

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA
FILHO - UNESP
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CÂMPUS JABOTICABAL**

**SENSORIAMENTO REMOTO APLICADO AO MODELO SAFER NA ESTIMATIVA
DE PARÂMETROS BIOFÍSICOS DE CULTIVOS**

**Samira Luns Hatum de Almeida
Engenheira Agrônoma**

2022

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA
FILHO - UNESP
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CÂMPUS JABOTICABAL**

**SENSORIAMENTO REMOTO APLICADO AO MODELO SAFER NA
ESTIMATIVA DE PARÂMETROS BIOFÍSICOS DE CULTIVOS**

Samira Luns Hatum de Almeida

Orientador: Prof. Dr. Rouverson Pereira da Silva

Coorientadores: Dra. Sandra Furlan Nogueira

Dr. José Ricardo Macedo Pezzopane

Dr. Antônio Heriberto de Castro Teixeira

Tese apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de Doutora em Agronomia (Produção Vegetal).

A447s

Almeida, Samira Luns Hatum de

Sensoriamento remoto aplicado ao modelo SAFER na estimativa de parâmetros biofísicos de cultivos / Samira Luns Hatum de Almeida. -- Jaboticabal, 2022

91 p. : il., tabs., fotos, mapas

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Rouverson Pereira da Silva

1. Agricultura digital. 2. Massa de forragem. 3. Maturação do amendoim. 4. Sensor proximal. 5. Sensor orbital. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

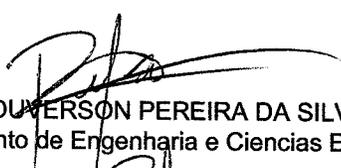
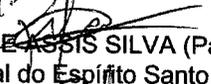
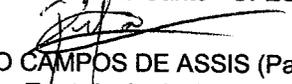
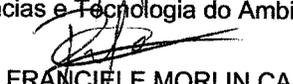
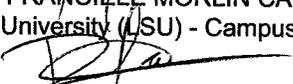
Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: SENSORIAMENTO REMOTO APLICADO AO MODELO SAFER NA ESTIMATIVA DE PARÂMETROS BIOFÍSICOS DE CULTIVOS

AUTORA: SAMIRA LUNS HATUM DE ALMEIDA
ORIENTADOR: ROVERSON PEREIRA DA SILVA
COORIENTADORA: SANDRA FURLAN NOGUEIRA
COORIENTADOR: JOSÉ RICARDO MACEDO PEZZOPANE
COORIENTADOR: ANTÔNIO HERIBERTO DE CASTRO TEIXEIRA

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

- 
Prof. Dr. ROVERSON PEREIRA DA SILVA (Participação Virtual)
Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal
- 
Prof. Dr. SAMUEL DE ASSIS SILVA (Participação Virtual)
Universidade Federal do Espírito Santo - UFES / Alegre/ES
- 
Prof. Dr. LEONARDO CAMPOS DE ASSIS (Participação Virtual)
Instituto de Ciências e Tecnologia do Ambiente-Uniube / Uberaba/MG
- 
Pós-doutoranda FRANCIELE MORLIN CARNEIRO (Participação Virtual)
Louisiana State University (LSU) - Campus de Baton Rouge / Louisiana/EUA
- 
PhD. LUCIANO SHOZO SHIRATSUCHI (Participação Virtual)
School of Plant, Environmental, and Soil Sciences / Louisiana State University - LSU

Jaboticabal, 18 de fevereiro de 2022

DADOS CURRICULARES DA AUTORA

SAMIRA LUNS HATUM DE ALMEIDA – nascida em Cachoeiro de Itapemirim, Espírito Santo, no dia 16 de fevereiro de 1994, filha de Jeanne Dias Luns e Samir Hatum de Almeida. cursou ensino fundamental na escola “Centro de Ensino Lauro Pinheiro” – CELP e ensino médio de 2009 a 2011 na Escola “Guimarães Rosa”. Em março de 2012, ingressou no curso de Agronomia pela Universidade Federal do Espírito Santo (UFES), Câmpus de Alegre, obtendo o título de Agrônoma em fevereiro de 2017. Durante a graduação realizou Iniciação Científica durante três anos, sob a orientação dos professores Drs. Alexandre Rosa dos Santos e Samuel de Assis Silva, com enfoque em Sensoriamento Remoto e Agricultura de Precisão. Ao final da graduação foi estagiária na Embrapa Informática agropecuária, atual Embrapa Agricultura digital, supervisionada pelo Dr. Luís Gustavo Barioni. Iniciou em 2017 o Mestrado Acadêmico em Engenharia Agrícola pela Universidade Federal de Viçosa sob a orientação do Dr. Daniel Marçal de Queiroz e coorientação do Dr. Francisco de Assis de Carvalho Pinto. A dissertação de título “Monitoramento da maturação do café arábica utilizando câmera digital modificada a bordo de veículo aéreo não tripulado” foi defendida em fevereiro de 2019. No mês seguinte deu início ao doutorado em Agronomia – Produção vegetal pela Universidade Estadual Paulista “Júlio de Mesquita Filho” – Unesp, Câmpus Jaboticabal, passando a integrar o grupo LAMMA – “Laboratório de Máquinas e Mecanização Agrícola”. Orientada pelos professores Drs. Rouverson Pereira da Silva e Cristiano Zerbato e coorientada pelos Drs. Sandra Furlan Nogueira, Antônio Heriberto de Castro Teixeira, e José Eduardo Macedo Pezzopane realizou estudos da aplicação de sensoriamento remoto e dados meteorológicos na estimativa de parâmetros biofísicos da pastagem e conduziu experimentos com a cultura do amendoim. Em 2021, realizou doutorado sanduíche na Universidade da Geórgia, Tifton -EUA, sendo supervisionada pela Dra. Cristiane Pilon. Na ocasião continuou a desenvolver trabalhos com a cultura do amendoim, com foco na estimativa de maturação a partir de dados espectrais e meteorológicos.

“Quem não luta por alguma coisa, paralisa por qualquer coisa.
Quem tem um motivo forte, não desiste por qualquer razão.”
(Caio Carneiro)

Aos meus pais Samir Hatum de Almeida e Jeanne Dias Luns; às minhas irmãs Sayanne e Renata; à minha tia Soraya; ao meu tio Clóvis; ao meu avô Clóvis. Aos amigos e a todos que me apoiaram.

A vocês, DEDICO!

AGRADECIMENTOS

Meus agradecimentos primeiramente a Deus e à Nossa Senhora por me abençoarem e iluminarem meu caminho possibilitando que eu chegasse até aqui.

Aos meus pais Samir e Jeanne por todo apoio e por terem me passado ensinamentos essenciais para que eu me tornasse a pessoa que sou hoje. Aos meus tios Soraya e Clóvis que nunca mediram esforços para nos ajudar a buscar nossos objetivos.

Agradeço à minha irmã Sayanne, pessoa que esteve ao meu lado em todos os momentos da minha vida, sendo uma grande conselheira, e incentivadora. À minha irmã Renata e meus familiares que me apoiam e torcem pelo meu crescimento.

Ao meu namorado Jarlyson por todo apoio, por acreditar em mim, e sempre me incentivar a correr atrás dos meus sonhos. Agradeço também por ter sido um excelente parceiro na coleta dos dados e nas discussões acerca do trabalho.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal) pela oportunidade e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsa – Cod. Financiamento 001.

Ao meu orientador Professor Dr. Rouverson Pereira da Silva, por quem fui tão bem recebida na Unesp. Pessoa que mesmo antes de ser meu orientador, acreditou e me deu suporte para colocar minhas ideias em prática, e também pude trocar ótimas conversas. Obrigada pelos ensinamentos, pelos conselhos, por ser tão humano, e por tratar seus orientandos com tanto respeito. O senhor é um dos meus maiores exemplos de professor e orientador, e uma pessoa na qual eu me espelho.

Ao Dr. Cristiano Zerbato pelos ensinamentos e orientação em parte do meu doutorado. À minha coorientadora Dra. Sandra Furlan Nogueira, pessoa que sempre se mostrou disposta a me ajudar e fazer o possível para que conseguíssemos realizar este trabalho, e também pelos ensinamentos e contribuições na escrita do projeto e da tese. Aos meus coorientadores Drs. José Ricardo Macedo Pezzopane e Antônio Heriberto de Castro Teixeira pelos ensinamentos e contribuições. Ao Dr. Luís Gustavo Barioni por ter se disponibilizado e me ajudado na indicação da minha coorientadora.

À Universidade da Georgia, Campus de Tifton, pela oportunidade de realizar seis meses de doutorado sanduiche. À Dra. Cristiane Pilon por ter me proporcionado essa experiência e dado todo o suporte para o desenvolvimento do experimento com a cultura de amendoim. Muito obrigada pela ajuda, pelos conselhos e por todos os ensinamentos. Ao Dr. George Vellidis que sempre mostrou-se disponível para sanar minhas dúvidas.

Ao professor Dr. Adão Felipe dos Santos, da Universidade Federal de Lavras, pela ajuda com o doutorado sanduíche e pelos ensinamentos.

Ao servidores David Trevizoli e Valdeci Aparício (Maranhão) por todo auxílio, e aos demais funcionários do Departamento de Engenharia Rural.

Agradeço às amigas que o doutorado me proporcionou conhecer, Franciele Morlin e Francielle Morelli, pelo companheirismo no dia a dia e na vida acadêmica, pelos trabalhos desenvolvidos, pelas conversas e por todo apoio.

Às minhas amigas Mariane, Ana Paula e Mariele, com quem eu tive o prazer de morar em Jabotical, pelo companheirismo, pelas risadas e pelo ótimo convívio que tivemos na República Goteiras. A todos da República Toca Fogo, Mailson Oliveira, Bruno Rafael, Armando Lopes, Eduardo Arouche, Francisco Amaral, Jardel Souza, Ancelmo Cazusa, Helena Carvalho, por toda a parceria.

Agradeço aos colegas do Laboratório de Máquinas e Mecanização agrícola, LAMMA, Alex Gonzaga, Armando Lopes, Aline Alcântara, Bruno Rocca, Danilo Tedesco, Elizabeth Kazama, Francielle Morelli, Franciele Morlin, Jarlyson Souza, Jean Lucas, Letícia Santos, Paulo Sérgio, Mailson Oliveira, Marcelo Junior, Romário Porto, Danilo Tedesco, e Vinicius Carreira pelo convívio e apoio no desenvolvimento dos trabalhos.

Aos colegas do NESPAL Awori Jimmy, Chiara Rossi, Letícia Santos, Pedro Leite, Morgan Sysskind e Austin pela receptividade e ajuda na execução dos experimentos. À Joara que foi muito prestativa e me ajudou por todo o período do meu doutorado sanduíche, e à todos os demais que tive oportunidade de conhecer em Tifton.

À Universidade Federal de Viçosa e Universidade Federal do Espírito Santo, instituições que contribuíram com a minha formação.

Aos Professores Drs. Daniel Maçã de Queiroz e Francisco de Assis de Carvalho Pinto pela orientação no mestrado. Ao Professor Dr. Samuel de Assis Silva, orientador na graduação, por quem sou extremamente grata por ter me passado tantos ensinamentos e me apresentado a agricultura de precisão.

A todos os amigos do mestrado, graduação e de Cachoeiro de Itapemirim pela amizade e companheirismo ao longo destes anos.

Por fim, a todos me apoiaram e que de alguma forma contribuíram para que eu chegasse até aqui, o meu muito obrigado!

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

SUMÁRIO

RESUMO	iii
ABSTRACT	iv
CAPITULO 1: CONSIDERAÇÕES GERAIS	1
1. Introdução.....	1
2. Hipóteses	2
3. Objetivos.....	3
4. Revisão Bibliográfica	3
4.1. Sistemas de produção de pastagens.....	3
4.1.1. Sistemas integrados de produção animal.....	4
4.1.2. Avaliação de massa de forragem.....	5
4.2. Produção e desenvolvimento de amendoim	6
4.2.1. Maturação do amendoim	7
4.3. Sensoriamento Remoto (SR)	9
4.3.1. Níveis de coleta de dados e classificação	12
4.3.2. Balanço de energia x SR.....	14
4.3.3. Evapotranspiração (ET)	15
4.3.4. <i>Simple Algorithm for Evapotranspiration Retrieving</i> - SAFER.....	15
5. Referências	19
CAPÍTULO 2: ESTIMATIVA DE MASSA DE FORRAGEM EM SISTEMAS SILVIPASTORIL E PLENO SOL: AVALIAÇÃO POR MEIO DE SENSORIAMENTO REMOTO PROXIMAL APLICADO AO MODELO SAFER.....	29
Resumo.....	29
1. Introdução.....	30
2. Material e métodos.....	32
2.1. Área experimental	32
2.2. Aquisição de dados	34
2.3. Modelo de estimativa de massa de forragem.....	35
2.4. Análise estatística.....	39
3. Resultados.....	40
3.1. Parâmetros meteorológicos.....	40
3.2. Parâmetro espectral	42
3.3. Massa de forragem estimada	44

3.4. Avaliação dos modelos de regressão linear	48
4. Discussão	51
5. Conclusão	55
6. Referências	56
CAPÍTULO 3: DESEMPENHO DO MODELO SAFER NA ESTIMATIVA DA MATURAÇÃO DO AMENDOIM	62
Resumo:.....	62
1. Introdução.....	63
2. Material e métodos.....	65
2.1. Área experimental	65
2.2. Aquisição de dados – <i>In situ</i>	66
2.3. Aquisição dos dados – Meteorológicos e Espectrais	68
2.4. Modelo SAFER.....	69
2.5. Análise estatística.....	71
3. Resultados.....	72
3.1. Parâmetros climatológicos e espectrais	72
3.2. Evapotranspiração real estimada.....	77
3.3. Avaliação dos modelos de regressão linear	79
4. Discussão	80
5. Conclusão	84
6. Referências	84
7. Material complementar	89
CAPÍTULO 4: CONSIDERAÇÕES FINAIS	90

RESUMO

O sensoriamento remoto (SR) é um importante instrumento na estimativa de parâmetros biofísicos das culturas, e tem possibilitado a criação de metodologias precisas, menos morosas e capazes de considerar a variabilidade dos campos de produção. Aliar o SR a variáveis climatológicas, pode melhorar a precisão de modelos de estimativa de variáveis biofísicas das culturas e ainda considerar as individualidades e adversidades de cada região. Nesse contexto, o *Simple Algorithm for Evapotranspiration Retrieving* (SAFER) combina o comportamento espectral da cultura e dados meteorológicos com o objetivo de estimar a evapotranspiração real das culturas, processo relacionado ao seu desenvolvimento. Dito isso, objetivou-se com esta pesquisa avaliar o potencial do sensoriamento remoto aplicado ao modelo SAFER na estimativa: (i) de massa de forragem em sistemas de produção animal; (ii) na estimativa de maturação do amendoim. O experimento com pastagem foi desenvolvido no estado de São Paulo, Brasil, nos sistemas de produção animal a pleno sol e silvipastoril, por quatro ciclos completos da forragem, com a utilização do sensor proximal CropCircle. Já os experimentos com a cultura do amendoim foram desenvolvidos no estado da Geórgia, EUA em três campos comerciais. A reflectância ao longo do ciclo foi obtida a partir de imagens do satélite PlanetScope. Os resultados demonstraram que o SAFER é um modelo promissor, tendo maior acurácia e precisão para estimar a massa da forragem composta por folhas e caule no sistema silvipastoril. Para o amendoim, a evapotranspiração estimada pelo SAFER apresentou correlação significativa com o índice de maturação.

Palavras-chave: Agricultura digital, massa de forragem, maturação do amendoim, sensor proximal, sensor orbital.

ABSTRACT

Remote sensing is an important tool for estimation of crop biophysical parameters, and has enabled the creation of precise methodologies, less time-consuming and capable of considering the spatial variability of production compounds. Combining this tool with climatological variables can allow better accuracy of estimation models and also consider the individualities and adversities of each region. In this context, the *Simple Algorithm for Evapotranspiration Retrieving* (SAFER) combines the crop spectral behavior and meteorological data, with the objective of estimating the crop real evapotranspiration, a process related to crop development. The objective of this work was to evaluate the potential of remote sensing applied to the SAFER model in estimating: (i) forage mass in animal production systems. (ii) in the estimation of peanut maturity. The pasture experiment was carried out in the state of São Paulo, Brazil, in full sun and silvopastoral animal production systems during four complete forage cycles, using an active crop canopy sensor HOLLAND Scientific model ACS 430. The experiments with the peanut crop were carried out in the state of Georgia, USA in three commercial fields. The reflectance over the cycle was obtained from PlanetScope satellite images. The results showed that SAFER is a promising model in the estimation of forage mass, having greater accuracy and precision to estimate the mass of forage composed of leaves and stem in the silvopastoral system. For peanuts, the evapotranspiration estimated by SAFER showed a significant correlation with the maturity index and made it possible to generate a robust model for estimating this variable.

Keyword: Digital agriculture, forage mass, peanut maturity, proximal sensor, orbital sensor.

CAPÍTULO 1: CONSIDERAÇÕES GERAIS

1. Introdução

Esta tese encontra-se estruturada em quatro capítulos, em que são abordadas diferentes plataformas de sensoriamento remoto, aplicado ao modelo SAFER na estimativa de parâmetros biofísicos de culturas. Este trabalho reveste-se de relevância por aliar dados espectrais e meteorológicos, tornando as estimativas de produção de forragem e de avaliação da maturação do amendoim mais rápidas, precisas e menos exigentes de mão de obra.

No caso das pastagens, a massa de forragem é uma variável de suma importância para indicar a taxa de lotação animal, com melhor aproveitamento do pasto e sem utilizá-lo até à escassez de seus nutrientes. Tratando-se do sistema de produção animal silvipastoril, as estimativas são um desafio diante do componente arbóreo que dificulta a utilização de sensores remotos orbitais e aéreos. Com isso, torna-se necessário buscar alternativas que considerem apenas o comportamento espectral da forragem e nesse sentido os sensores proximais apresentam alto potencial.

Em relação à cultura do amendoim, a identificação da maturação permite indicar o momento ideal para o arranquio da cultura, primeira etapa da colheita. O sensoriamento remoto pode tornar a estimativa de maturação não destrutiva e não subjetiva, além de permitir considerar toda a variabilidade existente dentro de um campo de produção.

Dito isso, no primeiro capítulo é apresentado o referencial teórico que embasa a hipótese de que é possível utilizar o sensoriamento remoto aplicado ao modelo SAFER na estimativa de massa de forragem e de maturação do amendoim, assim como os trabalhos que vêm sendo desenvolvidos nestas vertentes.

No segundo capítulo são apresentados os resultados obtidos a partir do uso de sensoriamento proximal aplicado ao modelo SAFER, trabalhando de forma conjunta os dados

meteorológicos e espectrais na estimativa de massa de forragem. Foram abordados neste capítulo dois sistemas de produção animal, a pleno sol e silvipastoril, tendo o segundo avaliações em diferentes níveis de sombreamento. As áreas de estudo estão localizadas no estado de São Paulo, Brasil e foram acompanhadas por quatro ciclos completos da forragem. O sensor proximal utilizado foi o sensor ativo de dossel CropCircle, que registra a reflectância nos comprimentos de onda do vermelho, borda do vermelho e infravermelho próximo.

No terceiro capítulo o SAFER foi aplicado na estimativa de maturação do amendoim. Foram avaliados três campos comerciais de amendoim do estado da Georgia, EUA, sendo um deles no ano de 2020 e os demais em 2021. Os dados meteorológicos utilizados foram obtidos a partir de estações meteorológicas da Universidade da Georgia, enquanto os dados espectrais foram extraídos de imagens PlanetScope, que disponibilizam a reflectância nas bandas do azul, verde, vermelho e infravermelho próximo.

Por fim, o quarto capítulo é composto das considerações finais, trazendo os principais resultados e conclusões sobre a utilização do sensoriamento remoto aplicado ao modelo SAFER na estimativa de parâmetros de culturas. Além disso, são apresentadas perspectivas de trabalhos futuros.

2. Hipótese

O modelo SAFER tem potencial para estimar a massa de forragem em sistemas de produção animal a pleno sol e silvipastoril, de forma não destrutiva e menos morosa, por meio da utilização de sensoriamento proximal. Além disso, por integrar dados meteorológicos e espectrais é uma ferramenta promissora para a estimativa de maturação do amendoim com o emprego de sensoriamento orbital.

3. Objetivos

- Avaliar o sensoriamento proximal incorporado ao modelo SAFER na estimativa de massa de *Urochloa brizantha* cv. Piatã em sistemas silvipastoril e pleno sol.

- Avaliar o desempenho do modelo SAFER com dados de sensoriamento remoto orbital como método de estimativa do *Peanuty Maturity Index*, variável indicadora do momento ideal do arranquio da cultura.

4. Revisão Bibliográfica

4.1. Sistemas de produção de pastagens

A pecuária, atividade de grande importância no cenário agrícola mundial, ocupa aproximadamente um terço de todo território global livre de gelo, com rebanho mundial de bovinos com cerca de 1 bilhão de animais (Ellis e Ramankutty, 2018; USDA, 2022). Neste contexto, o Brasil destaca-se como detentor do maior rebanho bovino mundial, com aproximadamente 218 milhões de cabeças (IBGE, 2020). A atividade está presente em 21% da extensão territorial do país que equivalem a 178 milhões de hectares (Parente e Ferreira, 2018).

De toda a área ocupada com pastagens no Brasil, aproximadamente 50 milhões de hectares, na região do Cerrado, são ocupados por pastagens cultivadas do gênero *Brachiaria* (Sano et al., 2000). Deste total, estima-se que mais da metade encontra-se em algum nível de degradação (Oliveira et al., 2004). Além de todo o problema ambiental ao entorno da degradação das pastagens, essa situação leva à redução da capacidade de suporte animal, o que leva a perdas bilionárias ao setor de produção de carne bovina (Oliveira et al., 2004). Dentre os fatores responsáveis pela degradação das pastagens, pode-se citar falhas no estabelecimento da pastagem e práticas inadequadas de manejo, como por exemplo, a condução do pasto com quantidade de animais superior à suportada pela área (Dias-Filho, 2011).

Contornar a situação de degradação das pastagens brasileiras é um grande desafio para o setor agropecuário. Segundo Oliveira Silva et al. (2017) a restauração das pastagens pode ser feita a partir da melhora da fertilidade do solo e por meio de intervenções químicas e mecânicas. Outra alternativa é o planejamento forrageiro, que consiste no melhor aproveitamento das pastagens, com adequado dimensionamento do rebanho, baseado na oferta de pasto durante o ano. Além disso, o cultivo consorciado com espécies florestais e agrícolas pode contribuir com maior ciclagem de nutrientes, disponibilidade de matéria orgânica, entre outros.

4.1.1. Sistemas integrados de produção animal

O sistema de produção animal a pleno sol, o mais utilizado no Brasil, consiste no cultivo da forragem como monocultura, não apresentando nenhum outro componente vegetal no sistema interferindo na radiação incidente sobre a pastagem, condição que a deixa mais exposto às intempéries e, conseqüentemente, à degradação.

