpe.br/col/dpi.inpe.br/marte2/2013/05.28.23.53.35/doc/p0704.pdf>>. Acesso em: 14 junho 2018.

RODRIGUES, W.; LUNCKES, J. F. **Rentabilidade econômica da produção de biodiesel de mamona**. Custo e Agronegócio, v. 7, n. 2, 20 outubro 2011. Disponível em: <<http://www.custoseagronegocioonline.com.br/numero2v7/rentabilidade.pdf>>. Acesso em: 16 maio 2018.

ROGOWSKI, A. S. **Quantifying soil variability in GIS applications: II Spatial distribution of soil properties**. International Journal of Geographical Information, v. 10, n. 04, p. 455-475, janeiro 1993. Disponível em: <<https://www.tandfonline.com/doi/pdf/10.1080/02693799608902090?needAccess=true>>. Acesso em: 25 maio 2018.

SALES, H. **Análise multivariada nos grãos de soja localizados em diferentes partes da planta visando a produção de bioenergia**. ResearchGate, janeiro 2014. Disponível em: <https://www.researchgate.net/publication/276059780_Analise_multivariada_nos_graos_de_soja_localizados_em_diferentes_partes_da_planta_visando_a_producao_de_energia>. Acesso em: 08 junho 2018.

SANCHES, I. D. **Sensoriamento remoto para o levantamento espectro-temporal e estimativa de área de culturas agrícolas**. Instituto Nacional de Pesquisas Espaciais, São Jose dos Campos, 19 fevereiro 2004. 172. Disponível em: <<http://mtc-m12.sid.inpe.br/col/sid.inpe.br/jeferson/2004/07.02.14.17/doc/publicacao.pdf>>.

m12.sid.inpe.br/col/sid.inpe.br/jeferson/2004/05.14.10.59/doc/publicacao.pdf>. Acesso em: 05 junho 2018.

SANTOS, J. S.; GEHARDT, A.; FONTANA, D. C. **Análise das Estimativas de Área de Soja no Estado do Rio Grande do Sul Geradas por Imagens NDVI/MODIS** Coleções 4 e 5. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, 25-30 abril 2009. 435-442. Disponível em: <<http://www.ufrgs.br/leaa/arquivos/Artigos%20em%20Eventos%20Cient%C3%ADficos/Santos%20Gehardt%20Fontana%20SBSR%202009.pdf>>. Acesso em: 12 junho 2018.

SANTOS, K. E. L. teses.usp.br. **Biblioteca digital - Teses e Dissertações - USP**, 2017. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18139/tde-27102017-162650/pt-br.php>>. Acesso em: 15 julho 2018.

SANTOS, K. E. L. et al. Brazilian Journal of Biosystems Engineering. **Geoestatística e Geoprocessamento na tomada de decisão do uso de insumos em uma pastagem**, São Paulo, v. 11, n. 03, p. 294-307, setembro 2017. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1076575/geoestatistica-e-geoprocessamento-na-tomada-de-decisao-do-uso-de-insumos-em-uma-pastagem>>. Acesso em: 01 julho 2018.

SANTOS, R. O. D. et al. **Variabilidade espacial da fertilidade do solo e sua relação com a produtividade do cacauzeiro**. Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande - Paraíba, v. 21, n. 02, p. 89-93, janeiro 2017. Disponível em: <https://www.researchgate.net/publication/313866033_Spatial_variability_of_soil_fertility_and_its_relation_with_cocoa_yield>. Acesso em: 23 julho 2018.

SCHOWENGERDT, R. A. **Models and methods for image processing**. United Department of Survey (USGS), n. 03, 1997. Disponível em: <http://www.doganaydal.com/nesneler/kutuphanekitaplar/REMOTE_SENSING,3_ED_MODELS_AND_METHODS_FOR_IMAGE_PROCESSING.PDF>. Acesso em: 14 junho 2018.

SEDIYAMA, T. **Tecnologias de produção e uso da soja**. [S.l.]: Mecenass, 2009. 314 p.

SEDIYAMA, T.; SILVA, F.; BORÉM, A. **Soja do plantio à colheita**. Viçosa: UFV, 2015.

SEDIYAMA, T.; TEIXEIRA, R. C.; BARROS, B. H. **Origem, evolução e importância econômica**. In: SEDIYAMA, T. **Tecnologias de produção de uso da soja**. [S.l.]: [s.n.], 2009.

SEDIYAMA, T.; TEIXEIRA, R. C.; BARROS, H. B. Cultivares. In: SEDIYAMA, T.; SILVA, F.; BORÉM, A. **Soja do plantio à colheita**. Viçosa: UFV, 2015. p. 46-47.

SEPLAN. seplan.to.gov.br. **Secretaria de Planejamento do Estado do Tocantins**, 2012. Disponível em: <<https://seplan.to.gov.br/>>. Acesso em: 23 Maio 2018.

SEPLAN. Granol e processamento de soja no Tocantins. **Programa de desenvolvimento regional da área de influência da ferrovia norte-sul no estado do Tocantins**, 2016. Disponível em: <<http://pdris.seplan.to.gov.br/index.php/iniciativas-tipo-b/244-granol-e-processamento-de-soja-no-tocantins-2>>. Acesso em: 14 julho 2018.

SILVA, A. F. et al. Cultivares. In: SEDIYAMA, T.; SILVA, F.; BORÉM, A. **Soja do plantio á colheita**. Viçosa: UFV, 2015. p. 149-150.

SILVA, A. F.; SEDIYAMA, T.; BORÉM, A. **Exigências Edafoclimáticas**. In: SEDIYAMA, T.; SILVA, F.; BORÉM, A. **Soja do plantio a colheita**. Viçosa: UFV, 2015. Cap. 03, p. 54-59.

SILVA, F. B. **Geotecnologias no mapeamento de áreas degradadas no núcleo de desertificação em Gilbués, Pi**. Livros Grátis, março 2008. Disponível em: <<http://livros01.livrosgratis.com.br/cp139197.pdf>>. Acesso em: 12 julho 2018.

SILVA, J. X. D. **Universidade Federal Rural do Rio de Janeiro**, 2009. Disponível em: <<http://www.ufrj.br/lga/tiagomarin/artigos/oqueegeoprocessamento.pdf>>. Acesso em: 25 Maio 2018.

SILVA, P. R. F. D.; FREITAS, T. F. S. D. lume.ufrgs. **ufrgs**, 2008. Disponível em: <<http://www.lume.ufrgs.br/bitstream/handle/10183/22280/000639651.pdf?sequence=1>> . Acesso em: 24 Maio 2018.

SILVA, W. C.; DUARTE, J. B. **Métodos estatísticos para estudo de adaptabilidade e estabilidade fenotípica em soja**. Pesquisa Agropecuária Brasileira, Brasília, v. 41, n. 1, p. 23-30, jan 2006. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2006000100004>. Acesso em: 20 julho 2018.

SOUZA, A. **Coefficiente de Correlação Linear de Pearson**. Açores: [s.n.], 2016.

TEILLET, P. M.; STAENZ, K.; WILLIAMS, D. J. **Effects of spectral, spatial, and radiometric characteristics on remote sensing vegetation indices of forested regions**. Food and Agriculture Organization of the United Nations, Cairo - Egypt, 1997. Disponível em: <<http://agris.fao.org/agris-search/search.do?recordID=US19970130997>>. Acesso em: 12 julho 2018.

THUNG, M. et al. **Quebrando paradigma: alta temperatura do ar não é fator limitante na produção de feijão com subirrigação em várzea tropical**. Congresso Nacional de Pesquisa de Feijão, Goiânia - GO, 2, 2005. 11156-1159. Disponível em: <<https://www.bdpa.cnptia.embrapa.br/consulta/busca?b=pc&id=214051&biblioteca=vazio&busca=autoria:%22OLIVEIRA,%20F.%20R.%20de%20A%22&qFacets=autoria:%22OLIVEIRA,%20F.%20R.%20de%20A%22&sort=&paginacao=t&paginaAtual=1>>. Acesso em: 12 maio 2018.