Diante de um cenário de degradação das pastagens e mudanças climáticas, os sistemas agroflorestais constituem importante estratégia na recuperação dos solos e mitigação de gases de efeito estufa (Takimoto et al., 2008). De acordo com Besar et al. (2020), os sistemas agroflorestais integram, em uma mesma área, cultivos arbóreos de produção de longo prazo e culturas anuais e/ou pecuária. Dentro do contexto de produção animal, os sistemas agroflorestais incluem os sistemas agrossilvipastoril e silvipastoril (Mohamed et al., 2013).

Os sistemas agrossilvipastoris consistem no consórcio de animais com cultivos agrícolas e árvores ou arbustos, de forma simultânea ou escalonada no tempo, em uma mesma área (Oliveira, 2009). Já o silvipastoril, parte do mesmo pressuposto, porém, sem a presença do cultivo agrícola (Oliveira, 2009). Segundo Silva et al. (2020) estes sistemas, além de garantir maior conforto térmico ao animal, promovem maior diversificação da produção, conservação do solo, da água e da biodiversidade.

Em sistemas silvipastoris, o componente arbóreo reduz o escoamento superficial diante de chuvas intensas e, conseqüentemente, auxilia na prevenção de erosão (Benegas et al., 2018). Ademais, as árvores contribuem com o processo de infiltração e armazenamento de água no solo, tornando-se uma estratégia interessante para contornar períodos de seca (Bosi et al., 2020). O sombreamento causado pelas árvores ainda pode gerar melhora na qualidade das pastagens, tendo a forragem maior proporção de massa viva, conforme observado por Pezzopane et al. (2019). Em contrapartida, as árvores podem ter impacto negativo sobre a produção de forragem, uma vez que o sombreamento excessivo pode restringir a quantidade de luminosidade disponível (Reis et al., 2011).

4.1.2. Avaliação de massa de forragem

Como já mencionado anteriormente, uma das principais causas da degradação das pastagens é a superlotação, em que a quantidade de animais colocados na área não respeita a capacidade de suporte do pasto. A definição da lotação animal deve ser baseada na disponibilidade de forragem ao longo do ano, entretanto, o método padrão de obtenção de massa de forragem, que consiste no corte e pesagem do capim, demanda tempo, mão de obra e é inviável de ser aplicado em grandes áreas (Sanderson et al., 2001).

Existem também métodos indiretos, em que a biomassa é obtida por meio de medição de outras variáveis da planta, como por exemplo, a altura do dossel, com utilização de régua graduada (Schmer et al., 2010). Outra metodologia de estimativa de massa de forragem é a da densidade com o disco medidor, também baseada na correlação entre as leituras de altura e densidade da forragem (Dufloth et al., 2015). De acordo com Dufloth et al. (2015), dentre as duas metodologias, a do disco medidor proporciona estimativas de matéria seca de forragem mais precisas.

A busca por estimativas mais precisas dessa variável tem aumentado a aplicação de teorias fundamentadas no comportamento espectral da cultura. Assim, o sensoriamento remoto (SR) é uma ferramenta promissora e que já vem sendo usada para a estimativa de massa de forragem (Pezzopane et al., 2019). Aliar essa ferramenta a dados meteorológicos, de efeito direto sobre o desenvolvimento das plantas, pode contribuir com estimativas ainda mais precisas e acuradas, conforme observado por Chen et al. (2021).

4.2. Produção e desenvolvimento de amendoim

O amendoim (*Arachis hypogaea* L.), cultura adaptada às regiões tropicais e subtropicais, é amplamente cultivada nos continentes africano, asiático e americano (Akram et al., 2018). Os principais países produtores são a China, Índia e Nigéria com produções de 18,2; 6,0 e 4,4 milhões de toneladas, respectivamente (USDA, 2021). No continente americano, os Estados Unidos destacam-se com produção de 2,9 milhões de toneladas (USDA, 2021), enquanto o Brasil é o terceiro maior produtor americano com 0,7 milhões de toneladas.

A alta distribuição do amendoim pelo mundo, sendo ele a quarta oleaginosa mais cultivada ao redor do planeta, pode ser atribuída à sua versatilidade (Ferrari-Neto et al., 2012). Além de ser destinado à produção de óleo vegetal, o amendoim pode ser destinado à alimentação animal, produção de biodiesel e alimentação humana. Nos Estados Unidos, a principal destinação é a alimentação humana, com consumo in natura ou por meio de subprodutos (Tilman e Stalker, 2009).

A produção de amendoim nos Estados Unidos é dividida em dez estados, sendo a Geórgia, responsável por concentrar aproximadamente 50% da produção nacional (NASS, 2021). Na região, o preparo conservacionista do solo para cultivo do amendoim tem aumentado, além de contar com muitas áreas que utilizam da irrigação para complementar as necessidades hídricas da cultura (Santos, 2019).

A temperatura é uma variável meteorológica com impacto direto sobre o crescimento e desenvolvimento da vegetação (Awal et al., 2013). Por ser amplamente cultivado em regiões dos trópicos, o amendoim é uma cultura constantemente exposta a altas temperaturas, inclusive superiores a 40°C. Entretanto, segundo Williams e Boote (1995) citados por Prasad et al. (2000), a faixa de temperatura ideal para o crescimento e desenvolvimento do amendoim é de 25°C a 30°C. Conforme relatado por Cox (1979) a fase reprodutiva da cultura é mais sensível a altas temperaturas do que a fase vegetativa. Estudo realizado por Ketring (1984) demonstrou que em temperaturas superiores à ideal, houve redução no número de vagens maduras, assim como na massa das sementes.

Além da temperatura, outro parâmetro crítico ao desenvolvimento das culturas é a luz (Assunção, 2005). A radiação solar é a fonte principal de energia utilizada em muitos processos físico-químicos da vegetação (Punia et al., 2020). Essa radiação é absorvida pela vegetação em quantidades distintas de acordo com o seu comprimento de onda e contribui, não só para a criação de um microclima interno da planta, mas também em processos essenciais como a fotossíntese, evapotranspiração, e acúmulo de biomassa (Assunção, 2005).

4.2.1. Maturação do amendoim

Por ser uma cultura com desenvolvimento subterrâneo dos frutos, a identificação da maturação das vagens é um grande desafio para a cadeia produtiva do amendoim. A maturação é importante, pois, a partir dela é possível indicar o momento ideal do arranquio da cultura. Essa etapa da colheita, quando realizada com vagens muito maduras, apresenta aumento de perdas oriundas da operação, devido à maior facilidade com que as vagens se desprendem da planta e ficam retidas no solo (Santos et al., 2019). Entretanto, realizar o arranquio com vagens imaturas, reduz a qualidade das sementes, o acúmulo de matéria seca, além de torná-las mais

propensas à presença da aflotoxina, contaminante da saúde humana e animal (Miningou et al., 2021).

A metodologia mais difundida de estimativa de maturação é o método Hull-Scrape (Williams and Drexler, 1981). A identificação se dá pela coloração do mesocarpo da vagem, sendo necessário a remoção do exocarpo. Posteriormente, as vagens são classificadas de acordo com o quadro de maturação (Figura 1). Com base no quadro de maturação, Rowland et al. (2006) estabeleceram o *Peanut Maturity Index* (PMI), que varia de 0 a 1, e é calculado pela razão do somatório das vagens marrons e pretas, pelo somatório de todas as vagens. A indicação para o início da colheita é quando o PMI atinge 0.7 (Rowland et al., 2006).



Figura 1. Quadro de maturação.

Apesar de ser a metodologia mais utilizada, o método Hull-Scrape é subjetivo, uma vez que a classificação depende da interpretação de quem está avaliando (Colvin et al., 2014). Ademais, é moroso e não representa a variabilidade existente no campo de produção decorrente do crescimento indeterminado do amendoim.

Diante disso, métodos alternativos têm sido propostos, principalmente com o intuito de reduzir essa subjetividade. Nesse sentido, Colvin et al. (2014) propuseram um método de análise digital baseado na utilização de um scanner comercial capaz de identificar as diferentes cores de mesocarpo da vagem. Segundo o autor, o método Digital Image Model (DIM) foi bem

sucedido em prever porcentagem de vagens maduras. Já Zou et al. (2019) sugeriram um método de classificação de maturação de amendoim em que não é necessário a remoção do exocarpo das vagens e baseia-se na assinatura hiperespectral das vagens. Os autores encontraram resultados satisfatórios e observaram que as diferenças espectrais nos distintos estágios de maturação estão relacionadas também aos diferentes teores de água nos níveis de maturação.

Na mesma vertente, Sorensen et al. (2020) utilizaram raios-x para determinar a maturação. Em vagens recém arrancadas não obtiveram bons resultados devido à umidade, entretanto, ao aplicar o raio-x em vagens secas, a técnica mostrou-se válida para a estimativa de maturação do amendoim, sem a necessidade de raspagem do exocarpo.

Por mais que estes métodos solucionem o principal gargalo do método Hull-Scrape, a subjetividade, continuam por exigir amostras destrutivas das plantas, assim como alta amostragem a fim de representar a variabilidade dos campos de produção de amendoim. Com isso, o sensoriamento remoto passou a ser utilizado como uma ferramenta com potencial para estimar o PMI, por meio do comportamento espectral do dossel do amendoim, sendo integrado inclusive a ferramentas de aprendizado de máquina (Monsef et al., 2019; Santos et al., 2021; Santos et al., 2022).

4.3. Sensoriamento remoto (SR)

O termo sensoriamento remoto, ciência que permite obter informações de um alvo sem que haja contato direto entre sensor e alvo, foi criado em meados dos anos 1960 e vem sendo utilizado para fins agrícolas desde 1970 (Meneses et al., 2012). O país que deu a início a utilização do SR para o monitoramento da agricultura foram os Estados Unidos, com o lançamento em 1972 do satélite Landsat (Formaggio e Sanches, 2017), primeiro da série que atualmente encontra-se na nona missão. Uma definição mais aprofundada elaborada por Jensen (2007) diz que: “sensoriamento remoto é o registro da informação das regiões do ultravioleta,

visível, infravermelho e micro-ondas do espectro eletromagnético, sem contato, por meio de instrumentos tais como câmeras, escâneres, lasers, dispositivos lineares e/ou matriciais localizados em plataformas como aeronaves ou satélites, e a análise da informação adquirida por meio visual ou processamento digital de imagens”.

Para Formaggio e Sanches (2017) diversas são as aplicações do SR, podendo destacar a realização de estimativas de biomassa e produtividade, mapeamento de distúrbios e estresses, e o mapeamento do desenvolvimento fenológico das culturas. Essas aplicações só são possíveis devido à interação da superfície com a radiação eletromagnética (REM), fundamento na qual baseia-se o sensoriamento remoto. Ao incidir sobre um alvo, a REM proveniente de uma fonte de energia, seja ela o sol ou alguma fonte artificial, pode ser absorvida, refletida ou transmitida (Figura 2). O que define o comportamento da REM são as características físicas e químicas do alvo, e tratando-se de uma superfície vegetada, a região do espectro eletromagnético em que ocorre maior absorção é a do visível, realizada pelos pigmentos fotossintéticos (clorofila, xantofila e caroteno) (Ponzoni et al., 2012).

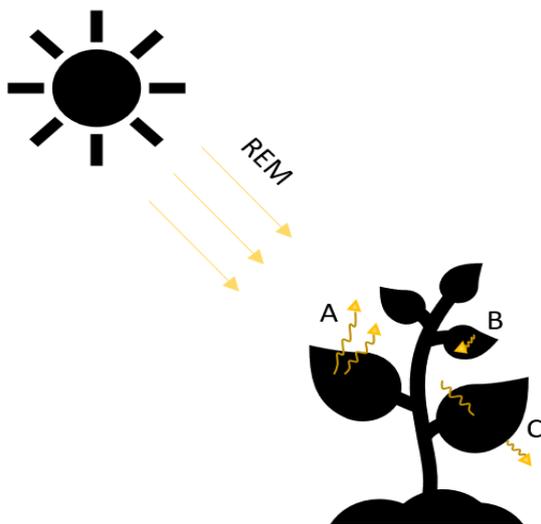


Figura 2. Interação da radiação eletromagnética (REM) com o alvo. A – Reflectância; B - Absortância; C – Transmitância.

Segundo Molin et al. (2015), juntamente à região do visível, a do infravermelho próximo (NIR) compõe a principal faixa de interesse para o estudo de vegetação. Isso porque, no NIR, o comportamento da radiação está relacionado às estruturas celulares e alterações que afetam a absorção, que normalmente é baixa (menos de 15%), com reflectância podendo atingir 50% (Tucker e Garratt, 1977). As condições fisiológicas e morfológicas que afetam diretamente a absorção da radiação em diferentes comprimentos de ondas estão atreladas, principalmente, ao tipo de folha, estágio de maturação e da senescência (Formaggio e Sanches, 2017) (Figura 3). Baseado nisso, a aplicação do sensoriamento remoto na identificação de estádios fenológicos, incluindo a identificação do grau de maturação das culturas pode gerar resultados satisfatórios.

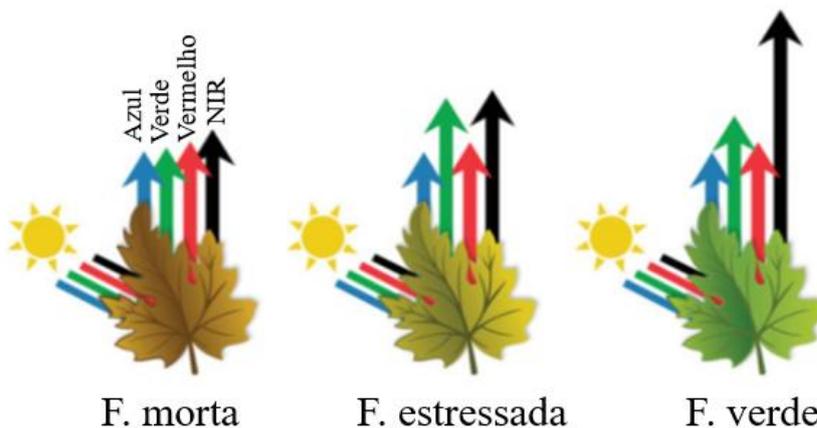


Figura 3. Comportamento da REM diante da vegetação em diferentes condições. F. – Folha; NIR – Infravermelho Próximo. Fonte: Adaptado de blog.droneng.com.br/radiacao-eletromagnetica-e-plantas/.

O comportamento da folha isolada difere-se do comportamento do dossel vegetativo, condição que torna possível a estimativa da biomassa através do sensoriamento remoto. De acordo com Ponzoni et al. (2012), o aumento do número de camadas de folhas acarreta em diminuição da reflectância na região visível do espectro eletromagnético e o aumento na região do infravermelho próximo. Entretanto, culturas com alta densidade de biomassa podem atingir

ponto de saturação, ou seja, mesmo que haja crescimento da vegetação esta não é acompanhada pelos valores de reflectância nas regiões do visível e NIR. Isso ocorre, pois, a partir do momento em que a cultura apresenta o dobro ou triplo de área de folhas em relação à área do terreno, não são observadas alterações de reflectância na região do visível (Ponzoni et al., 2012). Já na região do NIR, essa saturação é atingida quando a relação varia entre 6 e 8, o que torna a utilização dessa faixa do espectro ainda mais importante para estudos da vegetação (Ponzoni et al., 2012).

4.3.1. Níveis de coleta de dados e classificação

Dentro do contexto de sensoriamento remoto existem diferentes níveis de coleta de dados, podendo ser: orbital, aéreo, terrestre/proximal (Figura 4). A definição de qual utilizar deve ser baseada nas condições da área de estudo.

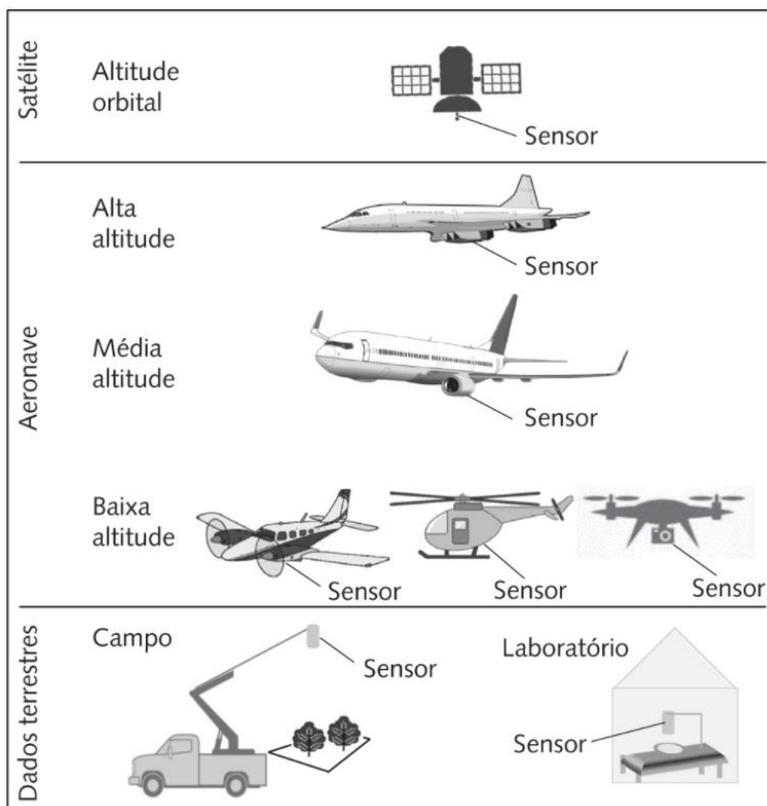


Figura 4. Níveis de coleta de sensoriamento remoto. Fonte: Formaggio e Sanches, 2017.

As principais provedoras de dados de sensoriamento remoto atualmente são as plataformas orbitais, capazes de mapear grandes áreas. Os sensores orbitais comumente utilizados na agricultura, série Landsat e Sentinel-2, são sensores passivos, cujo a fonte de REM é o sol. Atualmente, a constelação de satélites PlanetScope também tem ganhado espaço no meio agrícola por possibilitar o mapeamento em alta resolução espacial.

Entretanto, alguns sistemas agrícolas são limitados à aplicação das plataformas orbitais, como ocorre em sistemas de produção animal silvipastoril. A presença do componente arbóreo dificulta a obtenção da reflectância da pastagem, prejudicando modelos de estimativa. Com isso, recorrer a sensores proximais pode solucionar essa questão. Pezzopane et al. (2019) encontraram resultados satisfatórios ao utilizar sensor proximal na estimativa de massa de forragem em sistemas de produção pleno sol e silvipastoril. O sensor utilizado pelo autor, o Crop Circle ACS-430, é um sensor ativo, que não necessita de radiação solar para seu funcionamento. A REM é emitida pelo próprio sensor, incide sobre o alvo, e o que é refletido é captado pelo sensor, de modo a quantificar a reflectância nos comprimentos de onda do vermelho, infravermelho próximo, e borda do vermelho (região estreita do espectro eletromagnético entre o vermelho e o infravermelho próximo). Além disso, o sensor não é imageador, o que torna sua aplicação mais simples, já que exclui a necessidade do processamento de imagens, processo crítico e até um gargalo pensando em aplicações comerciais.

Além dos níveis de coleta, as quatro resoluções (espacial, temporal, espectral e radiométrica) devem ser consideradas ao escolher um sensor para determinado fim agrícola. Segundo Moraes (2002) a resolução espacial está relacionada à capacidade do sensor em distinguir os alvos. Para Formaggio e Sanches (2017), “corresponde ao tamanho individual do menor elemento da imagem”, o pixel, com isso, objetos individuais só serão detectados quando maiores que o tamanho do pixel. A resolução temporal é a frequência de revisita do sensor sobre

um mesmo alvo. A resolução espectral é baseada em quais faixas do espectro eletromagnético (comprimento de onda/ banda) o sensor opera. Já a resolução radiométrica “é limitada pelo número discreto de níveis de quantização utilizado para digitalizar um valor de intensidade contínuo”, ou seja, o número de BITS (dígito binário) da imagem (Formaggio e Sanches, 2017). Dito isso, o PlanetScope, anteriormente mencionado pela capacidade de mapear com maior detalhamento, é um sensor de alta resolução espacial (3 metros) e temporal (diário), operando nas regiões do visível e infravermelho próximo (Azul (B) – Verde (G) – Vermelho (R) - Infravermelho próximo (NIR)). Por sua vez, o Landsat e o Sentinel-2, possuem resolução espacial de 30 metros (sensor OLI) e 10 metros (RGB-NIR), e intervalo de revisita de 16 e 5 dias, respectivamente, sendo indicados para o monitoramento de áreas mais extensas.

As ferramentas de sensoriamento remoto, dentre as diversas aplicações, constituem uma importante fonte de dados para estudos, em variadas escalas, dos fatores que afetam o desenvolvimento das culturas, como por exemplo o balanço de energia.

4.3.2. Balanço de energia x SR

Os fluxos de energia em sistemas agrícolas exercem grande interferência sobre o desenvolvimento das culturas, tendo impacto direto sobre o processo de evaporação da água e sobre a temperatura da superfície (Gomes, 2009). A quantificação deste fluxo baseia-se no balanço de energia, que por meio do saldo da radiação, permite estimar essa transferência de energia no sistema solo-água-plantas-atmosfera (Fontana et al., 1991). Tratando-se de atividade agrícola, entender o processo de troca de energia entre superfície e atmosfera é fundamental para adequar o manejo das culturas, isso porque afeta o processo de evapotranspiração (ET) e a produção de biomassa (Araújo, 2014), entre outros.

Entretanto, a medição destas variáveis relacionadas ao saldo de radiação é complexa e exigente de equipamentos de alto custo, o que dificulta sua utilização (Majumdar et al., 2007;

Silva, 2018). Além disso, a obtenção de ET realizada por meio de experimentos pontuais a partir de dados de superfície impede a visualização espacial dessa variável (Araújo, 2014). Diante disso, métodos baseados na aplicação de sensoriamento remoto (SR), como o *Simple Algorithm for Evapotranspiration Retrieving* (SAFER), têm sido elaborados com o intuito de mapear, espacial e temporalmente, aspectos ligados aos balanços de energia e água, como por exemplo a evapotranspiração (Teixeira et al., 2010). Além disso, a aplicação de SR para esta finalidade contribui para que áreas mais extensas e heterogêneas sejam manejadas de forma mais adequada, de modo a considerar a variabilidade espacial existente.

4.3.3. Evapotranspiração (ET)

De acordo com Allen et al. (1998) a evapotranspiração é composta pela transpiração dos vegetais e a evaporação da água na superfície do solo. Ainda segundo o autor, além das condições de manejo, a ET sofre interferência das características do meio, assim como das condições meteorológicas.

Para melhor compreensão da ET é fundamental entender conceitos como evapotranspiração de referência (ET_o) e evapotranspiração real (ET_r). Segundo Carvalho, a ET_o corresponde a evapotranspiração de uma cultura hipotética de comportamento similar a um gramado verde (Carvalho et al., 2011). Já a ET_r consiste na quantidade de água translocada para atmosfera oriunda dos processos de evaporação e transpiração, em condições reais atmosféricas e de umidade de solo (Matzenauer 1992).

4.3.4. *Simple Algorithm for Evapotranspiration Retrieving* - SAFER

O Simple Algorithm for Evapotranspiration Retrieving (SAFER), cujo o objetivo é o cálculo da evapotranspiração real com base na equação de Penman-Monteith (Silva, 2018), destaca-se pela facilidade de execução. A ET real (ET_r) é obtida a partir da razão modelada

entre a ET real e de referência (ET_0), cujo os inputs são dados meteorológicos e espectrais (Venâncio et al., 2021) (Figura 5).

O SAFER foi desenvolvido a partir de dados de quatro campos experimentais de culturas frutíferas irrigadas e vegetação natural na região do semi-árido brasileiro (Teixeira et al., 2010). Para a modelagem foram utilizadas sete estações agrometeorológicas, com medições de radiação solar, balanços de energia e água, condições de microclima, juntamente a imagens Landsat-5 e Landsat-7 (Teixeira et al., 2010).

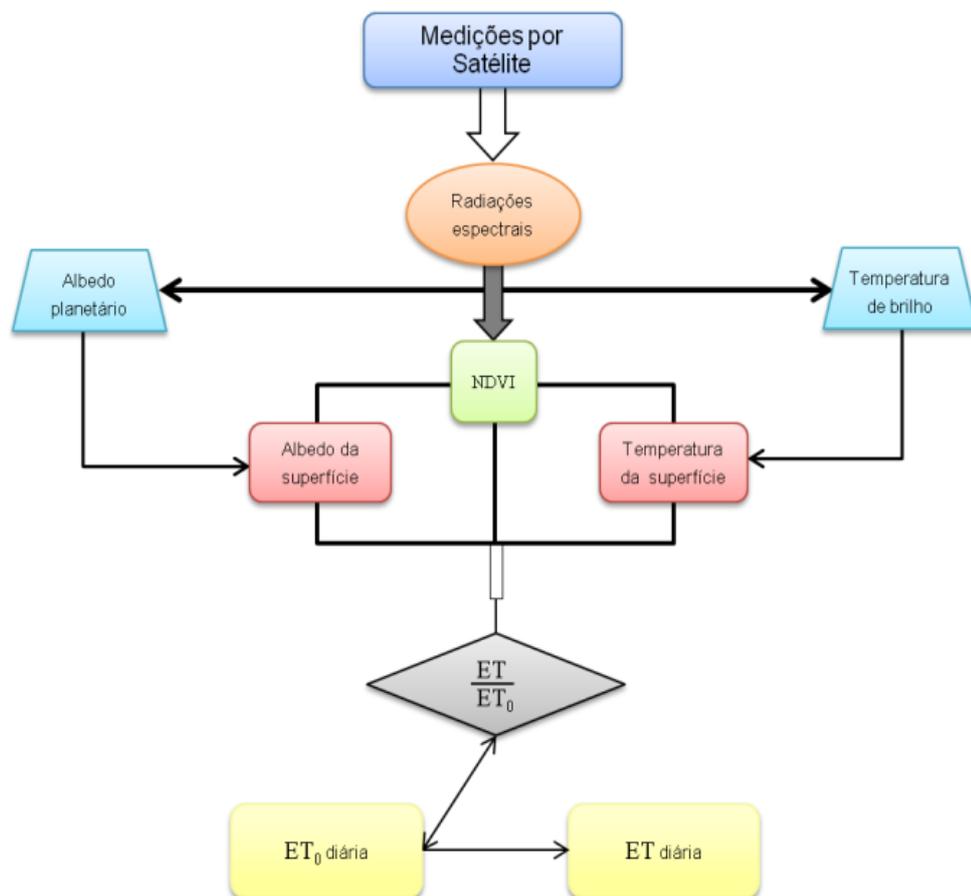


Figura 5. Fluxograma para estimativa de evapotranspiração com aplicação do modelo SAFER.

Fonte: Teixeira et al. (2013).

Os parâmetros de sensoriamento remoto que compõem o modelo SAFER são albedo e o índice de vegetação NDVI (Índice de Vegetação da Diferença Normalizada). O albedo da superfície é definido como a razão entre a radiação solar refletida e a incidente em uma dada superfície terrestre, e a partir disso, modula a quantidade de radiação solar absorvida pelos alvos (Liang et al., 2010; Pang et al., 2022). O cálculo dessa variável tem sido realizado a partir de bandas espectrais nas regiões do visível e infravermelho próximo do espectro eletromagnético, com fatores de correção que variam de acordo com o sensor utilizado (Souza, 2016). O albedo varia de 0 a 1, sendo o menor valor (0) representante de uma superfície perfeitamente negra sem nenhuma reflexão, e o outro extremo (1), a reflexão de uma superfície branca (Padovani, 2017). A partir dessa variável é possível analisar o quanto de radiação de ondas curtas, emitida pelo sol, incide sobre a superfície terrestre (Teixeira et al., 2010)

A utilização dos IVs beneficia avaliações de biomassa, uso da água, sanidade de plantas, além da produção agrícola (Jackson and Huete 1991). Estes são obtidos a partir de cálculos aritméticos com a reflectância em diferentes regiões do espectro eletromagnético. De acordo com Jackson and Huete (1991) usar IVs ao invés de dados de reflectância, reduz efeitos do solo, da topografia e do ângulo de visada sobre a resposta espectral do alvo.

Dentre os IV's, o mais disseminado é o NDVI (Rouse et al., 1973), calculado a partir das bandas do vermelho e NIR. De maneira geral, o maior contraste entre a reflectância destas bandas indica maior vigor da vegetação (Ponzoni et al., 2012). Além de estar relacionada ao processo de fotossíntese, a banda do vermelho é muito utilizada na geração de IVs por ser a banda do visível que sofre menor interferência dos efeitos atmosféricos. Conforme relatado por Ponzoni et al. (2012), quanto menor o comprimento de onda, maior a interferência atmosférica. Através do NDVI é possível criar perfis sazonais e temporais da vegetação, sendo utilizado para detectar estádios fenológicos, mudanças fisiológicas e períodos de senescência (Ponzoni et al., 2012). Segundo Teixeira et al. (2008) e Teixeira et al. (2009), além de ser um indicador de

cobertura de solo, o índice de vegetação possui relação com umidade do solo e com taxas de evapotranspiração no semiárido brasileiro.

A junção destas variáveis à temperatura de superfície e à evapotranspiração de referência, no modelo SAFER, é suficiente para indicar o comportamento do dossel vegetativo, não sendo necessário indicar a espécie agrícola, e/ou o estágio fenológico da cultura. Em sistemas agrícolas de policulturas, ou até mesmo em situações onde a identificação da cultura é difícil de ser feita por imagens de satélite, essa condição torna-se uma grande vantagem do modelo SAFER, frente a outros modelos que necessitam do coeficiente da cultura (k_c). Ademais a facilidade encontrada no SAFER advém também da não necessidade de identificação de condições hidrológicas extremas.

A temperatura de superfície, variável de entrada no modelo SAFER, originalmente foi extraída via sensoriamento remoto (Teixeira et al., 2010). Entretanto, essa condição poderia ser um limitante à aplicação do modelo, já que muitos sistemas de sensoriamento remoto orbital não trabalham com essa faixa do espectro eletromagnético, como é o caso do PlanetScope. Além disso, impediria que sensores proximais e aéreos fossem utilizados para essa finalidade. Com base nisso, Teixeira et al. (2010) sugeriram que em substituição às bandas termais, fossem utilizados, de forma combinada, dados de temperatura do ar oriundos de estação meteorológica e parâmetros de SR. Teixeira et al. (2021a) confirmaram que é possível a utilização SAFER a partir de câmera a bordo de aeronave remotamente pilotada e dados de estação meteorológica. Além de expandir a aplicação do modelo através da utilização de estações meteorológicas, outra importante vantagem do SAFER é que podem ser usadas estações convencionais e automáticas, de modo a proporcionar análise em larga escala espacial e temporal dos componentes do balanço de energia (Araujo, 2018; Teixeira et al., 2012).

Como já mencionado, os coeficientes utilizados nas equações que compõem o SAFER foram desenvolvidos para o semiárido brasileiro com culturas frutíferas irrigadas. A calibração

destes coeficientes para culturas e regiões distintas pode contribuir com a obtenção de estimativas de evapotranspiração mais consistentes, o que coloca o SAFER como um modelo adaptável a condições distintas. Venâncio et al. (2021) ao calibrarem o SAFER para as condições do semiárido da Bahia para o milho irrigado observaram melhor desempenho em relação ao modelo sem calibração dos coeficientes e, com isso, encontraram no SAFER uma ferramenta importante para o manejo da irrigação de precisão. O SAFER também se mostrou promissor na estimativa de evapotranspiração em culturas como coco, cana-de-açúcar e limão (Teixeira et al., 2019; Avilez et al., 2020; Teixeira et al., 2021b).

Outra importante variável agrônômica passível de ser estimada por meio do SAFER é a biomassa. Isso pode ser feito por meio da combinação do modelo SAFER ao modelo de eficiência de uso de radiação de Monteith (EUR). Conforme proposto por Monteith (1972) a EUR é a relação entre o acúmulo de massa vegetal e a de radiação solar interceptada em um mesmo período de tempo. Com base nisso, a energia capturada na fotossíntese é parcialmente convertida em matéria seca e através do modelo EUR é possível estimar em larga escala, a biomassa (Teixeira et al., 2017). Estudos integrando estes dois modelos têm sido realizados com esse objetivo na cultura do milho de sequeiro, em remanescentes florestais, culturas anuais e perenes (Teixeira et al., 2021a; Coaguila et al., 2017). Nas pastagens, estes modelos foram utilizados na estimativa de parâmetros biofísicos e componentes do balanço de energia, e na identificação das classes de degradação (Bayma-Silva et al., 2016; Andrade et al., 2016).

5. Referências

Akram, N.A., Shafiq, F., Ashraf, M. 2018. Peanut (*Arachis hypogaea* L.): A prospective legume crop to offer multiple health benefits under changing climate. *Comprehensive reviews in food science and food safety*, 17(5), 1325-1338.

Allen, R.G., Pereira, L.S., Raes, D., Smith, M. 1998. Crop evapotranspiration Guidelines for computing crop water requirements-FAO. Irrigation and Drainage, v. paper 56, n. 9, p. 318.

Andrade, R.G., Teixeira, A.H.D.C., Leivas, J.F., Nogueira, S.F., 2016. Analysis of evapotranspiration and biomass in pastures with degradation indicatives in the Upper Tocantins River Basin, in Brazilian Savanna. Revista Ceres, 63(6), 754-760.

Araújo, A.L. 2014. Operacionalização do balanço de energia e evapotranspiração em escala regional com dados de sensores orbitais. Tese (Doutorado em Meteorologia) - Universidade Federal de Campina Grande. Campina Grande, 102 p.

Araujo, L.M. 2018. Indicadores agrometeorológicos no Perímetro Irrigado Pontal Sul. Dissertação (Mestrado em Agronomia). Universidade Estadual Paulista “Júlio de Mesquita Filho – Unesp. Botucatu, 168 p.

Assunção, I.C.D.A. 2005. Avaliação da eficiência do amendoim (*Arachis hypogaea* L.) na utilização da radiação fotossinteticamente ativa para produção de matéria seca. Dissertação (Mestrado em Agronomia) de mestrado – Universidade Estadual Paulista “Júlio de Mesquita Filho” – Unesp. Botucatu, 61 p.

Avilez, A.M.A., Hernandez, F.B.T., Galvão, Í.M., Castro Teixeira, A. H. 2020. Determinação dos coeficientes de cultivo e a evapotranspiração real da cana-de-açúcar com o uso do modelo SAFER. Agrometeoros, 28.

Awal, M.A., Ikeda, T., Itoh, R. 2003. The effect of soil temperature on source-sink economy in peanut (*Arachis hypogaea*). Environmental and Experimental Botany 50, 41–50.

Bayma-Silva, G., Teixeira, A.H.C., Victoria, D.C., Nogueira, S.F., Leivas, J.F., Coaguila, D.N., Herling, V.R., 2016. Energy balance model applied to pasture experimental areas in São Paulo State, Brazil. In: Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII. International Society for Optics and Photonics, 99981C.

- Benegas, L., Ilstedt, U., Roupsard, O., Jones, J., Malmer, A. 2014. Effects of trees on infiltrability and preferential flow in two contrasting agroecosystems in Central America. *Agriculture, ecosystems & environment*, 183, 185-196.
- Besar, N.A., Suardi, H., Phua, M.H., James, D., Mokhtar, M.B., Ahmed, M.F. 2020. Carbon stock and sequestration potential of an agroforestry system in Sabah, Malaysia. *Forests*, 11(2), 210.
- Bolonhezi, D., Mutton, M.Â., Martins, A.L.M. 2007. Sistemas conservacionistas de manejo do solo para amendoim cultivado em sucessão à cana crua. *Pesquisa Agropecuária Brasileira*, 42, 939-947.
- Bosi, C., Pezzopane, J.R.M., Sentelhas, P.C. 2020. Soil water availability in a full sun pasture and in a silvopastoral system with eucalyptus. *Agroforestry Systems*, 94(2), 429-440.
- Carvalho, L.G.D., Rios, G.F.A., Miranda, W.L., Castro Neto, P. 2011. Evapotranspiração de referência: uma abordagem atual de diferentes métodos de estimativa. *Pesquisa Agropecuária Tropical*, 41(3), 456-465.
- Chen, Y., Guerschman, J., Shendryk, Y., Henry, D., Harrison, M.T., 2021. Estimating Pasture Biomass Using Sentinel-2 Imagery and Machine Learning. *Remote Sensing*, 13, 603, 1-10.
- Coaguila, D.N., Hernandez, F.B., Teixeira, A.H.D.C., Franco, R.A., & Leivas, J.F. 2017. Water productivity using SAFER-Simple Algorithm for Evapotranspiration Retrieving in watershed. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 21, 524-529.
- Colvin, B., Rowland, D., Ferrell, J., Faircloth, W. H. 2014. Development of a digital analysis system to evaluate peanut maturity. *Peanut Science*, 41(1), 8–16.
- Cox, F.R. 1979. Effect of temperature treatment on vegetative and fruit growth. *Peanut Science* 6(1), 14–17.

- Dias-Filho, M.B. 2011. Degradação de pastagens: Processos, Causas e Estratégias de Recuperação. 4. ed, Belém: MBDF, 215 p.
- Dufloth, J.H., Back, A.J., Passos, R., 2005. Estimativa da produção de pasto através de dois métodos indiretos: Régua (altura) e Disco Medidor (densidade). *Agropecuária Catarinense*, 28(1), 83-86.
- Ellis, E.C., Ramankutty, N. 2008. Putting people in the map: anthropogenic biomes of the world. *Frontiers in Ecology and the Environment*, 6(8), 439-447.
- Ferrari Neto, J., Costa, C.H.M., Castro, G.S.A. 2012. Ecofisiologia do amendoim. *Scientia Agraria Paranaensis*, 11(4):1-13.
- Fontana, D.C.; Berlato, M.A.; Bergamaschi, H. 1991. Balanço de energia em soja irrigada e não irrigada. *Pesquisa Agropecuária Brasileira*, 26(3), 403–410.
- Formaggio, A.R., Sanches, I.D.A. 2017. Sensoriamento remoto em agricultura. *Oficina de Textos*.
- Gomes, H.B. 2009. Balanços de radiação e energia em áreas de cultivo de canade-açúcar e Cerrado no Estado de São Paulo mediante imagens orbitais. Tese (Doutorado em Meteorologia) Universidade Federal de Campina Grande. Campina Grande, 108 p.
- IBGE. Produção de pecuária municipal 2020. p. 1-12.
- Jackson, R.D., Huete, A.R. 1991. Interpreting Vegetation Indices. *Preventive Veterinary Medicine*. 11(3-4), 185-200.
- Jensen, J.R. 2007. *Remote Sensing of the Environment: An Earth Resource Perspective*. 2nd. ed. Upper Saddle River, NJ: Prentice Hall, 592p.
- Ketring, D.L. 1984. Temperature effects on vegetative and reproductive development of peanuts. *Crop Science* 24,877–882.

- Liang, S., Wang, K., Zhang, X., Wild, M. 2010. Review on estimation of land surface radiation and energy budgets from ground measurement, remote sensing and model simulations. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 3(3), 225-240.
- Majumdar, T.J.; Brattacharyya, R.; Chattejee, S. 2007. On the utilization of ENVISAT AATSR data for geological/hydrological applications. *Acta Astronautica*, 60, 899-905.
- Monsef, H.A., Smith, S.E., Rowland, D.L., Rasol, N.A.E. 2019. Using multispectral imagery to extract a pure spectral canopy signature for predicting peanut maturity. *Computers and Electronics in Agriculture*, 162(1), 561-572.
- Monteith, J.L. 1972. Solar radiation and productivity in tropical ecosystems. *Journal of applied ecology*, 9, 747-766.
- Meneses, P.R., Almeida, T.D. 2012. *Introdução ao processamento de imagens de sensoriamento remoto*. Universidade de Brasília, Brasília.
- Miningou, A., Traore, S.A., Kabre, B., Konate, S.E.A.L.M. 2021. Assessment of sixteen varieties of groundnut in two agro ecological zones in Burkina Faso for yield and tolerance to aflatoxin. *African Journal of Agricultural Research*, 17(1), 66-78.
- Mohamed, A.H., Ibrahim, N.I., Ghani, A.N.A. 2013. Agroforestry education and professional level links in Peninsular Malaysia. *Journal of Sustainability Science and Management*, 8(2), 161-170.
- Molin J.P., Amaral L.R., Colaço A.F. 2015. *Agricultura de precisão*. Oficina de Textos: São Paulo, p. 119-153.
- Oliveira, O.C., De Oliveira, I.P., Alves, B.J.R., Urquiaga, S., Boddey, R.M. 2004. Chemical and biological indicators of decline/degradation of *Brachiaria* pastures in the Brazilian Cerrado. *Agriculture, ecosystems & environment*, 103(2), 289-300.

Oliveira Silva, R., Barioni, L.G., Hall, J.J., Moretti, A.C., Veloso, R.F., Alexander, P., Crespolini, M., Moran, D. 2017. Sustainable intensification of Brazilian livestock production through optimized pasture restoration. *Agricultural systems*, 153, 201-211.

Oliveira, T.K. 2009. Sistemas silvipastoris e agrossilvipastoris: integração entre reflorestamento e pecuária. Embrapa Acre-Capítulo em livro técnico (INFOTECA-E).

Padovanni, N.G. 2017. Análise espacial da temperatura e albedo de superfície em bacias hidrográficas. Dissertação (Mestrado em Ciências Ambientais) – Universidade Estadual Paulista “Júlio de Mesquita Filho – UNESP. Sorocaba, 78 p.

Pang, G., Chen, D., Wang, X., Lai, H. W. 2022. Spatiotemporal variations of land surface albedo and associated influencing factors on the Tibetan Plateau. *Science of The Total Environment*, 804, 150100.

Parente, L., Ferreira, L. 2018. Assessing the spatial and occupation dynamics of the Brazilian pasturelands based on the automated classification of MODIS Images from 2000 to 2016. *Remote Sensing*. 10, 1–14.

Pezzopane, J.R.M., Bernardi, A.C.C., Bosi, Crippa, P.H., Santos, P.M, Nardachione, E.C., 2019. Assessment of Piatã palisadegrass forage mass in integrated livestock production systems using a proximal canopy reflectance sensor. *European Journal of Agronomy*, 103, 130–139.

Ponzoni, F. J., Shimabukuro Y. E., Kuplich, T. M. 2012 *Sensoriamento Remoto no Estudo da Vegetação*. Oficina de textos, São Paulo, 2012.

Prasad, P.V.V., Craufurd, P.Q., Summerfield, R.J., Wheeler, T.R. 2000. Effects of short episodes of heat stress on flower production and fruit-set of groundnut (*Arachis hypogaea* L.). *Journal of experimental botany*, 51(345), 777-784.

Punia, H., Tokas, J., Malik, A., Satpal, Rani, A., Gupta, P., Kumari, A., Mor. V.S., Bhuker, A., Kumar, S. 2020. Solar Radiation and Nitrogen Use Efficiency for Sustainable Agriculture. In:

Kumar S., Meena R.S., Jhariya M.K. (eds) Resources Use Efficiency in Agriculture. Springer, Singapore.

Reis, G.L., Lana, Â.M.Q., Lana, R.M.Q., Silva, A.A., Moreira, G.H.F.A., Pereira, F.M., Longo, R.M., Machado, R.M. 2011. Sombreamento e fertilização nitrogenada sobre atributos químicos de solo em uma pastagem de *Brachiaria brizantha* cv. marandu. *Revista Brasileira de Agropecuária Sustentável*, 2(1).

Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W. 1973. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3. Washington. Proceedings...Washington: NASA, Goddard Space Flight Center, 1973. 1, 309-317.

Rowland, D.L., Sorensen, R.B., Butts, C.L., Faircloth, W.H. 2006. Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Science*, 33(2), 125-136.

Sanderson, M.A., Rotz, C.A., Fultz, S.W., Rayburn, E.B., 2001. Estimating forage ass with a commercial capacitance meter, rising plate meter, and pasture ruler. *Agronomy journal*, 93, 1281–1286.

Sano, E. E., Barcellos, A. D. O., Bezerra, H. S. D. 2000. Assessing the spatial distribution of cultivated pastures in the Brazilian savanna. *Pasturas tropicales*, 22(3), 2-15.

Santos, A.F.D. 2019. Método não destrutivo para predição da maturação de amendoim (*arachis hypogaea* l.) utilizando sensoriamento remoto. Tese (Doutorado em Agronomia) – Universidade Estadual Paulista “Júlio de Mesquita Filho” – Unesp. Jaboticabal, 107 p.

Santos, A.F., da Silva, R.P., Zerbato, C., Menezes, P.C., Kazama, E.H., Paixão, C.S.S., Voltarelli, M.A. 2019. Use of real-time extend GNSS for planting and inverting peanuts. *Precision Agric* 20, 840–856.

Santos, A.F., Correa, L.N., Lacerda, L.N., Tedesco-Oliveira, D., Pilon, C., Vellidis, G., Silva, R.P. 2021. High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agric* 22, 1464–1478.

Santos, A.F., Lacerda, L.N., Rossi, C., Moreno, L.A., Oliveira, M.F., Pilon, C., Silva, R., Vellidis, G. 2022. Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear Models and Artificial Neural Networks. *Remote Sens.* 2022, 14(1), 93.

reflorestamento e pecuária. Embrapa Acre-Capítulo em livro técnico (INFOTECA-E).

Silva, S., Oliveira Neto, S.N., Leite, H.G., Alcântara, A.E.M., Oliveira Neto, R.R., Souza, G.S.A. 2020. Productivity estimate using regression and artificial neural networks in small familiar areas with agrosilvopastoral systems. *Agroforest Syst* 94, 2081–2097.