TOBLER, W. R. **A Computer Movie Simulating Urban Growth in the Detroit Region**. Economic Geography - Supplement: Proceedings. International Geographical Union. Commission on Quantitative Methods, junho 1970. Disponível em: <https://www.jstor.org/stable/pdf/143141.pdf?refreqid=excelsior%3Ac529766f408f528030ea904a74d546e7&seq=1#page_scan_tab_contents>. Acesso em: 27 junho 2018.

USDA. fas.usda.gov. **Departamento de Agricultura do Estados Unidos**, 2018. Disponível em: <<https://apps.fas.usda.gov/psdonline/circulars/production.pdf>>. Acesso em: 24 Maio 2018.

USGS. landsat.usgs.gov. **USGS**, 2015. Disponível em: <<https://landsat.usgs.gov/using-usgs-landsat-8-product>>. Acesso em: 24 Maio 2018.

USGS. landsa.usgs.gov. **USGS**, 2016. Disponível em: <https://landsat.usgs.gov/sites/default/files/documents/LSDS-1574_L8_Data_Users_Handbook.pdf>. Acesso em: 15 julho 2018.

VANZELA, L. S. et al. **Sensoriamento remoto para estimar a produtividade de biomassa de cana-de-açúcar**. Congresso Brasileiro de Engenharia Agrícola, São Pedro - SP, 13-17 setembro 2015. Disponível em: <<http://publicacoes.conbea.org.br/anais/busca/?pagina=1&ano=2015&categoria=&opcoes=VANZELA%2C+L.+S>>. Acesso em: 10 julho 2018.

VICENTE, J. R. et al. **Comparações entre dados dos censos agropecuários e estimativas das safras agrícolas do Estado de São Paulo**. Instituto de Economia Agrícola, São Paulo, janeiro 1990. Disponível em: <<http://www.iea.sp.gov.br/out/verTexto.php?codTexto=9271>>. Acesso em: 30 junho 2018.

VIEIRA, S. R. et al. **Geostatistical Theory and Application to Variability of Some Agronomical Properties**. Hilgardia, 51, n. 03, junho 1983. Disponível em: <<http://ucanr.edu/repository/fileaccess.cfm?article=152848&p=NSZLCD>>. Acesso em: 13 maio 2018.

WANG, F. **Fuzzy supervised classification of remote sensing images**. 02. ed. New York: IEEE, v. 28, 1990. Acesso em: 02 junho 2018.

WATSON, D. J. **The Physiological Basis of Variation in Yield**. Advanced in Agronomy, v. 4, p. 101-145, 1952. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0065211308603077>>. Acesso em: 10 julho 2018.

WOODCOCK, C. E.; STRAHLER, A. H.; JUPP, D. L. B. **The use of variograms in remote sensing: I. Scene models and simulated images**. Remote Sensing of Environment, v. 25, n. 03, p. 323-348, agosto 1988. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0034425788901083>>. Acesso em: 10 julho 2018.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística - Conceitos e Aplicações**. 01. ed. [S.l.]: Oficina do Texto, 2013.

ZADEH, L. A. Fuzzy sets. **ScienceDirect**, v. 08, n. 03, p. 338-353, june 1965. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S001999586590241X>>. Acesso em: 23 junho 2018.

ZHENG, D.; KAINZ, W.; GROTEN, S. **Integrated approach of GIS and neural fuzzy network for linguistic decision-making on land use management**. Geospatial Information in Agriculture and Forestry, Lake Buena Vista - Florida - EUA, v. 01, p. 95-102, 2000. Acesso em: 14 junho 2018.