Silva, Y.F. 2018. Uso do algoritmo SAFER para evapotranspiração real na cultura da soja. Dissertação (Mestrado em Agronomia) – Universidade Estadual Paulista “Júlio de Mesquita Filho – Unesp. Jaboticabal. 73 p.

Sorensen, R.B., Butts, C.L. Lamb. M.C. 2020. X-ray technology to determine peanut maturity. *Peanut Sci.* 47, 38– 45.

Souza, J.M.F. 2016. Aplicação do algoritmo SAFER na obtenção da evapotranspiração atual das culturas em condições de cerrado. Tese (Doutorado em Agronomia) – Universidade Federal de Goiás. Goiânia, 95 p.

Takimoto, A., Nair, P.R., Nair, V.D. 2008. Carbon stock and sequestration potential of traditional and improved agroforestry systems in the West African Sahel. *Agriculture, ecosystems & environment*, 125(1-4), 159-166.

Teixeira, A.H.C.; Bastiaanssen, W.G.M.; Ahmad, M.D.; Bos, M.G. 2008. Analysis of energy fluxes and vegetation-atmosphere parameters in irrigated and natural ecosystems of semi-arid Brazil. *J. Hydrol.* 362, 110–127.

Teixeira, A.H.C.; Bastiaanssen, W.G.M.; Ahmad, M–ud–D; Bos, M. G. 2009. Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the Low-Middle São Francisco River basin, Brazil Part A: Calibration and validation. *Agr. Forest. Meteorol.*

Teixeira, A. H. D. C. 2010. Determining regional actual evapotranspiration of irrigated crops and natural vegetation in the São Francisco river basin (Brazil) using remote sensing and Penman-Monteith equation. *Remote Sensing*, 2(5), 1287-1319.

Teixeira, A.H.C.; Hernandez, F.B.T.; Lopes, H.L. 2012. Application of Landsat images for quantifying the energy balance under conditions of land use changes in the semi-arid region of Brazil. *Remote Sensing for Agriculture, Ecosystems, and Hydrology XIV. Anais... . 8531*, 1–9.

Teixeira, A.H.C., Hernandez, F.B.T., Lopes, H.L, Scherer-Warren, M., Bassoi, L.H. 2013. Modelagem espaço temporal dos componentes dos balanços de energia e de água no Semiárido brasileiro. Campinas, Embrapa Monitoramento por Satélite. 32p. (Documentos, 99)

Teixeira, A.H.C. 2017. Sensoriamento remoto para agricultura, ecossistemas e recursos hídricos.

Teixeira, A.H.C., de Miranda, F.R., Leivas, J.F., Pacheco, EP., & Garçon, E.A.M. 2019. Water productivity assessments for dwarf coconut by using Landsat 8 images and agrometeorological data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 155, 150-158.

Teixeira, A., Pacheco, E., Silva, C., Dompieri, M., & Leivas, J. (2021a). SAFER applications for water productivity assessments with aerial camera onboard a remotely piloted aircraft (RPA). A rainfed corn study in Northeast Brazil. *Remote Sensing Applications: Society and Environment*, 22, 100514.

Teixeira, A., Leivas, J., Struiving, T., Reis, J., & Simão, F. (2021B). Energy balance and irrigation performance assessments in lemon orchards by applying the SAFER algorithm to Landsat 8 images. *Agricultural Water Management*, 247, 106725.

Tillman B.L., Stalker H.T. 2009. Peanut. In: Vollmann J., Rajcan I. (eds) *Oil Crops. Handbook of Plant Breeding*, vol 4. Springer, New York, NY.

Tucker, C.J., Garratt, M.W. 1977. Leaf optical system modelled as a stochastic process. *Applied Optics*, 16(3), 635-642.

USDA National Agricultural Statistics Service (NASS). 2021. <https://quickstats.nass.usda.gov/>.

USDA. 2022. *Livestock and Poultry: World Markets and Trade*. Foreign Agricultural Service. 2022. Available online: https://apps.fas.usda.gov/psdonline/circulars/livestock_poultry.pdf

Williams, E.J., Drexler, J.S. 1981. A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2), 134–141.

Zou, S., Tseng, Y.C., Zare, A., Rowland, D.L., Tillman, B.L., Yoon, S.C. 2019. Peanut maturity classification using hyperspectral imagery. *Biosystems Engineering*, v. 188, p. 165–177.

CAPÍTULO 2: Estimativa de massa de forragem em sistemas silvipastoril e pleno sol: avaliação por meio de sensoriamento proximal incorporado ao modelo SAFER¹

Resumo:

A lentidão operacional na execução dos métodos diretos de estimativa de massa de forragem, variável importante para definição da taxa de lotação animal, fez surgir a necessidade de métodos com respostas mais rápidas e maiores abrangências territoriais. Nesse contexto, objetivou-se com este estudo avaliar um método para estimar a massa de *Urochloa brizantha* cv. Piatã em sistemas silvipastoril e pleno sol, por meio de sensoriamento proximal incorporado ao modelo Simple Algorithm for Evapotranspiration Retrieving (SAFER), combinado ao modelo de eficiência de uso de radiação de Monteith (RUE). A pesquisa foi realizada em área experimental da Fazenda Canchim, centro de pesquisa da Embrapa Pecuária Sudeste, São Carlos, SP, Brazil (21°57' S, 47°50'W, 860 m), com coletas de massa de forragem e da reflectância nos sistemas de produção animal silvipastoril e pleno sol. Os dados de reflectância, assim como dados climatológicos obtidos por estação meteorológica instalada na área de estudo, foram utilizados como entrada para o modelo SAFER, e, posteriormente, para o modelo de eficiência do uso da radiação para cálculo de massa verde de forragem. A forragem coletada em campo foi direcionada para o laboratório, separada, pesada e seca gerando as variáveis da pastagem a) massa seca total, b) massa seca total de folha, c) massa seca de folha e colmo e d) índice de área foliar. Com as variáveis da pastagem, *in situ*, e a massa verde, obtida a partir do SAFER, foram gerados modelos de regressão, no qual 80% foram utilizados para treinamento e 20% para teste dos modelos. O SAFER foi capaz de expressar de forma promissora o comportamento das variáveis da forragem, com correlação significativa com todas elas. As variáveis que obtiveram modelo de melhor desempenho de estimativa foram a massa seca de

¹ Artigo submetido à revista European Journal of Agronomy.

folha e colmo, e massa seca de folha nos sistemas silvipastoril e pleno sol, respectivamente. Concluiu-se que a associação do modelo SAFER ao sensoriamento proximal permitiu a obtenção de um método rápido, preciso e acurado de estimativa de forragem.

Palavras-chave: sensor proximal, dados climatológicos, agricultura digital, *Urochloa brizantha*.

1. Introdução

A degradação das pastagens e consequente necessidade de novas áreas para a manutenção da atividade pecuária é realidade em diversas regiões do mundo. Tal condição é cada vez mais frequente devido à crescente demanda por alimento e utilização inapropriada dos recursos naturais. Os principais motivos disso são o manejo inadequado da área juntamente ao pastejo excessivo (Torres et al., 2019; Nesper et al., 2015). Devido a isso, a pecuária tem sido um dos principais vetores de mudança de uso e cobertura da terra, principalmente relacionados com a conversão de florestas no Brasil (Almeida et al., 2016).

Uma forma de evitar a utilização excessiva das pastagens é por meio do dimensionamento do rebanho com base na oferta de pasto durante o ano. Para isso, é fundamental estimar a massa de forragem, amplamente realizada por meio de métodos diretos ou indiretos. Métodos diretos, baseados no corte e na pesagem da forragem exigem muito esforço e são de difícil realização em grandes áreas. Por outro lado, existem diferentes métodos que permitem a estimativa da massa da forragem, como os a partir da medição da altura do dossel forrageiro, partindo do pressuposto da relação entre a altura da planta e produção de massa (Wilm et al., 1944; Schmer et al., 2010). Métodos indiretos como esse ainda necessitam de ampla coleta de dados a campo, podendo a altura ser medida por disco medidor ou régua graduada (Sanderson et al., 2001; Dufloth et al., 2015). Além disso, a execução dos métodos indiretos exige coletas destrutivas para gerar uma ou mais equações de calibração.

Diante dos diferentes métodos de estimativa de massa e de seu caráter operacional e moroso, o sensoriamento remoto surge como alternativa potencial para a obtenção desta estimativa. Por meio do sensoriamento remoto é possível gerar informações de um alvo sem que haja contato direto com este, facilitando assim que culturas sejam monitoradas, inclusive em grandes extensões territoriais. Neste contexto, existem diferentes níveis de coleta de dados no sensoriamento remoto, que vão desde os sensores orbitais aos terrestres, em diferentes altitudes até ao nível de campo, ambos com alto potencial para estimativa de massa das culturas.

Em sistemas como o silvipastoril, que consorcia o cultivo de pastagem com o de espécies arbóreas, a utilização de imagens orbitais pode contribuir para sub ou superestimar a quantidade de massa de forragem na área, em decorrência da mistura espectral. Em situações como esta, a alternativa é a utilização dados de sensoriamento remoto coletados ao nível de campo, aqui chamado de proximal. Assim, as avaliações são realizadas abaixo da copa das árvores, minimizando a influência do dossel arbóreo sobre a refletância registrada pelo sensor. Estes dados de refletância, quando aliados a variáveis climáticas podem ser incorporados em modelos capazes de estimar a evapotranspiração, como o modelo Simple Algorithm for Evapotranspiration Retrieving - SAFER (Teixeira et al., 2013). Ao gerar os dados de evapotranspiração, torna-se possível por meio deste, estimar a massa da vegetação, conforme realizado por Andrade et al. (2016) com pastagens na Bacia Hidrográfica do Alto Tocantins, que obteve resultados satisfatórios na identificação da disponibilidade de forragem em áreas degradadas.

O SAFER é um modelo para obtenção da evapotranspiração real de cultivo baseado na equação de Penman-Monteith (Silva, 2018). A evapotranspiração é estimada por meio de parâmetros biofísicos aliados a dados de estações meteorológicas, não exigindo dados de classificação das culturas e física de radiação (Teixeira, 2012). A possibilidade de usar dados meteorológicos oriundos de diferentes estações é uma grande vantagem desse modelo e amplia

os dados disponíveis para processamento (Teixeira et al., 2013). Além disso, outra importante vantagem do SAFER é não necessitar de informações de bandas termais, fato que possibilita o emprego de uma maior gama de sensores que não dispõem deste tipo de informação (Teixeira et al., 2013).

Estudos com estes modelos têm sido cada vez mais utilizados com o intuito de calcular a massa e produtividade de culturas agrícolas. Trabalhos realizados por Andrade et al. (2015) e Santos et al. (2020) indicaram que o modelo SAFER se mostrou promissor para a estimativa de biomassa do milho e da pastagem. Bayma-Silva et al. (2016) verificaram que o modelo possui alta viabilidade de aplicação para estimativas de parâmetros biofísicos e do balanço energético em pastagem de *Urochloa brizantha* cv. Marandu. Entretanto, este modelo ainda não foi utilizado para realizar a estimativa de massa de forragem em um sistema silvipastoril.

Diante destas questões, o sensoriamento proximal mostra-se uma ferramenta com alto potencial de estimativa da massa de forragem, inclusive em sistemas com restrições, como o caso do silvipastoril. Desta forma, pressupondo-se que o sensoriamento proximal aliado ao uso de dados climatológicos possa ser usado na estimativa de massa de forragem, objetivou-se com este estudo avaliar o sensoriamento proximal incorporado ao modelo SAFER na estimativa de massa de *Urochloa brizantha* cv. Piatã em sistemas silvipastoril e pleno sol.

2. Material e Métodos

2.1. Área experimental

O estudo foi conduzido em área experimental da Embrapa Pecuária Sudeste, São Carlos, SP, Brazil (21°57' S, 47°50'W, 860 m) (Figura 1). De acordo com a classificação de Köppen e Geiger (1928), a região é caracterizada com clima Cwa (clima subtropical úmido), composto por inverno seco e verão chuvoso. O solo na área de estudo é o Latossolo Vermelho-Amarelo distrófico (Calderano Filho et. al., 1998).

Na área de estudo foram avaliados dois sistemas de pastejo: sistema silvipastoril (SILV) em quatro níveis de sombreamento, e sistema a pleno sol, também denominado intensivo (INT) com pastagem de *Urochloa* (syn. *Brachiaria*) *brizantha* cv. Piatã, em pastejo rotacional. No sistema SILV, as árvores de eucalipto (*Eucalyptus urograndis* clone GG100) foram plantadas em abril de 2011, em fileiras únicas, com orientação próxima a leste-oeste em espaçamento de 15 m × 2 m (15 m entre linhas e 2 m entre árvores nas linhas), o que resultou em densidade populacional de 333 árvores ha⁻¹.

A pastagem em ambos os sistemas foi manejada sob lotação rotacionada e ocupada por machos castrados da raça Canchim (3/8 Nelore + 5/8 Charolais), com lotação ajustada de acordo com a massa forrageira no pré-pastejo. O período de ocupação e repouso foram de 6 e 30 dias, respectivamente, com estratégia de manejo animal.

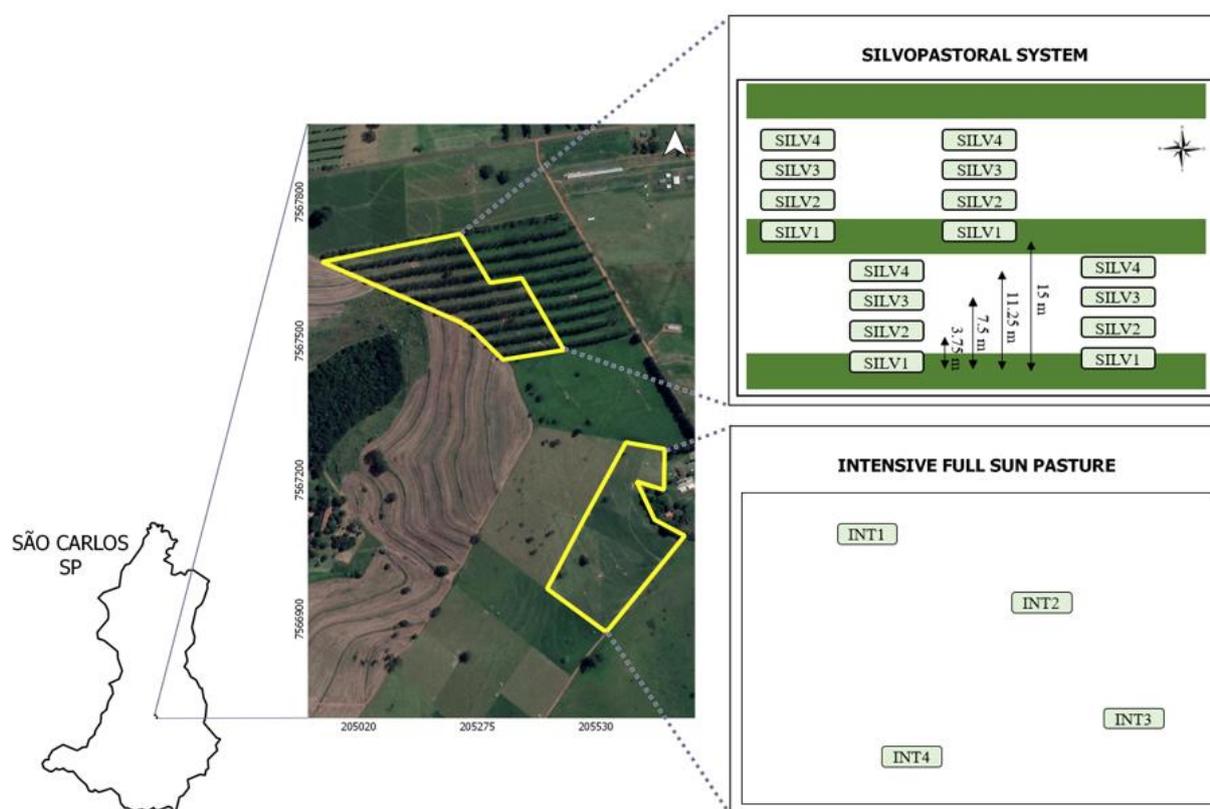


Figura 1. Área experimental (em amarelo) com a estratégia amostral para os sistemas silvipastoril, com diferentes níveis de sombreamento (SILV), e intensivo (INT) - Fazenda Canchim, centro de pesquisa da Embrapa Pecuária Sudeste, São Carlos, SP, Brasil.

2.2. Aquisição dos dados

A estratégia amostral com a localização dos pontos de coleta está exemplificada na Figura 1. As coletas foram realizadas em quatro ciclos completos de crescimento da forragem, de setembro de 2015 a janeiro de 2016, sendo três coletas por ciclo, próximas ao 15°, 22° e 30° dia após o final do pastejo, no horário entre 8 e 9 horas da manhã. No sistema intensivo foram amostrados quatro pontos distribuídos ao acaso no piquete amostral. Já no sistema silvipastoril, a forragem foi amostrada em quatro níveis de sombreamentos. Para isso, as avaliações foram feitas paralelamente entre as linhas de árvores espaçadas em 3.75 m, sendo amostrados quatro pontos para cada nível de sombreamento (Figura 1).

Para a implementação do modelo SAFER, com o intuito de calcular o acúmulo de massa de forragem diária, foram utilizados dados das variáveis climáticas e espectrais da cultura. As variáveis climáticas, radiação fotossinteticamente ativa (PAR), temperatura média e evapotranspiração de referência, foram obtidas em duas estações meteorológicas instaladas nas áreas de estudo. No sistema silvipastoril, os sensores de PAR foram instalados nos diferentes níveis de sombreamento.

Os dados espectrais da forragem foram obtidos utilizando o sensor ACS-430 Crop Circle (Holland Scientific, Lincoln, NE, EUA). O sensor em questão é ativo, emite luz eletromagnética e capta a refletância nos comprimentos de onda centrais 670, 730 e 780 nm, compreendidos nas regiões do vermelho, borda do vermelho e infravermelho próximo, respectivamente.

As leituras foram realizadas em área de 4 m² (2 x 2 m) com sensor posicionado a 0,7 m, aproximadamente, do dossel forrageiro. No mesmo dia da avaliação, do centro desta área foram coletadas as amostras de massa de forragem. A coleta de massa foi realizada pelo método direto, no qual a forragem dentro da moldura de 0.5 x 0.5 m foi cortada rente ao solo. As amostras de massa foram pesadas e tiveram uma subamostra retirada para análise de matéria seca, obtida

após secagem em estufa por 72 h, a 65 °C, e outra para avaliação morfológica, em que foram separadas e pesadas as folhas, caule, e massa morta. De posse da matéria seca e composição morfológica foram calculadas a massa seca total (MST) (massa de folha + colmo + massa morta), massa seca de folha + colmo (MSfc) e massa seca foliar (MSf) em kg ha⁻¹. O índice de área foliar (LAI) foi determinado a partir dos dados de massa seca foliar e medidor de área foliar modelo LI-3100 (Li-Cor, Lincoln, NE, USA). Todas essas variáveis foram utilizadas para a aferição do modelo SAFER, com o intuito de observar qual delas seria melhor relacionada com a massa estimada pelo modelo em cada um dos sistemas de produção.

2.3. Modelo de estimativa de massa de forragem

Para a obtenção do acúmulo de massa de forragem, o modelo SAFER (*Simple Algorithm for Evapotranspiration Retrieving*), capaz de estimar a relação de evapotranspiração, foi aplicado de forma combinada ao modelo de eficiência de uso de radiação de Monteith (RUE). A variável estimada foi tratada como massa verde (MV), em referência a massa com água, uma vez que o modelo emprega variáveis inerentes ao processo de evapotranspiração e o índice de vegetação da diferença normalizada (NDVI).

Para isso, dados espectrais e climáticos foram utilizados como entrada para o modelo SAFER. Inicialmente, com base na refletância nos comprimentos de onda do vermelho (α), borda do vermelho (α_1), e infravermelho próximo (α_2), estimou-se o albedo de superfície (α_0).

$$\alpha_0 = b\alpha + c\alpha_1 + d\alpha_2 \quad (1)$$

Em que: b , c e d - coeficientes de regressão calculados a partir da lei de Planck (Teixeira et al. 2017).

A refletância nas bandas do vermelho e infravermelho próximo foram aplicadas para cálculo do NDVI (Rouse et al., 1973).

$$NDVI = \frac{(\alpha_2 - \alpha)}{(\alpha_2 + \alpha)} \quad (2)$$

A partir da radiação fotossinteticamente ativa (PAR) medida na estação meteorológica, estimou-se a radiação global incidente (R_G).

$$R_G = \frac{PAR}{a_B} \quad (3)$$

Em que: a_B - coeficiente de regressão.

Em seguida, foi calculada a radiação da atmosfera (R_a) por meio da lei de Stefan-Boltzman.

$$R_a = \sigma \varepsilon_A T_a^4 \quad (4)$$

Em que: σ - constante de Stefan-Boltzmann ($5.67 \times 10^{-8} \text{ W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$), T_a - temperatura medida na estação meteorológica, e ε_A - emissividade atmosférica calculada de acordo com Teixeira et al. (2008).

$$\varepsilon_A = \alpha_A (\ln \tau_{sw})^{b_A} \quad (5)$$

Em que: α_A e b_A - coeficientes de regressão, τ_{sw} - transmissividade atmosférica.

Com base no R_G e no albedo de superfície (α_0), os valores de radiação refletida (R_R) foram calculados.

$$R_R = \alpha_0 R_G \quad (6)$$

Como etapa seguinte, para a obtenção da temperatura de superfície (T_0) pelo método residual, foi calculada a radiação líquida (R_n) por meio da equação de Slob.

$$R_n = (1 - \alpha_0)R_G - (a_L \tau) \quad (7)$$

Em que: a_L - coeficiente de regressão, correlacionada com T_a (Teixeira et al., 2008).

De posse dos dados de R_G , R_R , R_a e R_n foi utilizada a equação de balanço de radiação para obtenção da radiação de onda longa emitida pela superfície cultivada (R_s).

$$R_s = R_G - R_R + R_a - R_n \quad (8)$$

T_0 foi então estimado por meio da equação 9.

$$T_0 = \sqrt[4]{\frac{R_s}{\sigma \varepsilon_s}} \quad (9)$$

Em que: ε_s - emissividade da superfície calculada de acordo com Teixeira et al. (2008).

$$\varepsilon_s = a_s \ln NDVI + b_s \quad (10)$$

Em que: a_s e b_s - coeficientes de regressão.

A relação de evapotranspiração foi obtida com base na equação 11.

$$\frac{ET}{ET_0} = \exp[a_{sf} + b_{sf} \left(\frac{T_0}{\alpha_0 NDVI} \right)] \quad (11)$$

Em que: a_{sf} e b_{sf} - são coeficientes de regressão

De posse dos dados de evapotranspiração calculados a partir do modelo SAFER foi estimada a biomassa forrageira diária (MVD) e a radiação fotossinteticamente ativa absorvida (APAR) (Equação 12). A radiação fotossinteticamente ativa absorvida, APAR, constitui a equação de estimativa de MVD (Equação 13) (Monteith, 1972, adaptado por Teixeira et al., 2018).

$$APAR = (-0.161 + 1.257NDVI)(PAR) \quad (12)$$

Em que: PAR - radiação fotossinteticamente ativa.

$$MVD = \sum \left(\varepsilon_{\max} \frac{ET}{ET_0} APAR 0.864 \right) \quad (13)$$

Em que: ε_{\max} - máxima eficiência do uso da radiação. Para o capim Piatã foi utilizado

$$\varepsilon_{\max} = 2.31 gMJ^{-1} \text{ (Bosi et al., 2020).}$$

Apesar de terem sido realizadas avaliações espectrais e em campo em três momentos do ciclo, as estimativas foram feitas diariamente, considerando os dados meteorológicos dos dias exatos, e o comportamento espectral da forragem coletado de forma subsequente. Por exemplo, no 20º dia de avaliação, consideraram-se os dados meteorológicos do próprio dia e os dados espectrais coletados no 22º dia do ciclo. Diante dos resultados de acúmulo de massa de forragem verde diária ($kg\ ha^{-1}$), estes foram somados, de modo a obter a estimativa de massa de forragem condizente aos dias de coleta (MV).

2.4. Análise estatística

Ao final das avaliações em campo, foram totalizadas 192 amostragens no sistema silvipastoril, e 48 no sistema pleno sol, ao final dos quatro ciclos de forragem. O método de resíduos padronizados foi usado para eliminar outliers de valores menores que -2 e maiores que +2 do conjunto de dados. O máximo de outliers retirados do conjunto de dados do sistema silvipastoril foram 11, enquanto no à pleno sol, 2. Em sequência, para análise dos dados, foi realizado teste de Shapiro Wilk para verificar se os dados possuíam a distribuição normal.

Diante de dados não normais para as variáveis (massa verde estimada, massa seca total, massa seca de folha, massa seca de folha e colmo e índice de área foliar), realizou-se Correlação de Sperman a 1% de probabilidade, separadamente para os sistemas silvipastoril e pleno sol.

Modelos de regressão linear foram gerados para cada um dos sistemas entre os dados estimados pelo modelo SAFER e as variáveis da pastagem coletadas *in situ*. Para treinamento dos modelos foi utilizado 80% do total dos dados, e 20% para a etapa de teste. Os valores de coeficiente de determinação (R^2) foram utilizados para analisar o comportamento da massa verde estimada, das demais variáveis e da relação entre elas.

Para avaliar o desempenho dos dados obtidos a partir do SAFER na estimativa de massa de forragem, os dados estimados após essa etapa foram confrontados com os dados observados, por meio de gráfico de performance, R^2 , raiz do erro quadrático médio (RMSE) e, erro relativo (ER) (equações 14 a 16).

$$R^2 = \frac{SQR}{SQT} \quad (14)$$

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |O_i - E_i| \quad (15)$$

$$ER (\%) = \frac{100}{n} \sum_{i=1}^n \left| \frac{O_i - E_i}{O_i} \right|$$

Em que: SQR é a soma dos quadrados da regressão, SQT é a soma dos quadrados totais, O_i é o valor observado, E_i é o valor estimado, n é a quantidade de pontos.

3. Resultados

As estimativas de massa de forragem verde obtidas a partir do modelo SAFER, são baseadas em dados espectrais da cultura e dados meteorológicos da área. Com base nisso, convém analisar as variáveis obtidas a partir de estação meteorológica, como temperatura, precipitação (Figura 2A) e radiação fotossinteticamente ativa (PAR) (Figura 2B). Além disso, foi analisado o NDVI, variável oriunda do comportamento espectral da forragem.

3.1. Parâmetros meteorológicos

As avaliações foram realizadas ao final do inverno, toda primavera e início do verão, sendo possível assim, observar diferentes condições meteorológicas que afetam diretamente o crescimento da gramínea (Figura 2A). No inverno, representado pelos dias do ano (DOY) 246 – 265 observa-se alta queda da temperatura média, atingindo valores menores que 18°C, condição não observada nos demais dias avaliados. A precipitação média ao longo destes 20 dias foi de 7.26 mm d⁻¹, com acúmulo de 145.20 mm.

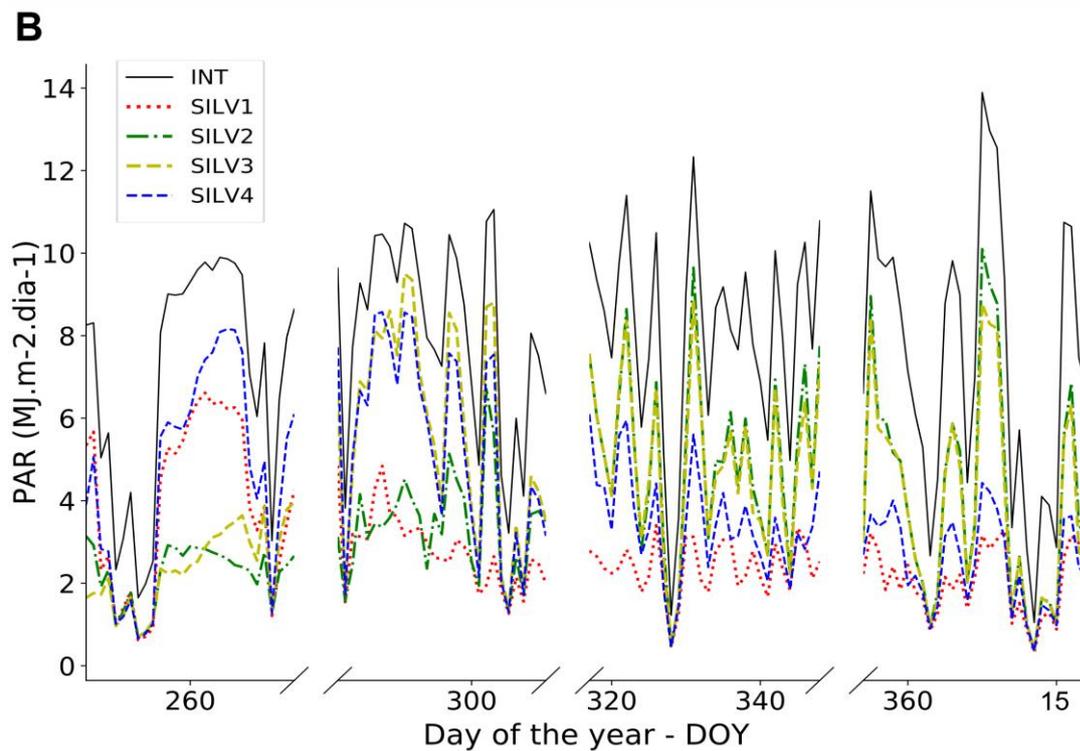
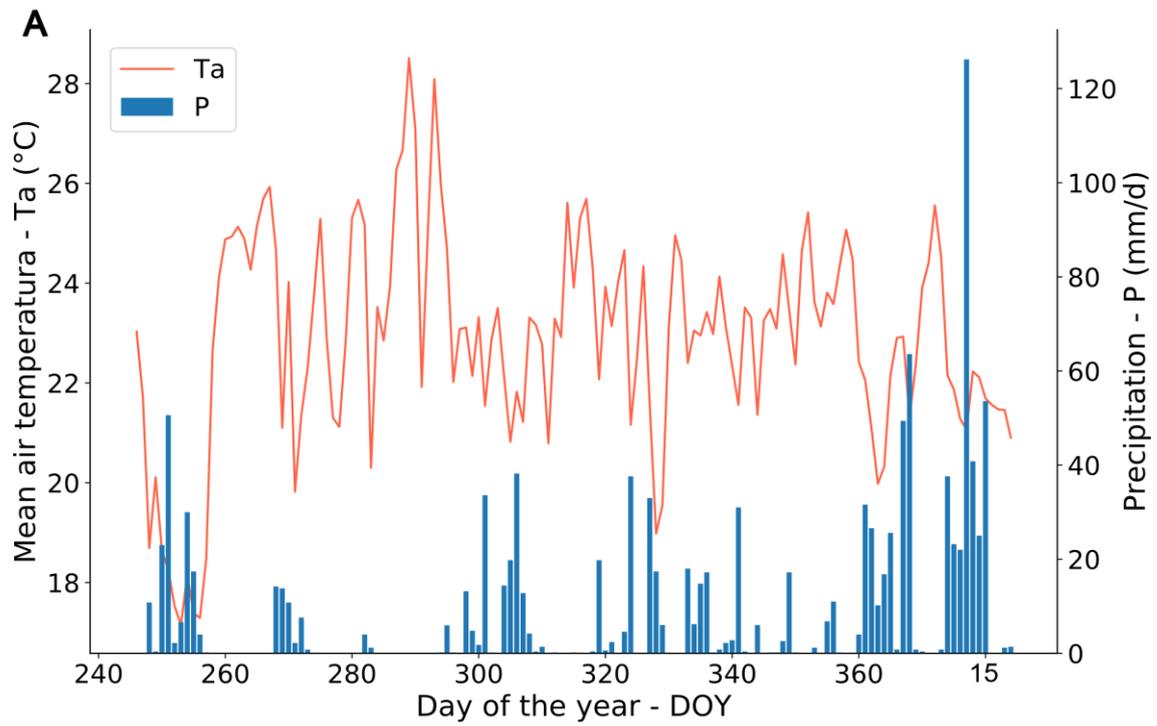


Figura 2. Parâmetros climatológicos para o período de 03/09/2015 a 19/01/2016 São Carlos, SP, Brazil. A – Temperatura média do ar (°C) e Precipitação (mm/dia). B – Radiação fotossinteticamente ativa (PAR) (MJm⁻²dia⁻¹)

Na primavera (DOY 266 – 355) a precipitação média foi de aproximadamente 5 mm d⁻¹, com precipitação máxima não ultrapassando 40 mm em nenhum dos dias avaliados. Quanto à temperatura, observa-se amplitude ao longo da estação de aproximadamente 11°C, com maior temperatura média de 28°C, entretanto, na maior parte dos dias as temperaturas médias variaram de 21 a 25°C. Já no início do verão (DOY 356 – 19), o período em questão apresentou precipitação média de 19.75 mm dia⁻¹. Apesar de apenas um dia ter acumulado 126 mm, choveu em 80% dos dias de verão avaliados, ou seja, as chuvas foram uniformemente distribuídas.

Conforme classificação proposta por Koppen e Geiger (1928), a região caracterizada como Cwa, apresenta período quente e úmido entre os meses de outubro e março. Na Figura 2A esta condição é evidenciada pelo aumento da precipitação e da temperatura ao final do mês outubro (DOY 294), se estendendo até janeiro.

Ao analisar a radiação fotossinteticamente ativa (Figura 2B) é possível observar comportamentos distintos para a pastagem em pleno sol e os quatro níveis de sombreamento na pastagem em sistema integração pecuária floresta. A pastagem em pleno sol, apresentou ao longo de todos os dias avaliados PAR superior às demais condições, fator que contribui para que as plantas deste sistema tenham maior capacidade fotossintética. Isso ocorre devido à ausência de extrato arbóreo acima da vegetação, condição observada nos sistemas SILV, em que as folhas das árvores absorvem parte da radiação PAR, reduzindo a quantidade incidente sobre a pastagem e, conseqüentemente, a produção de massa de forragem. A interferência do eucalipto acontece em diferentes proporções, podendo ser baseada na distância entre o capim amostrado e o renque de árvores, conforme observado na Figura 2B.

3.2. Parâmetro espectral

No primeiro ciclo da forragem, predominantemente inserido no inverno, a pastagem obteve mediana de NDVI próximo a 0.4, nos quatro níveis de sombreamento do sistema

silvipastoril, enquanto no sistema pleno sol foi superior a 0.6, significativamente diferente. O NDVI aumentou no ciclo seguinte, já na primavera, para todas as condições, mantendo-se maior o índice no sistema pleno sol. No terceiro ciclo, o NDVI aumentou novamente, tendo médias muito próximas entre os sistemas e apresentou pequena queda no quarto ciclo, início do verão, mantendo próximas as médias entre os sistemas.

O inverno na região do estudo, característico por ser mais seco e com temperaturas mais amenas (Figura 1A), não favoreceu o desenvolvimento da vegetação, contribuindo para os baixos valores de NDVI no primeiro ciclo. Ainda no primeiro ciclo, assim como no segundo, a maior incidência de radiação fotossinteticamente ativa (PAR) sobre o sistema pleno sol (Figura 2), favoreceu o acúmulo de massa verde em relação aos diferentes níveis de sombreamento no silvipastoril, o que pode ser confirmado pela diferença no NDVI entre sistemas. O aumento do NDVI ao final da primavera e início do verão (3º ciclo) pode ser associado às condições meteorológicas mais favoráveis ao crescimento da forragem (temperatura, precipitação e PAR – Figura 2). Entretanto, os altos valores de NDVI e baixa variabilidade observada no ciclo sugerem saturação em ambos sistemas de produção pecuária, condição decorrente da alta densidade de massa de forragem.

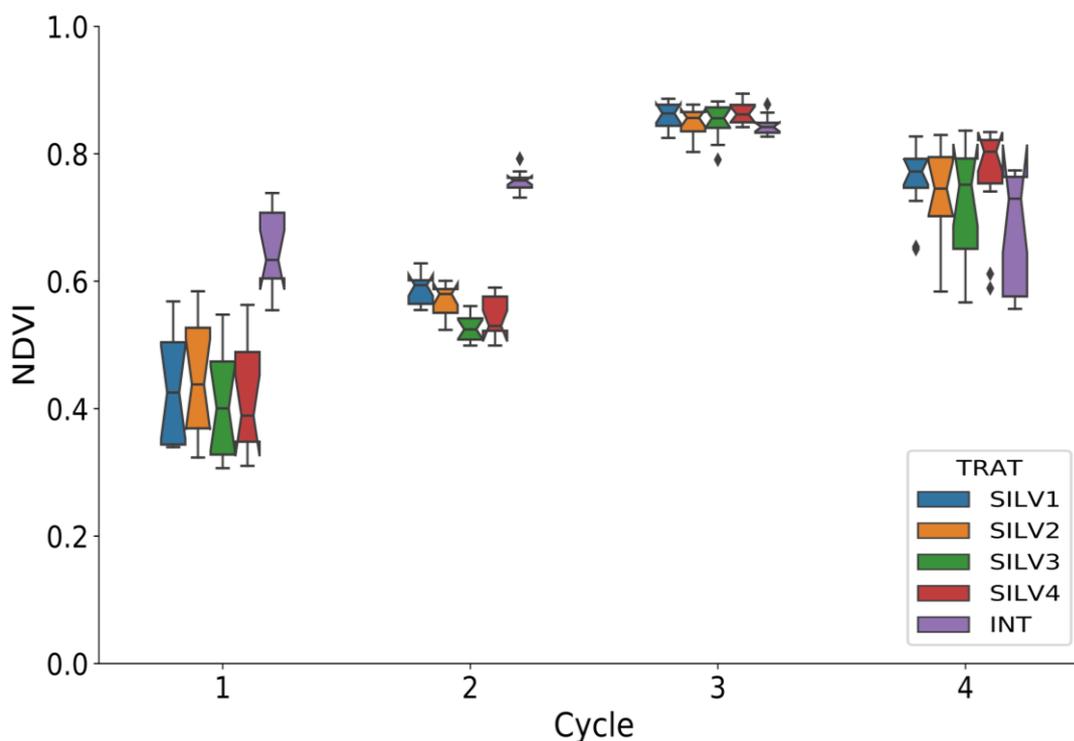


Figure 3. NDVI boxplots at four levels of shading of SILV (SILV1 to SILV4) and INT for the four evaluated forage cycles.

3.3. Massa de forragem estimada

A coleta de dados de NDVI em diferentes níveis de sombreamento no sistema silvipastoril, assim como da radiação fotossinteticamente ativa foi realizada com intuito de alimentar o modelo SAFER com condições reais de campo e considerando a variabilidade de massa na área. Para isso, estes dados foram usados de forma conjunta no SAFER para obtenção de resultados mais robustos no sistema silvipastoril e que representavam de fato a evapotranspiração da forragem, variável necessária para o cálculo de massa verde (kg ha^{-1}). Dessa forma, os modelos mencionados foram aplicados e analisados para duas condições, os sistemas de produção animal silvipastoril e pleno sol.

A relação entre massa verde estimada e as variáveis da pastagem coletadas em campo (massa seca total, massa seca de folha e colmo, massa seca de folha e índice de área foliar) são

relatadas na Figura 4. As relações entre as variáveis da pastagem *in situ* são apresentadas nos gráficos como registro.

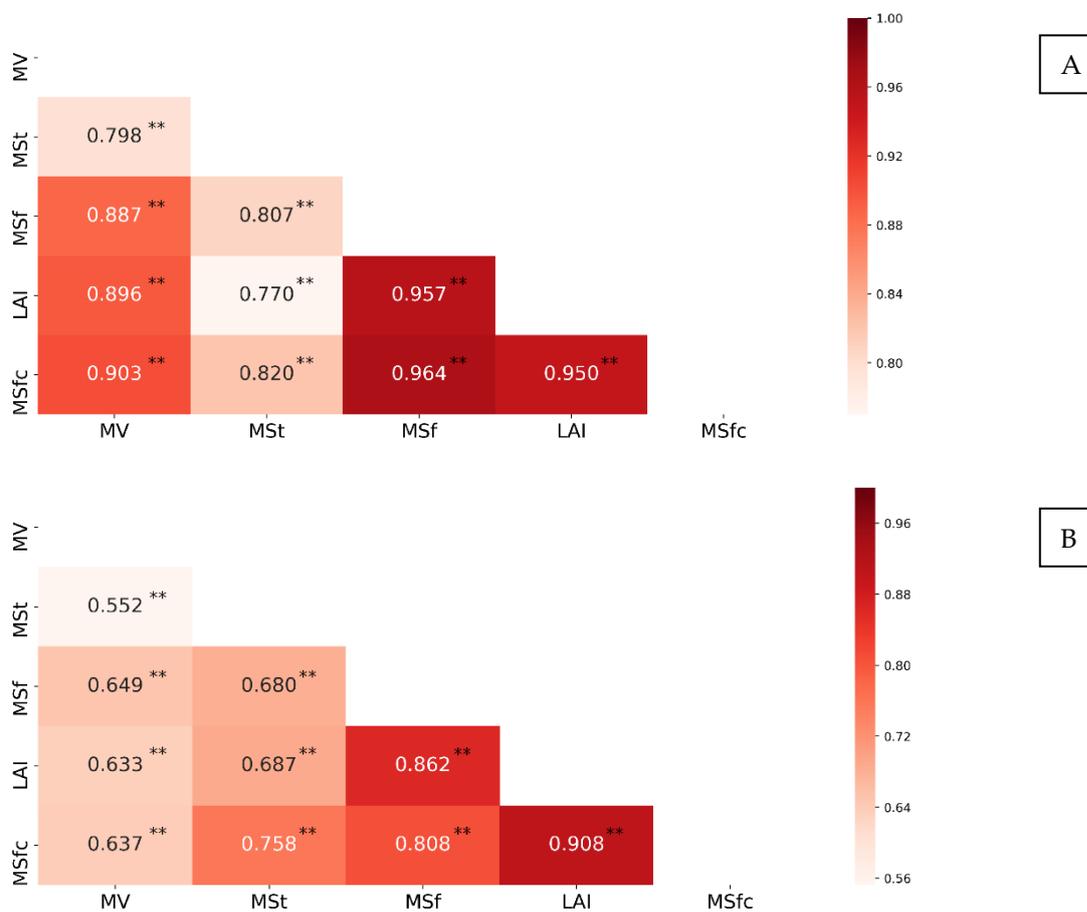


Figura 4. Correlograma entre massa verde estimada (MV) e as variáveis da pastagem *in situ* (massa seca total – MSt; massa seca de folha – MSf; massa seca de folha e colmo – MSfc; e índice de área foliar – LAI). A – Sistema Silvipastoril; B – Sistema Pleno sol. ** = correlação de Sperman significativa a 0.01.

Para o sistema silvipastoril (Figura 4A) verificou-se forte correlação entre a massa verde estimada e as variáveis da pastagem *in situ*, com destaque para a massa seca de folha e colmo (0.903). As variáveis índice de área foliar e massa seca de folha apresentaram correlação de aproximadamente 0.9 com os resultados obtidos a partir do modelo SAFER. Já no sistema pleno sol, as correlações foram inferiores ao sistema silvipastoril, sendo a maior observada para a

massa seca de folha (0.649). As demais correlações foram moderadas com valores 0.637, 0.633 e 0.552 para massa de folha e colmo, índice de área foliar, e massa seca total, respectivamente.

As regressões geradas a partir dos dados estimados e as variáveis da pastagem *in situ* para os sistemas de produção encontram-se nas Figuras 5 e 6. Pode-se observar que as estimativas de massa de forragem no sistema silvipastoril (Figura 5) não ultrapassaram 3000 kg ha⁻¹, com a maior concentração de pontos até 2000 kg ha⁻¹, valores abaixo dos observados em campo. Vale ressaltar que o SAFER foi criado e calibrado para a região do semiárido e isso pode ter afetado os resultados finais de massa verde, mas ainda assim, foi capaz de gerar valores que se correlacionam fortemente com as variáveis da pastagem na região de cerrado. Com isso é possível criar, por meio de regressão linear, modelos entre estas variáveis, sugerindo-se uma validação prévia em campo. Dentre as quatro variáveis da pastagem analisadas, somente a massa seca total apresentou R² inferior a 0.65. A regressão de melhor desempenho foi observada para massa seca de folhas (Figura 5B), com R² de 0.76.

No pleno sol, a massa verde estimada e as massas secas de pastagem foram maiores do que no silvipastoril, situação esperada uma vez que a radiação fotossinteticamente ativa incidente sobre a vegetação é maior (Figura 6). Enquanto a massa verde estimada atingiu aproximadamente 4000 kg ha⁻¹, a massa seca total observada atingiu valores de até 12000 kg ha⁻¹. Novamente, a variável de menor R² foi a massa seca total. A presença de matéria morta tende a reduzir o NDVI, uma vez que há aumento da reflectância no vermelho e redução na região do infravermelho próximo, e, com isso, o NDVI sofrerá interferência do processo de senescência e não refletirá a condição real de biomassa na área. A regressão de melhor adequação no pleno sol foi a massa seca de folha e colmo, seguida do índice de área foliar, ambos com R² de 0.52.

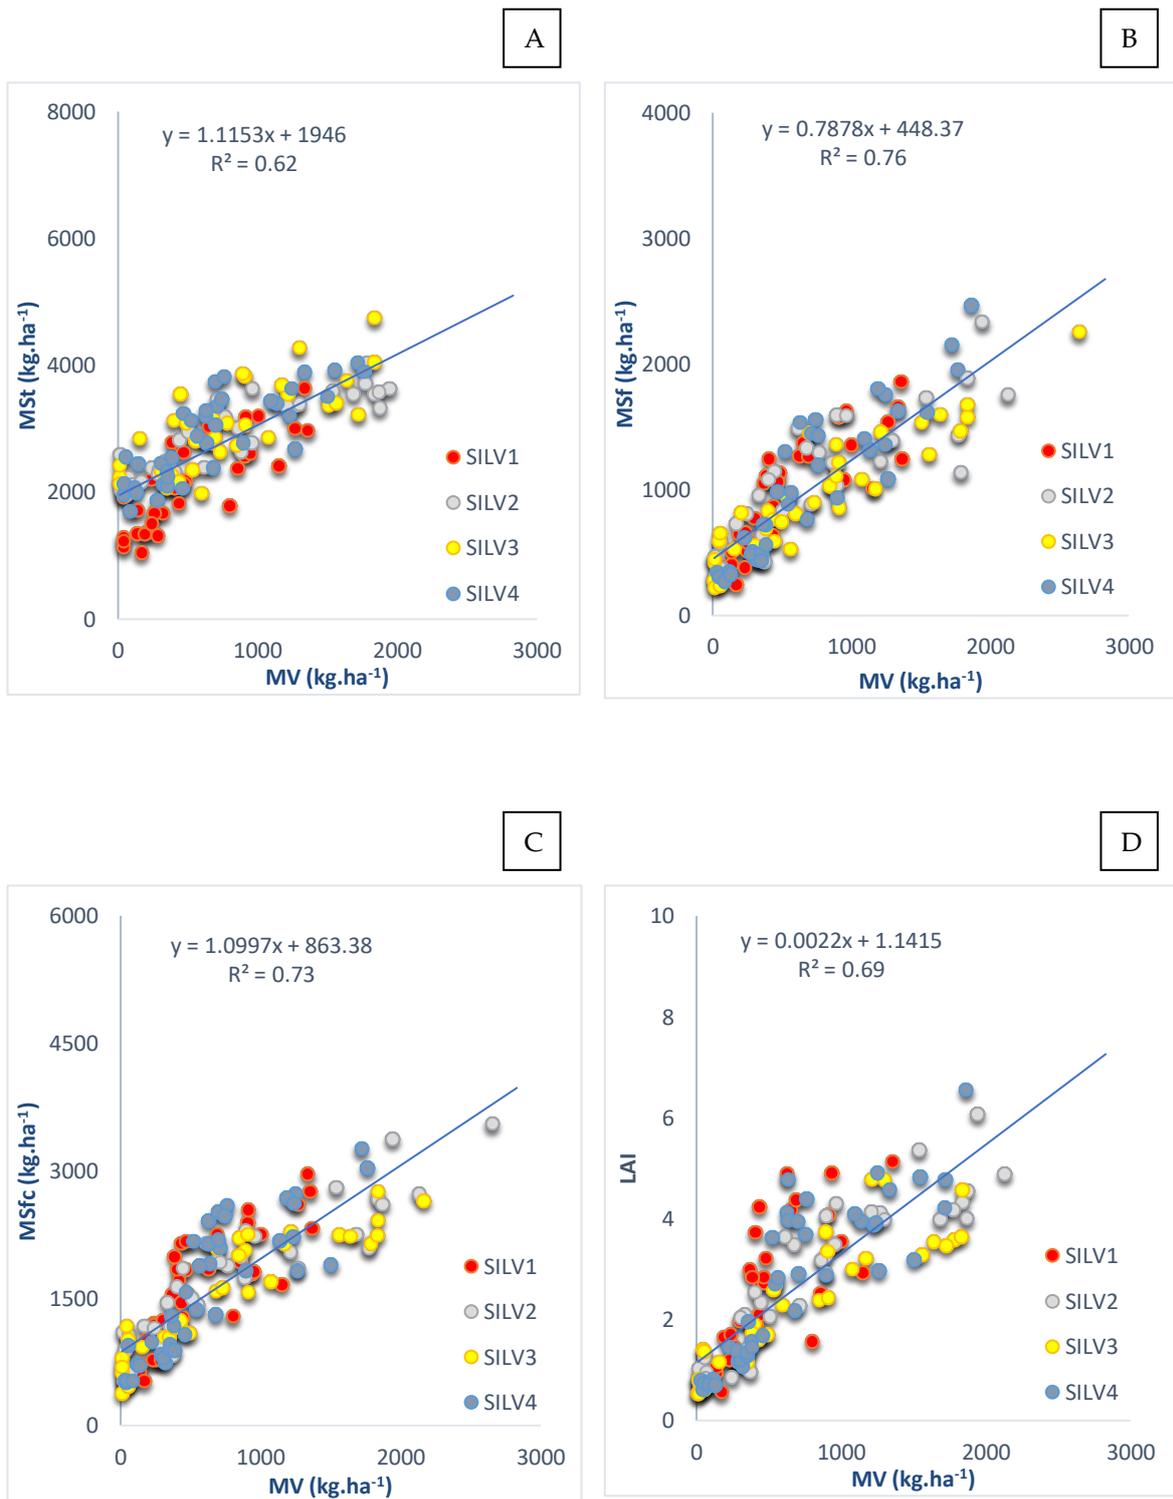


Figura 5. Regressão linear entre massa verde estimada (MV) pelo modelo SAFER e as variáveis da pastagem de capim Piatã em sistema silvipastoril. A – Massa seca total (MSt); B – Massa seca de folhas (MSf); C – Massa seca de folha e colmo (MSfc); D – Índice de área foliar (LAI).

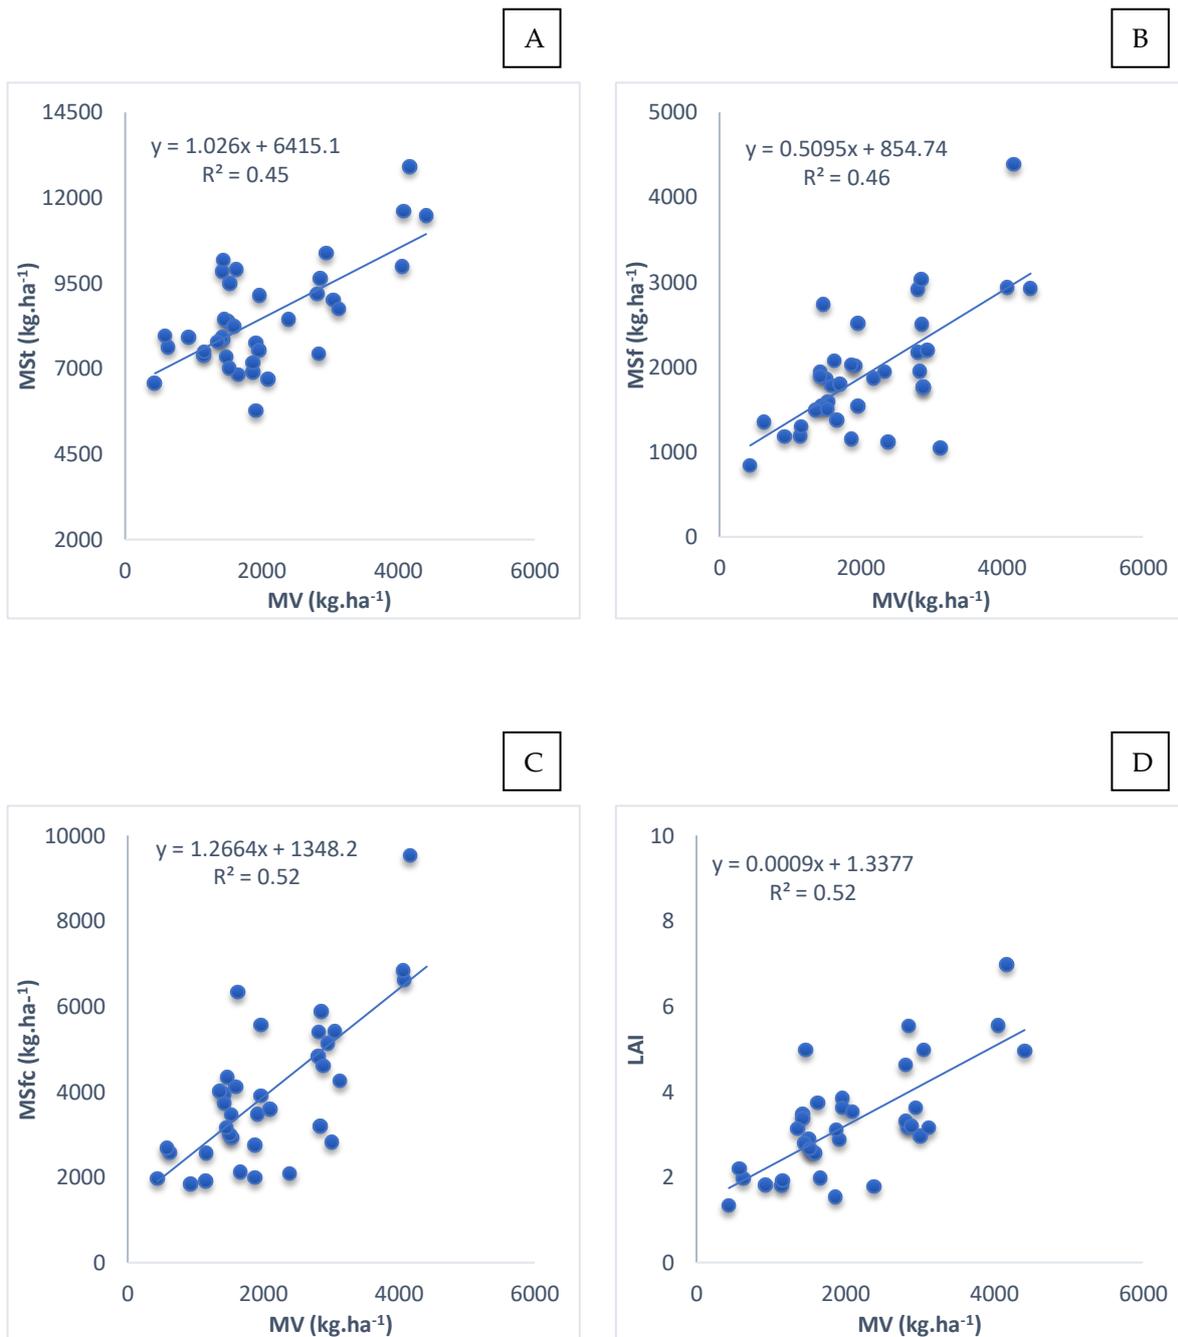


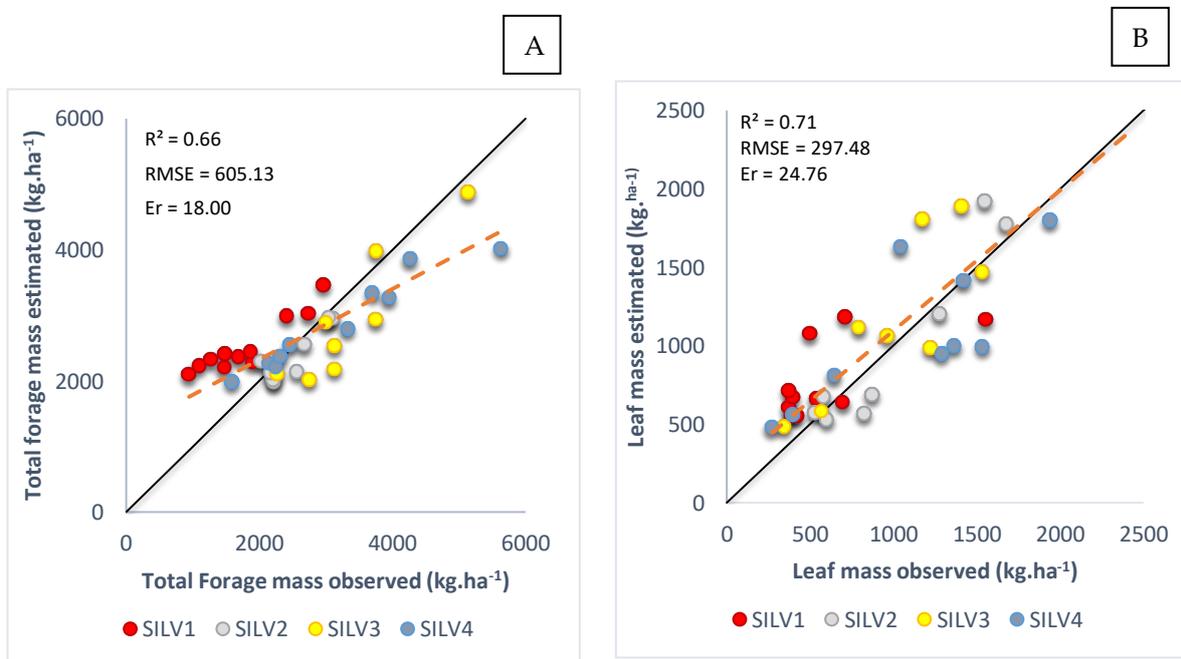
Figura 6. Regressão linear entre massa verde estimada (MV) pelo modelo SAFER e as variáveis da pastagem de capim Piatã em sistema a pleno sol. A – Massa seca total (MSt); B – Massa seca de folhas (MSf); C – Massa seca de folha e colmo (MSfc); D – Índice de área foliar (LAI).

3.4. Avaliação dos modelos de regressão linear

Na Figuras 7 e 8 são demonstradas as relações entre os dados observados e os preditos para os sistemas silvipastoril e pleno sol, respectivamente. No silvipastoril, os modelos

apresentaram melhor desempenho em relação ao pleno sol. Das variáveis avaliadas, o modelo obtido a partir da massa seca de folha e colmo (MSfc – Figura 7C) destacou-se por ter a reta ajustada e os valores de predição mais próximos a linha 1:1, com maior precisão expressa por R^2 de 0.88 e maior acurácia, com erro relativo de 15.19%. No modelo em questão, o erro quadrático médio foi de 290.32 kg ha⁻¹. O nível de sombreamento SILV3 e SILV1 foram os que apresentaram maiores erros de predição, e o SILV2 menor erro. O modelo utilizando massa seca de folha (MSf – Figura 7B) também apresentou bons resultados, tendo R^2 de 0.71, porém com Er de 24.76%.

No sistema pleno sol, o modelo que apresentou maior precisão, foi o com massa seca de folha (Figura 8B) com R^2 de 0.60. Ao analisar a acurácia, a massa seca total (Figura 8A) gerou modelo de melhor desempenho, com erro relativo de 10.30%. A reta que se ajustou melhor à linha 1:1 foi para massa seca de folhas (Figura 8B).



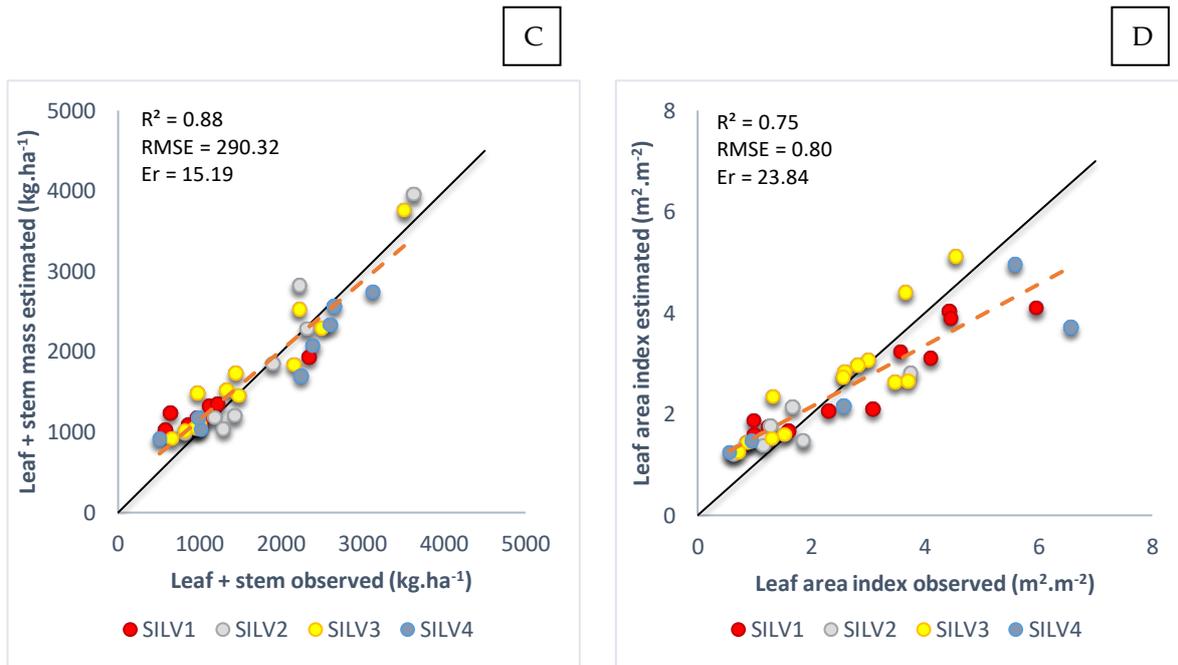
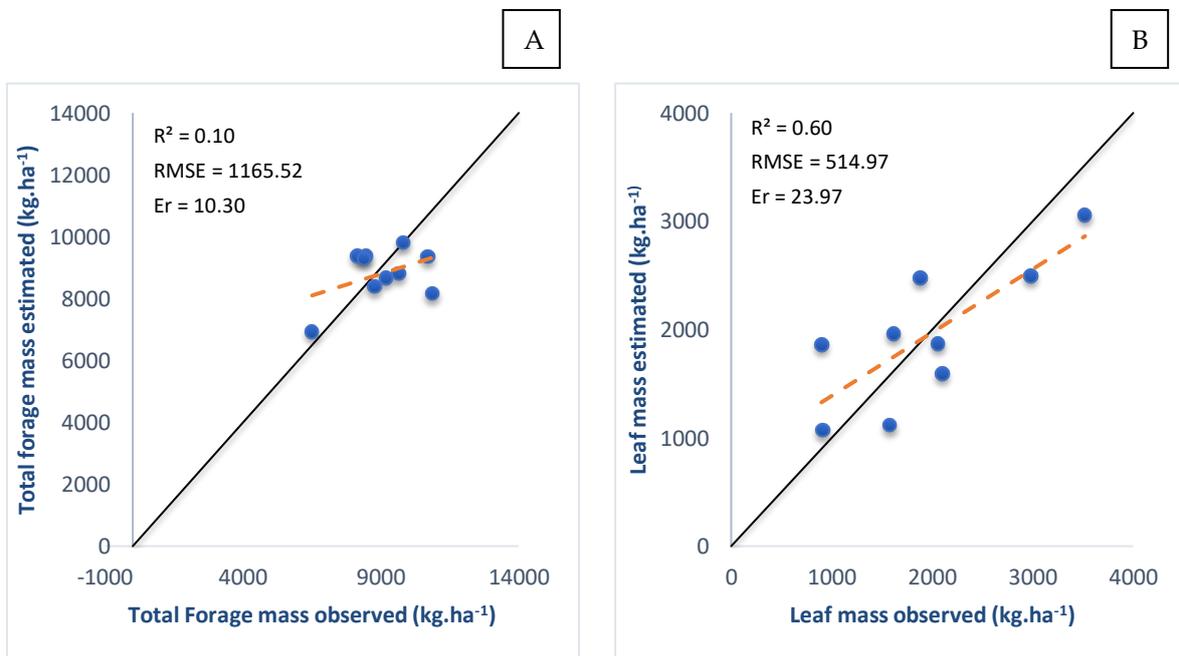


Figura 7. Relação entre variáveis observadas e estimadas de pastagem de capim Piatã em sistema silvipastoril. A – Massa seca total (MSt); B – Massa seca de folhas (MSf); C – Massa seca de folha e colmo (MSfc); D – Índice de área foliar (LAI).



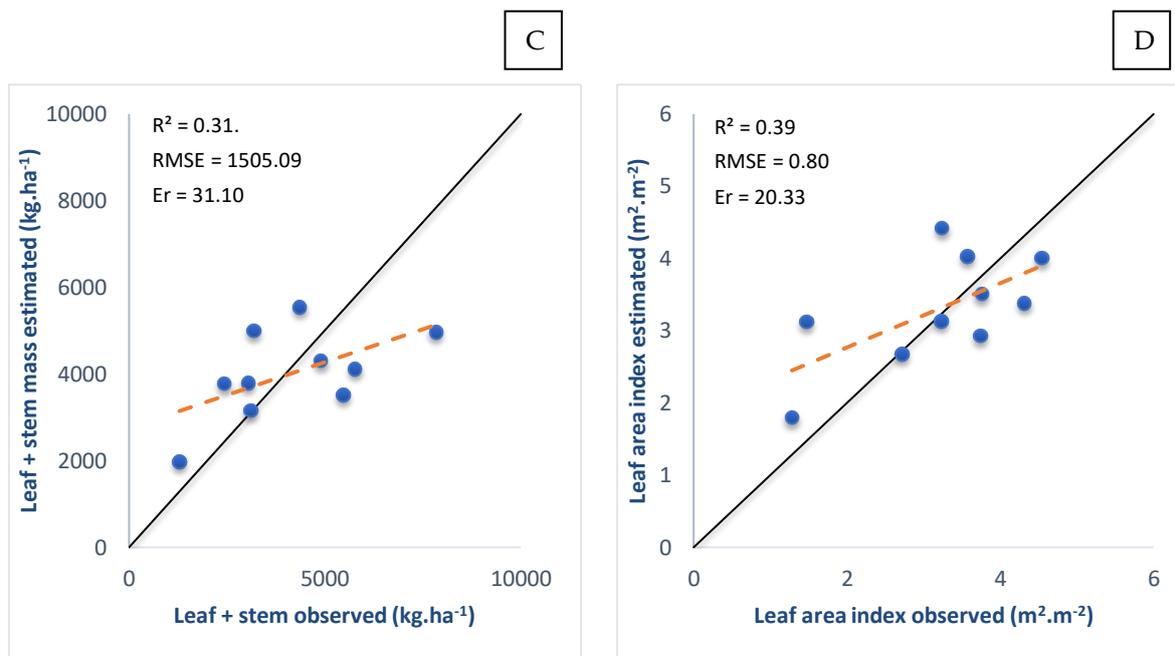


Figura 8. Relação entre variáveis observadas e estimadas de pastagem de capim Piatã em sistema a pleno sol. A – Massa seca total (MSt); B – Massa seca de folhas (MSf); C – Massa seca de folha e colmo (MSfc); D – Índice de área foliar (LAI).

4. Discussão

A quantidade de massa de pastagem disponível é uma informação de grande importância para a definição da taxa de lotação animal. A metodologia mais disseminada para a estimativa dessa variável é por meio de métodos diretos baseados no corte e pesagem da forragem (Sanderson et al., 2001). A dificuldade de aplicação em grandes áreas, necessidade de amostras destrutivas, e a alta demanda de tempo para execução tornam necessária a busca por métodos rápidos e que considerem a alta variabilidade existente em campo.

A metodologia apresentada neste trabalho propõe a estimativa de massa de forragem considerando as particularidades de dois sistemas de produção pecuária, em que as pastagens são conduzidas a pleno sol e em sistema silvipastoril por meio de dados de sensoriamento remoto e meteorológicos. Na primeira etapa, a obtenção de massa verde a partir do SAFER gerou resultados inferiores às massas secas de amostras coletadas em campo para ambos os sistemas, entretanto, conseguiu expressar de forma promissora o comportamento de

crescimento da *Urochloa* (syn. *Brachiaria*) *brizantha* cv. Piatã, condição demonstrada pela análise de correlação com as variáveis da pastagem (Figura 4). Pode-se relacionar os bons resultados ao fato de terem sido utilizadas como entrada no SAFER, variáveis altamente associadas à processos bioquímicos da planta como radiação fotossinteticamente ativa, temperatura do ar, evapotranspiração de referência, e eficiência máxima da cultura, além de NDVI e albedo da superfície, oriundos do comportamento espectral da vegetação (Carneiro et al., 2020, Teixeira et al., 2013).

Entre os dois sistemas de produção animal, o que apresentou modelos com melhor desempenho entre massa verde e as variáveis da pastagem *in situ* foi o silvipastoril (Figura 7). Tal condição pode ser associada à maior variabilidade do NDVI ao longo dos ciclos avaliados na forragem sombreada, uma vez que os modelos de regressão linear são mais sensíveis a grandes variações. Por ser uma das variáveis da entrada do SAFER, o NDVI influencia o balanço de energia e a massa verde gerada a partir da equação de Monteith. No sistema silvipastoril, a variabilidade de massa seca de forragem coletada em campo é acompanhada pela variabilidade do NDVI (Figura 3). Entretanto, no sistema pleno sol, a variabilidade de massa seca no campo é maior que no sistema silvipastoril e o NDVI obteve menor variabilidade ao longo dos ciclos. Este fato pode ser atribuído ao processo de saturação do NDVI na presença de altas densidades de biomassa (Mutanga and Skidmore, 2004; Carneiro et al., 2020). Enquanto foram observadas MS total de 6574.70 até 11607.35 kg ha⁻¹ no pleno sol, a massa de forragem no silvipastoril variou de 945.19 a 5626.32 kg ha⁻¹.

Outro fator que pode ter contribuído para a obtenção de modelos mais precisos e acurados no sistema silvipastoril é a maior fração viva da massa, constatada a partir da menor diferença entre a massa seca total e a massa seca de folha e colmo (Figura 5A e 6C), condição também relatada por Paciullo et al. (2011) e Pezzopane et al. (2017). De acordo com Barnes et al. (2014), a presença de material senescente afeta negativamente a relação do índice de

vegetação e a biomassa, material esse presente em maior proporção no sistema pleno sol. Isso ocorre porque o processo de senescência da vegetação tem impacto sobre a reflectância em diferentes comprimentos de onda, logo, alterações no NDVI podem ser atribuídas não somente a quantidade de massa de forragem, mas também ao processo de morte do tecido (Di Bella et al., 2004; Van Leeuwen and Huete, 1996).

Para o sistema silvipastoril (Figura 7), o modelo que apresentou melhor desempenho foi entre a massa verde gerada pelo SAFER e a massa seca de folha e colmo (MSfc). No sistema pleno sol (Figura 8), apesar de maior acurácia para o modelo com massa seca total, os pontos encontram-se concentrados entre 7000 e 11000 kg ha⁻¹, aproximadamente, o que poderia prejudicar estimativas em que as massas estivessem fora dessa faixa. O modelo com melhor precisão no sistema foi o que utiliza massa seca de folha. Definir a taxa de lotação animal com base nessas variáveis da pastagem é vantajoso, uma vez que desconsidera o material morto ainda na planta, fator limitante a qualidade da forragem com menor valor nutritivo (Pullanagari et al., 2017).

O SAFER, modelo que permite estimativa de parâmetros do balanço de energia, foi desenvolvido e validado para o semiárido brasileiro e com imagens Landsat, sensor imageador a bordo de satélite com características distintas ao sensor CropCircle (Teixeira et al., 2013). A região no qual foi desenvolvido possui maior temperatura média do ar e menor precipitação anual frente ao município de São Carlos, onde este trabalho foi realizado. Tais aspectos afetam a evapotranspiração, logo, a calibração do modelo, em específico dos coeficientes de regressão da relação de evapotranspiração (Equação 11), para a região do cerrado paulista, poderia contribuir com melhores resultados, conforme realizado por Venancio et al. (2021) para a cultura do milho na região do semiárido da Bahia. Por se tratar de uma etapa morosa e exigente de medições de variáveis climáticas não disponíveis para as áreas experimentais, a calibração não foi realizada neste trabalho. Ainda assim, os modelos criados com a massa verde calculada

a partir de SAFER mostraram-se propícios à estimativa de parâmetros da pastagem, em especial, no sistema silvipastoril.

Apesar de já ter sido aplicado em pastagens com imagens MODIS, permitindo encontrar massa verde de forragem de até $2500 \text{ kg ha}^{-1}\text{mês}^{-1}$ para pastagens em diferentes níveis de degradação, Andrade et al. (2016) não validaram os dados estimados pelo SAFER com dados reais de campo. Com base no que foi abordado, este trabalho é de relevância e de caráter inovador, uma vez que confronta os dados estimados pelo SAFER com dados reais para pastagem.

Além disso, já foram utilizados dados de plataformas orbitais e aéreas como entrada no modelo SAFER, mas não foi encontrado na literatura o emprego com dados de sensores não imageadores e proximais como o CropCircle. Assim como descrito nos trabalhos com imagens orbitais, em que imagens Landsat 8 utilizadas com SAFER permitiram estimar variáveis do balanço de energia (Dehziari and Sanaieejad, 2019; Teixeira et al., 2021a), Teixeira et al. (2021b) observaram aplicação bem sucedida de imagens de sensor multiespectral a bordo de aeronave remotamente pilotada (RPA) para obtenção da produtividade da água a partir do SAFER. As características/resoluções destes sensores, assim como a distâncias dos alvos no momento de aquisição dos dados acarretam resultados distintos de um mesmo alvo. Além disso, os imageadores até então utilizados são passivos e estão propensos a influência da fonte de radiação e interferência atmosférica (Jorge et al., 2017). Por mais que não se tenha atingido valores de massa verde pelo SAFER com sensor proximal condizentes com os dados coletados em campo, pode-se afirmar com base na correlação que a sua aplicação foi promissora, permitindo gerar modelos de regressão linear acurados e precisos para estimativa das variáveis da pastagem. Os modelos do sistema silvipastoril na fase de teste apresentaram desempenho superior à relatados na literatura, inclusive com aplicação de machine learning (Chen et al., 2021; Bispo et al., 2020; Pezzopane et al., 2019).

Pezzopane et al., 2019 ao aplicarem dados de sensoriamento proximal na estimativa de massa de forragem (folha + caule) observaram modelos de melhor desempenho em sistema de produção animal sombreado quando comparado a sistema pleno sol. Ainda assim, o melhor R^2 encontrado, com índice de vegetação MSR, foi de 0.67, com erro relativo de 25.9%. Ao utilizar modelo gerado a partir da junção do NDVI e altura da planta, oriunda do sensor LIDAR, Schaefer e Lamb (2016) obtiveram estimativas de forragem mais precisas do que ao empregar modelos com apenas o NDVI como entrada. A aplicação combinada de dados de sensoriamento remoto orbital e dados climáticos por meio de redes neurais artificiais, realizada por Chen et al., 2021, mostrou-se mais promissora na estimativa de forragem do que quando realizada somente com dados de Sentinel-2. Com base nisso, a metodologia proposta neste trabalho une variáveis que apresentaram algum tipo de sucesso na estimativa de forragem, dados de sensoriamento proximal e climáticos.

A opção pelo sensor proximal foi feita considerando a disposição da forragem no sistema silvipastoril. A presença do componente arbóreo, neste caso o eucalipto, influenciaria no valor de reflectância do pixel caso fossem utilizadas imagens de satélite com acesso gratuito, causando mistura espectral entre a brachiaria e o eucalipto, o que levaria a erros de estimativa. Outro fator importante, é a intenção de facilitar a disseminação do método e torná-lo o mais usual possível. Por não gerar imagens que exigem conhecimento para processamento e interpretação, a aplicação passa a ser mais simples, possibilitando que inclusive produtores menos tecnicizados consigam aplicá-lo.

5. Conclusão

Este estudo propõe avaliar metodologia de estimativa de massa de forragem em sistemas de produção animal a partir da utilização do modelo SAFER de forma combinada ao de eficiência de uso de radiação de Montheit (RUE). Além disso, utiliza dados de sensoriamento

proximal para alimentar o modelo SAFER, situação até então não observada na literatura especializada.

A associação do modelo SAFER e do modelo de Monteith permitiu a obtenção de um método rápido, e promissor de estimativa de forragem. A integração de dados climatológicos e de sensoriamento remoto, proposta por estes modelos, mostrou-se eficiente para realização da estimativa de massa de *Urochloa* (syn. *Brachiaria*) *brizantha* cv. Piatã nos sistemas de produção animal silvipastoril e pleno sol, tendo melhor desempenho no sistema silvipastoril.

6. Referências

- Almeida, C.A. de, Coutinho, A.C., Esquerdo, J.C.D.M., Adami, M., Venturieri, A., Diniz, C.G., Dessay, N., Duriex, L., Gomes, A.R., 2016. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. *Acta Amaz.* 46, 291–302. <https://doi.org/http://dx.doi.org/10.1590/1809-4392201505504>
- Andrade, R.G., Teixeira, A.D.C., Leivas, J.F., Nogueira, S.F., Da Silva, G.B.S., Victoria, D.D.C., Facco, A.G., 2015. Estimativa da evapotranspiração e da biomassa de pastagens utilizando o algoritmo SAFER e imagens MODIS. In Embrapa Territorial. Artigo em anais de congresso (ALICE). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. Anais... São José dos Campos: INPE, 2015.
- Andrade, R.G., Teixeira, A.H.D.C., Leivas, J.F., Nogueira, S.F., 2016. Analysis of evapotranspiration and biomass in pastures with degradation indicatives in the Upper Tocantins River Basin, in Brazilian Savanna. *Revista Ceres*, 63(6), 754-760.
- Barnes, P., Wilson, B.R., Reid, N., Bayerlein, L., Koen, T.B., Olupot, G., 2014. Examining the impact of shade on above-ground biomass and normalized difference vegetation index of C3 and C4 grass species in North-Western NSW, Australia. *Grass Forage Sci.*, 70, 324-334.

Bayma-Silva, G., Teixeira, A.H.C., Victoria, D.C., Nogueira, S.F., Leivas, J.F., Coaguila, D.N., Herling, V.R., 2016. Energy balance model applied to pasture experimental areas in São Paulo State, Brazil. In: Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII. International Society for Optics and Photonics, 99981C.

Bispo, P.d.C., Rodríguez-Veiga, P., Zimbres, B., do Couto de Miranda, S., Henrique Giusti Cezare, C.; Fleming, S., Baldacchino, F., Louis, V., Rains, D., Garcia, M., Del Bon Espírito-Santo, F., Roitman, I., Pacheco-Pascagaza, A.M., Gou, Y., Roberts, J., Barrett, K., Ferreira, L.G., Shimbo, J.Z., Alencar, A., Bustamante, M., Woodhouse, I.H., Eyji Sano, E., Ometto, J.P., Tansey, K., Balzter, H., 2020. Woody Aboveground Biomass Mapping of the Brazilian Savanna with a Multi-Sensor and Machine Learning Approach. *Remote Sensing*, 12, 2685, 2-22.

Bosi, C., Sentelhas, P.C., Huth, N.I, Pezzopane, J.R.M, Andreucci, M.P, Santos, P.M., 2020. APSIM-tropical pasture: a model for simulating perennial tropical grass growth and its parameterisation for palisade grass (*Brachiaria brizantha*). *Agricultural Systems*, 184, 1-14.

Calderano Filho, B., Santos, H.D.S., da Fonseca, O.O.M., Primavesi, O., Primavesi, A.C., 1998. Os solos da Fazenda Canchim, Centro de pesquisa de Pecuária do Sudeste, São Carlos, SP: levantamento semidetalhado, propriedade e potenciais. Embrapa - CNPS. Boletim de Pesquisa, 7 e Embrapa - CPPSE. Boletim de Pesquisa, 2.

Carneiro, F.M., Furlani, C.E.A., Zerbato, C., de Menezes, P.C., da Silva Gírio, L.A., Oliveira, M.F., 2019. Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. *Precision Agriculture*, 1-29.

Chen, Y., Guerschman, J., Shendryk, Y., Henry, D., Harrison, M.T., 2021. Estimating Pasture Biomass Using Sentinel-2 Imagery and Machine Learning. *Remote Sensing*, 13, 603, 1-10.

- Dehziari, S.A., Sanaieejad, S.H., 2019. Energy balance quantification using Landsat 8 images and SAFER algorithm in Mashhad, Razavi Khorasan, Iran. *Journal of Applied Remote Sensing*, 13(1), 014528.
- Di Bella, C.M., Paruelo, J.M., Becerra, J.E., Bacour, C., Baret, F., 2004. Effect of senescent leaves on NDVI-based estimates of fAPAR: Experimental and modelling evidences, *International Journal of Remote Sensing*, 25:23, 5415-5427.
- Dufloth, J.H., Back, A.J., Passos, R., 2015. Estimativa da produção de pasto através de dois métodos indiretos: Régua (altura) e Disco Medidor (densidade). *Agropecuária Catarinense*, 28(1), 83-86.
- Jorge, D., Barbosa, C., De Carvalho, L., Affonso, A., Lobo, F., Novo, E., 2017. SNR (signal-to-noise ratio) impact on water constituent retrieval from simulated images of optically complex Amazon lakes. *Remote Sensing*, 9, 644, 1-18.
- Lukina, E.V., Stone, M L., Raun, WR., 1999. Estimating vegetation coverage in wheat using digital images. *Journal of Plant Nutrition*, 22, 341 – 350.
- Monteith, J.L., 1972. Solar radiation and productivity in tropical ecosystems. *Journal of applied ecology*, 9, 747-766.
- Mutanga, O., Skidmore, A.K., 2004. Narrow band vegetation indices overcome the saturation problem in biomass estimation. *International Journal of Remote Sensing*, 25(19), 3999–4014.
- Nesper, M., Büneemann, E.K., Fonte, S. J., Rao, I. M., Velásquez, J. E., Ramirez, B., Hegglin D., Frosard, E., Oberson, A., 2015. Pasture degradation decreases organic P content of tropical soils due to soil structural decline. *Geoderma*, 257–258 (2015), 123-133.
- Paciullo, D.S.C., Gomide, C.A.M., Castro, C.R.T.D., Fernandes, P.B., Müller, M.D., Pires, M.F. Á., Fernandes, E.M., Xavier, D.F., 2011. Características produtivas e nutricionais do pasto em sistema agrossilvipastoril, conforme a distância das árvores. *Pesquisa Agropecuária Brasileira*, 46, 1176-1183.

Pezzopane, J.R.M., Bernardi, A.C.C., Bosi, C., Oliveira, P.P.A., Marconato, M.H., Pedroso, A.F., Esteves, S.N., 2017. Forage productivity and nutritive value during pasture renovation in integrated systems. *Agroforest Syst*, 93, 39–49.

Pezzopane, J.R.M., Bernardi, A.C.C., Bosi, Crippa, P.H., Santos, P.M, Nardachione, E.C., 2019. Assessment of Piatã palisadegrass forage mass in integrated livestock production systems using a proximal canopy reflectance sensor. *European Journal of Agronomy*, 103, 130–139.

Pullanagari, R.R.; Kereszturi, G.; Yule, I.J., 2017. Quantification of dead vegetation fraction in mixed pastures using aisafenix imaging spectroscopy data. *International journal of applied earth observation and geoinformation*, 58, 26–35.

Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., 1973. Monitoring vegetation systems in the great plains with ERTS. In: *EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM*, 3. Washington. Proceedings...Washington: NASA, Goddard Space Flight Center, 1, 309-317.

Sanderson, M.A., Rotz, C.A., Fultz, S.W., Rayburn, E.B., 2001. Estimating forage ass with a commercial capacitance meter, rising plate meter, and pasture ruler. *Agronomy journal*, 93, 1281–1286.

Santos, R. A., Venancio, L. P., Filgueiras, R., & Cunha, F. F., 2020. Remote sensing as a tool to determine biophysical parameters of irrigated seed corn crop. *Semina: Ciências Agrárias*, 41(2), 435-446.

Schaefer M.T., Lamb D.W., 2016. A Combination of Plant NDVI and LiDAR Measurements Improve the Estimation of Pasture Biomass in Tall Fescue (*Festuca arundinacea* var. Fletcher). *Remote Sensing*, 8(2),109.

Schmer, M.R., Mitchell, R.B., Vogel, K.P., Schacht, W.H., Marx, D.B., 2010. Efficient Methods of Estimating Switchgrass Biomass Supplies. *BioEnergy research*, 3, 243–250.

Silva, Y.D.F.D., 2018. Uso do algoritmo SAFER para evapotranspiração real na cultura da soja. Dissertação (Mestrado em Agronomia) – Universidade Estadual Paulista “Júlio de Mesquita Filho”. Jaboticabal, 57 p.

Teixeira, A.D.C., Bastiaanssen, W.G., Moura, M.S.B., Soares, J.M., Ahmad, M.U.D., Bos, M.G., 2008. Energy and water balance measurements for water productivity analysis in irrigated mango trees, Northeast Brazil. *Agricultural and forest meteorology*, 148(10), 1524-1537.

Teixeira, A.H.C., 2012. Modelling Evapotranspiration by Remote Sensing Parameters and Agrometeorological Stations. In. *Remote Sensing and Hydrology*; Neale, C.M.U.; Cosh, M.H., Eds.: IAHS Publ. 352; IAHS, Wallingford, UK, 154-157.

Teixeira, A.H.C.; Scherer-Warren, M.; Hernandez, F.B.T.; Andrade, R.G.; Leivas, J.F., 2013. Large-Scale Water Productivity Assessments with MODIS Images in a Changing Semi-Arid Environment: A Brazilian Case Study. *Remote Sensing*, 5, 5783-5804.

Teixeira, A.H.C., Leivas, J.F., Hernandez, F.B.T., Franco, R.A.M., 2017. Large-scale radiation and energy balances with Landsat 8 images and agrometeorological data in the Brazilian semiarid region. *Journal of Applied Remote Sensing*, 11(1), 016030.

Teixeira, A.H.C., Simão, F.R., Leivas, J.F., Gomide, R.L., Reis, J.B.D.S., Kobayashi, M.K., Oliveira, F.G., 2018. Water Productivity Modeling by Remote Sensing in the Semiarid Region of Minas Gerais State, Brazil. *Arid Environments and Sustainability*, 93.

Teixeira, A., Leivas, J., Struiving, T., Reis, J., Simão, F., 2021a. Energy balance and irrigation performance assessments in lemon orchards by applying the SAFER algorithm to Landsat 8 images. *Agricultural Water Management*, 247, 106725.

Teixeira, A., Pacheco, E., Silva, C., Dompieri, M., Leivas, J., 2021b. SAFER applications for water productivity assessments with aerial camera onboard a remotely piloted aircraft (RPA).

A rainfed corn study in Northeast Brazil. *Remote Sensing Applications: Society and Environment*, 22, 100514.

Torres, F. N., Richter, R., Vohland, M., 2019. A multisensoral approach for high-resolution land cover and pasture degradation mapping in the humid tropics: A case study of the fragmented landscape of Rio de Janeiro. *International Journal of Applied Earth Observation and Geoinformation*, 78, 189-201.

Van Leeuwen, W.J.D., Huete, A.R., 1996. Effects of standing litter on the biophysical interpretation of plant canopies with spectral indices. *Remote sensing of Environment*, 55(2), 123-138.

Venancio, L.P., Mantovani, E.C., Amaral, C.H.D., Neale, C.M.U., Filgueiras, R., Gonçalves, I.Z., Cunha, F.F.D., 2020. Evapotranspiration mapping of commercial corn fields in Brazil using SAFER algorithm. *Scientia Agricola*, 78.

Wilm, H.G., Costello, D.F., Klipple, G. E., 1944. Estimating forage yield by the doublesampling method. *Journal of the American Society of Agronomy*.

CAPÍTULO 3: Desempenho do modelo SAFER na estimativa da maturação do amendoim²

Resumo:

A identificação da maturação das vagens de amendoim (*Arachis hypogaea* L.) é um desafio para a cadeia produtiva, pois trata-se de uma cultura de crescimento indeterminado e com desenvolvimento subterrâneo das vagens. O método mais disseminado para obtenção do *Peanut Maturity Index* (PMI), o Hull-Scrape, é moroso e altamente subjetivo, o que dificulta sua aplicação em larga escala e não representa a variabilidade da área de produção. Buscando estimativas mais acuradas de PMI, essa pesquisa utiliza dados climáticos e espectrais de forma combinada. Com isso, objetivou-se avaliar o desempenho do modelo *Simple Algorithm for Evapotranspiration Retrieving* (SAFER), de cálculo de evapotranspiração, na estimativa de PMI, variável indicadora do momento ideal do arranquio da cultura. O experimento foi implantado em campos comerciais de amendoim no estado da Geórgia, USA, nos anos de 2020 (Campo A) e 2021 (Campos B e C). Vagens foram coletadas em diferentes datas e classificadas de acordo com a maturação pelo método Hull-Scrape. Dados climáticos e imagens PlanetScope foram utilizadas para o cálculo de evapotranspiração atual a partir do modelo SAFER, que foi correlacionada com o PMI coletado *in situ* e utilizada para geração de modelos de regressão linear. Os campos A e B obtiveram modelos mais acurados, o que levou a criação de um modelo composto dos dados dessas áreas, sendo o mais indicado por integrar diferentes condições de campo. O modelo SAFER mostrou-se promissor para a estimativa de PMI, reduzindo a subjetividade do método tradicional, e funcionando como indicador do momento mais adequado para o arranquio do amendoim. Além disso, por não exigir imagens dos dias exatos

² Artigo formatado para submissão na revista Agricultural System.

em que se deseja estimar o PMI, o modelo permite a estimativa mesmo em regiões altamente afetadas pela presença de nuvens e sombras.

Palavras-chave: Sensoriamento remoto, agrometeorologia, dados espectrais, agricultura digital, *Arachis hypogaea* L..

1. Introdução

A cadeia produtiva do amendoim (*Arachis hypogaea* L.) enfrenta desafios diante do hábito indeterminado da cultura e do crescimento das vagens abaixo da superfície do solo. Estes fatores contribuem para a variabilidade e dificuldade de identificar os estágios de maturação das vagens, o que tem impacto direto na definição do momento ideal da colheita. Segundo Santos et al. (2019), o arranquio tardio da cultura do campo, com excesso de vagens maduras, pode prejudicar a produção final devido ao aumento de perdas oriundas da operação. Em contrapartida, para o mercado de sementes, vagens imaturas reduzem a qualidade do lote (Sanders et al., 1982).

O método mais disseminado de identificação do Índice de Maturação do Amendoim (*Peanut Maturity Index*; PMI) é o (Williams and Drexler, 1981). O Hull-Scrape consiste na coleta destrutiva de plantas no campo, remoção do exocarpo das vagens e classificação de acordo com a cor do mesocarpo. Apesar de usado em diversas partes do mundo, esse método é moroso, exige mão de obra qualificada e é altamente subjetivo (Colvin et al., 2014). Além disso, não considera a variabilidade existente em uma mesma área de produção (Santos et al., 2021, Santos et al., 2022).

Métodos alternativos têm sido elaborados para reduzir a subjetividade do método Hull-Scrape, principalmente por meio da análise digital de imagens RGB (Li et al., 2021) e hiperespectrais (Zou et al., 2019; Yu, 2021). Ainda assim, não solucionam as questões

relacionadas à variabilidade do campo e exigência por amostras destrutivas. Nesse contexto, o sensoriamento remoto é uma ferramenta promissora, que permite avaliar a resposta do dossel vegetativo a diferentes comprimentos de onda, e já vem sendo testado com a finalidade de estimar o PMI (Rowland et al., 2008; Santos et al., 2021; Santos et al., 2022). Ainda assim, possuem fatores limitantes, como a disponibilidade de imagens nos momentos desejados, uma vez que sofre interferência da presença de nuvens.

Dados climáticos, como temperatura, são variáveis que possuem relação direta com o desenvolvimento fenológico das plantas (Bell and Wright, 1998). Em relação as vagens de amendoim, à medida que há acúmulo de graus-dias, condição que ocorre com a temperatura base de aproximadamente 13°C, aproximam-se da maturação fisiológica. Com isso, aliar variáveis climáticas e dados espectrais pode permitir a obtenção de métodos mais robustos de estimativa em relação a métodos baseados somente no uso de índices de vegetação (IVs) (Rowland et al., 2006).

O modelo SAFER (*Simple Algorithm for Evapotranspiration Retrieving*) (Teixeira et al., 2008; Teixeira, 2012) une essas variáveis para a obtenção da evapotranspiração real de cultivo, não sendo necessários dados de coeficiente de cultura (K_c). Além de já ter sido aplicado para essa finalidade em culturas frutíferas, vegetação natural, cana-de-açúcar e milho (Teixeira, 2010; Avilez et al., 2020, Venâncio et al., 2021), o SAFER também tem sido utilizado na estimativa de biomassa, conforme realizado por Bayma-Silva et al. (2016) e Andrade et al. (2016) com pastagem.

Em comparação com os modelos que utilizam somente dados espectrais para estimar o PMI, o modelo SAFER não exige a alta frequência de dados espectrais, de modo a contornar a dificuldade de aquisição de imagens em razão de nuvens e sombras sobre a área.

Desta forma, pressupondo que a combinação de dados climáticos e espectrais possa ser utilizada na estimativa da maturação do amendoim e que o modelo SAFER apresenta alto

potencial de aplicação para essa finalidade, objetivou-se avaliar o desempenho do modelo SAFER como método de estimativa do *Peanuty Maturity Index*, variável indicadora do momento ideal do arranquio da cultura.

2. Material e Métodos

2.1. Área experimental

O experimento foi conduzido em três áreas comerciais de amendoim no sul do estado da Geórgia, EUA, sendo duas áreas localizadas no condado de Tift (campos A e C) e uma no condado de Berrien (campo B) (Figura 1). As coordenadas geodésicas são 31.402°N e 83.421°W (campo A), 31.362°N e 83.388°W (campo B) e 31.576°N e 83.614°W (campo C). A região é caracterizada com clima Cfa, subtropical com verão quente e precipitação média anual de 1346 mm (Köppen e Geiger 1928), com solos arenosos, que porporcionam condições favoráveis à produção de amendoim

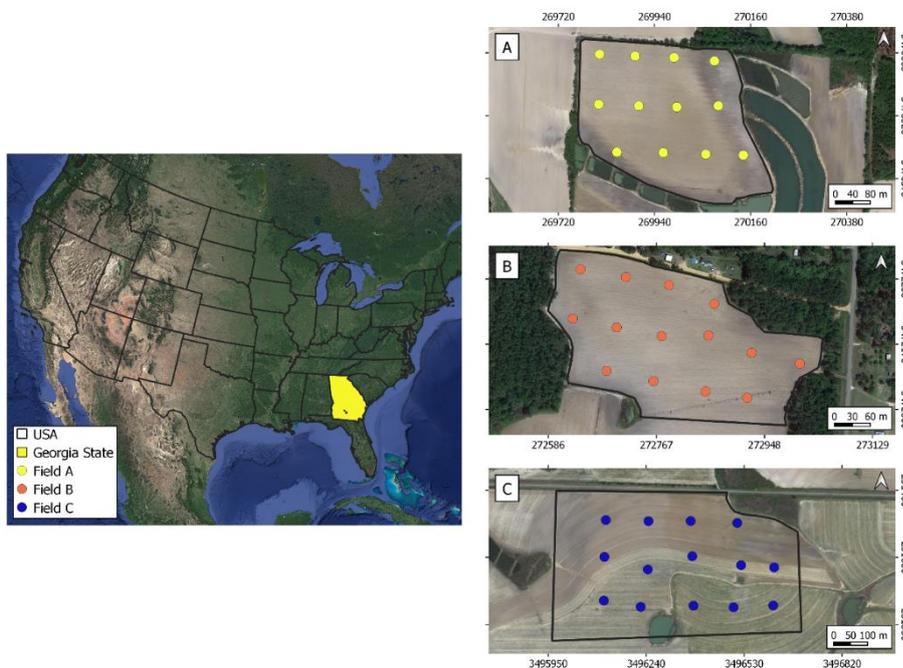


Figura 1. Áreas experimentais em campos comerciais de amendoim nos condados de Tift (Campo A e C) e Berrien (Campo B) no estado da Geórgia – USA.

A semeadura foi realizada, em todos os campos, com a cultivar Geórgia-06G, que possui hábito de crescimento rasteiro e geralmente atinge a maturação cerca de 140 dias após a semeadura (2500 graus-dias) (Branch, 2007). Os campos A e B são pertencentes ao mesmo produtor, o que lhes conferiu manejo similar. Os três campos eram irrigados, entretanto, em decorrência da disposição dos pivôs centrais no campo C, a porção central do campo não recebeu irrigação. As datas de semeadura e arranquio para cada campo encontram-se na Tabela 1.

Tabela 1. Datas de semeadura e arranquio do amendoim nos diferentes campos.

Campo / Operação	Semeadura	Arranquio
Campo A	19/05/2020	127 DAS [†]
Campo B	10/05/2021	156 DAS
Campo C	01/05/2021	147 DAS

[†]DAS – dias após a semeadura.

Para avaliação do PMI, foram definidos grids amostrais compostos de 12 pontos para o campo A (em 2020) e de 14 pontos para os campos B e C (2021) (Figura 1). Os pontos foram distribuídos de modo que conseguissem expressar a variabilidade dos campos (Figura 1) Por terem sido realizadas avaliações temporais, obteve-se número suficiente de dados de PMI , premissa importante para criação de modelos de estimativa.

2.2. Aquisição dos dados – *In situ*

Para avaliação da maturação, foram realizadas coletas semanais nos três campos de, aproximadamente, 8 plantas distribuídas em um raio de 5 metros a partir do centro de cada ponto amostral. O intuito em não concentrar a coleta das 8 plantas num único ponto era reduzir a quantidade de solo exposto, fator que pode impactar na reflectância do pixel. Para o campo A, as coletas iniciaram-se aos 105 DAS, com um total de 4 amostragens. Já nos campos B e C,

as coletas *in situ* foram realizadas a partir de 122 DAS no campo B, e 129 DAS no campo C, totalizando 4 e 6 amostragens, respectivamente. Por se tratar de experimento realizado em campos comerciais, o momento do arranquio foi definido pelo produtor, tendo impacto direto sobre a número de avaliações.

Em cada ponto amostral, cerca de 200 vagens foram separadas das plantas. Para evitar seleção tendenciosa das vagens, cada planta teve todas as vagens retiradas, e ao atingir o valor estipulado, era necessário concluir a retirada das vagens da planta em questão. Com isso, os pontos amostrais possuíam números distintos de vagens destinadas à avaliação no quadro de maturação.

Por ser necessária a exposição do mesocarpo da vagem para a identificação do nível de maturação, as vagens passaram pelo processo de remoção do exocarpo com a utilização de uma lavadora de alta pressão. Ainda úmidas, as vagens foram dispostas sobre o Quadro de Maturação e classificadas de acordo com a coloração do mesocarpo em branco, amarelo 1, amarelo 2, laranja, marrom e preto (Williams e Drexler, 1981). A quantidade de vagens em cada uma das classes foi contabilizada para obtenção do PMI de cada ponto amostral (Equação 1).

Em laboratório, a análise da maturação foi realizada conforme o método *Peanut Maturity Index* (PMI), em que o ponto ideal para o arranquio é atingido com PMI de 0.7 (Rowland et al., 2006).

$$PMI (\%) = \frac{(B+BL)}{(W+Y1+Y2+O+B+BL)} \quad (1)$$

Em que: W – branco; Y1 – amarelo 1; Y2 – amarelo 2; O – laranja; B – marrom; e BL – preto.

2.3. Aquisição dos dados – Meteorológicos e Espectrais

As variáveis meteorológicas necessárias para a implementação do SAFER, temperatura média, evapotranspiração de referência e radiação global, foram obtidas a partir de duas estações meteorológicas da Universidade da Geórgia. Para os campos A e B, a estação utilizada está localizada nas coordenadas 31.481° N, 83.439° W. Já para o campo B, a estação usada encontra-se nas coordenadas 31.509° N, 83.648° W.

Para aquisição dos dados espectrais, foram utilizadas imagens do sensor da plataforma PlanetScope CubeSat. O sensor gera imagens da reflectância da superfície com resolução espacial de 3 metros, composta de 4 bandas espectrais, sendo elas nas faixas de comprimento de onda do azul (455-515 nm), verde (500-590 nm), vermelho (590-670 nm) e infravermelho próximo (NIR - 780-860) (Planet Team, 2019). Para ajustar o modelo às condições reais da cultura, é interessante inserir no SAFER dados espectrais de diferentes momentos do desenvolvimento da cultura, englobando do início ao fim do ciclo. Apesar de ser uma plataforma composta de 148 satélites em órbita com imageamento diário, a constante presença de nuvens no período do experimento dificultou o processo de aquisição das imagens. Com base nisso, optou-se por utilizar uma imagem por mês para cada uma das áreas (quatro imagens) e, quando possível, uma imagem antecedente a etapa de arranquio.

Após a aquisição das imagens, utilizando o Qgis 3.8 (QGIS Development Team, Open Source Geospatial Foundation, Chicago, IL, EUA), foi possível identificar os pontos coletados em campo previamente georreferenciados com GPS geodésico. Um buffer de 5 metros de raio foi criado para cada ponto e, a partir dele, foi retirado o valor médio de reflectância. Vale ressaltar que as imagens PlanetScope são disponibilizadas em GeoTIFF de 16 bits com valores de reflectância dimensionados em 10.000, sendo necessário transformá-los para escala de 0 a 1. Após a extração dos valores no QGis, a transformação foi realizada no Python.

Para a obtenção de estimativas de evapotranspiração atual diária, foram considerados os dados meteorológicos dos dias exatos. Já os espectrais de cada imagem foram atribuídos para os dias que antecediam a sua data de aquisição.

2.4. Modelo SAFER

O modelo SAFER foi aplicado com intuito de estimar a evapotranspiração ao longo do ciclo de desenvolvimento do amendoim, posteriormente correlacionada com o índice de maturação da cultura.

Os dados espectrais, obtidos a partir de imagens PlanetScope, foram utilizados para o cálculo do albedo da superfície (α_0) e NDVI (Rouse et al., 1973), conforme as Equações 2 e 3, respectivamente.

$$\alpha_0 = b\alpha_1 + c\alpha_2 + d\alpha_3 + e\alpha_4 \quad (2)$$

Em que: $\alpha_1, \alpha_2, \alpha_3, \alpha_4$ são as refletâncias nos comprimentos de onda do azul, verde, vermelho e infravermelho próximo, respectivamente. b, c, d e e são os coeficientes de regressão calculados a partir da lei de Planck (Teixeira et al. 2017).

$$NDVI = \frac{(\alpha_4 - \alpha_3)}{(\alpha_4 + \alpha_3)} \quad (3)$$

Em seguida, com base na lei de Stefan-Boltzman, foi calculada a radiação da atmosfera (R_a) (Equação 4).

$$R_a = \sigma \varepsilon_A T_a^4 \quad (4)$$

Em que: σ é a constante de Stefan-Boltzmann ($5.67 \times 10^{-8} \text{ W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$), T_a é a temperatura média, e ε_A é a emissividade atmosférica (Equação 5).

$$\varepsilon_A = \alpha_A (\ln \tau_{sw})^{b_A} \quad (5)$$

Em que: α_A e b_A são os coeficientes de regressão (Teixeira et al., 2008) e τ_{sw} é a transmissividade atmosférica.

A etapa seguinte consistiu no cálculo da radiação líquida (R_n) por meio da equação de Slob (Equação 6).

$$R_n = (1 - \alpha_0)R_G - (a_L \tau) \quad (6)$$

Em que: a_L é o coeficiente de regressão, correlacionado com T_a (Teixeira et al., 2008).

A radiação refletida (R_R) foi calculada a partir da radiação global (R_G) e do albedo de superfície (α_0) (Equação 7).

$$R_R = \alpha_0 R_G \quad (7)$$

A partir dos dados de R_G , R_R , R_a e R_n , a radiação de onda longa emitida pela superfície cultivada (R_S) foi calculada, utilizando a equação de balanço de radiação (Equação 8).

$$R_S = R_G - R_R + R_a - R_n \quad (8)$$

A variável temperatura da superfície (T_0) foi então estimada por meio da equação 9.

$$T_0 = \sqrt[4]{\frac{R_S}{\sigma \varepsilon_S}} \quad (9)$$

Em que: ε_S é a emissividade da superfície e a_S e b_S são os coeficientes de regressão (Teixeira et al., 2008) (Equação 10).

$$\varepsilon_s = a_s \ln NDVI + b_s \quad (10)$$

A relação de evapotranspiração, da qual é possível obter a evapotranspiração real, foi calculada conforme demonstrada na Equação 11.

$$\frac{ET}{ET_0} = \exp[a_{sf} + b_{sf}(\frac{T_0}{\alpha_0 NDVI})] \quad (11)$$

Em que: a_{sf} e b_{sf} são coeficientes de regressão.

O modelo em questão resultou na obtenção da evapotranspiração diária. Para correlacionar com os dados de maturação, a evapotranspiração real diária foi somada, de modo a obter a evapotranspiração para cada um dos dias de coleta *in situ*.

2.5. Análise estatística

Com base nas avaliações *in situ*, ao final, o campo A totalizou 48 amostragens, enquanto que os campos B e C totalizaram 84 e 56 amostragens de PMI, respectivamente. Para eliminar outliers do conjunto de dados, utilizou-se o método de resíduos padronizados, no qual eliminam-se os pontos com valores menores que -1.5 e maiores que +1.5. O número de outliers nos campos A, B e C foram 5, 10, e 9, respectivamente. A verificação da normalidade dos dados foi realizada por meio do teste de Shapiro Wilk com intervalo de confiança de 0.05. Diante de dados normais no Campo A, aplicou-se a correlação de Pearson ($p < 0.05$). Nos demais campos, observaram-se dados não normais, portanto a correlação de Spearman ($p < 0.05$) foi aplicada. As análises foram feitas utilizando linguagem computacional Python.

Em uma análise preliminar, os campos A e B apresentaram alta correlação entre os dados de maturação e a evapotranspiração estimada pelo SAFER. Assim, realizou-se a junção dos conjuntos de dados, de modo que um quarto cenário contendo todas as informações de maturação e evapotranspiração desses dois campos fosse gerado. Isso foi realizado com o

intuito de criar um modelo robusto capaz de assimilar diferentes condições de cultivo. Nesse conjunto de dados, foram retirados os outliers e aplicou-se a correlação de Spearman ($p < 0.05$).

Para os quatro cenários (campo A, campo B, campo C e campo A+B), modelos de regressão linear entre os dados de evapotranspiração real estimada pelo SAFER e o PMI foram gerados. O treinamento dos modelos consistiu na utilização de 80% dos dados, enquanto que na etapa de validação, 20% dos dados foram usados. O desempenho dos modelos foi avaliado por meio de gráfico de performance, R^2 , erro médio absoluto (MAE) e erro relativo (ER) (Equações 12 a 14).

$$R^2 = \frac{SQR}{SQT} \quad (12)$$

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |O_i - E_i| \quad (13)$$

$$ER (\%) = \frac{100}{n} \sum_{i=1}^n \left| \frac{O_i - E_i}{O_i} \right| \quad (14)$$

Em que: SQR é a soma dos quadrados da regressão, SQT é a soma dos quadrados totais, O_i é o valor observado, E_i é o valor estimado, n é a quantidade de pontos.

3. Resultados

3.1 Parâmetros climatológicos e espectrais

Um dos principais processos que afetam o desenvolvimento das plantas é a evapotranspiração (transpiração da planta + evaporação de água do solo), que é fortemente influenciada pelas condições climáticas. Além disso, variáveis como temperatura média do ar, radiação global, evapotranspiração de referência e precipitação (Figura 2) também impactam diretamente no crescimento e desenvolvimento da cultura do amendoim e promovem alterações nos valores de índices de vegetação, como o NDVI (Figura 3).

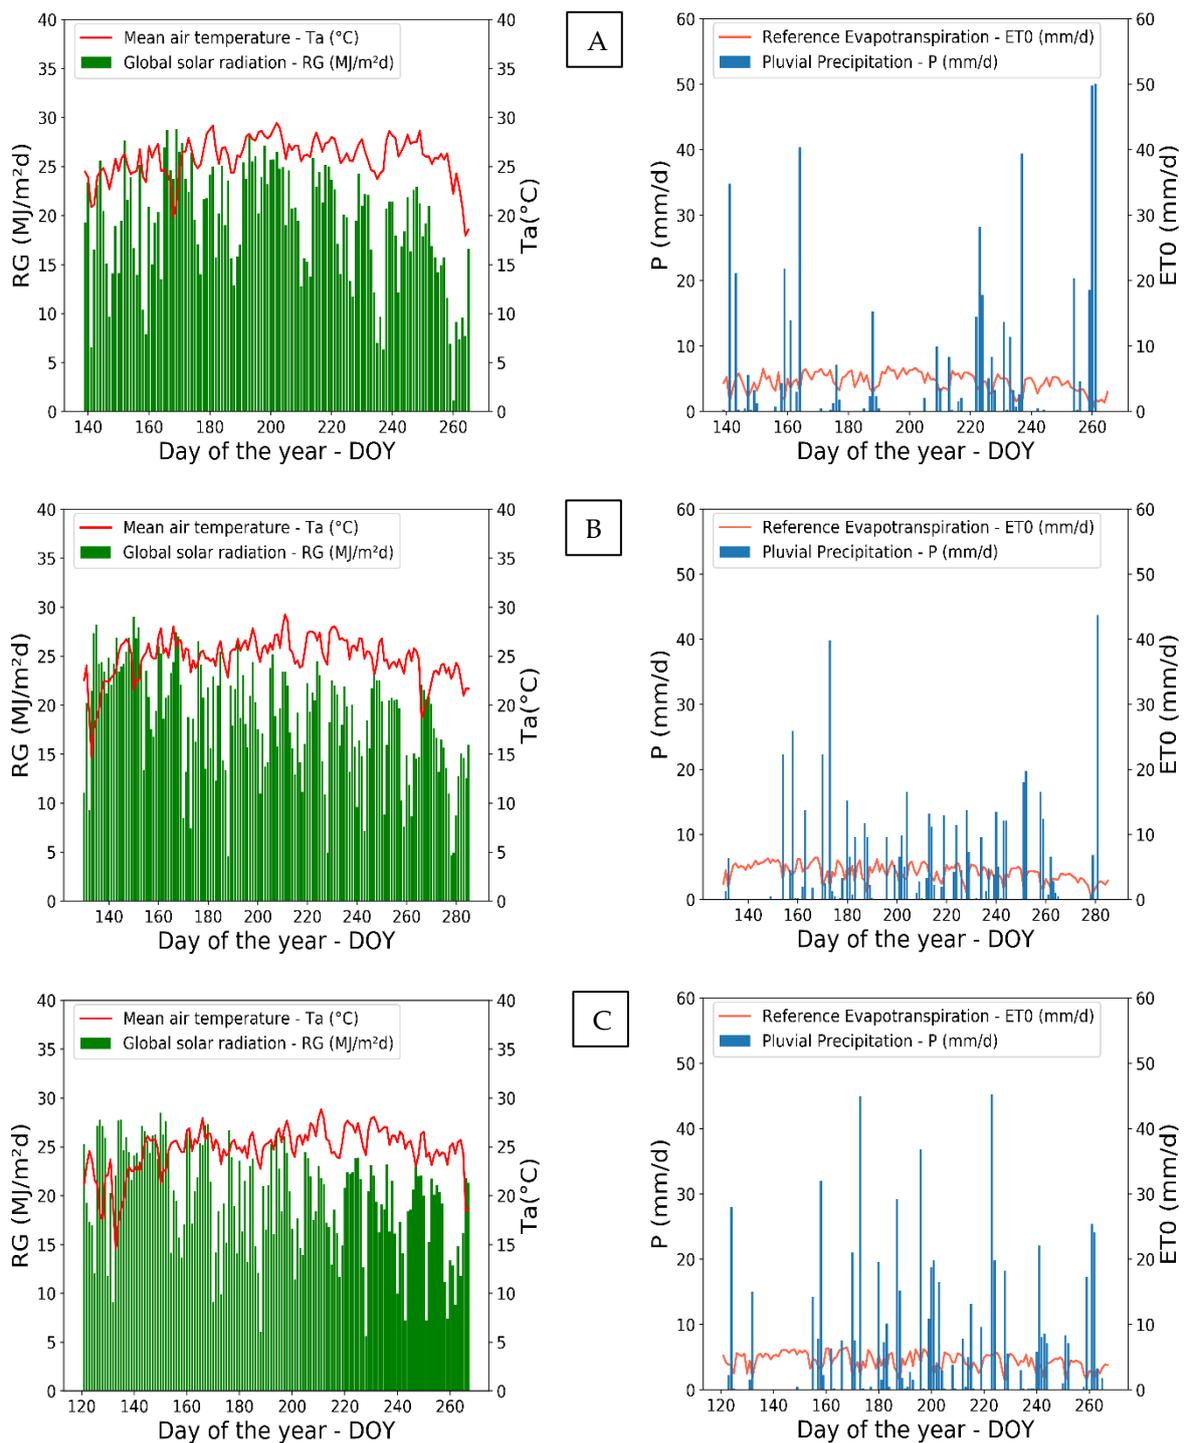


Figura 2. Parâmetros climatológicos para os períodos que compreendem o desenvolvimento do amendoim em cada área. A – Campo A (ano de 2020); B – Campo B (ano de 2021); e C – Campo C (ano de 2021).

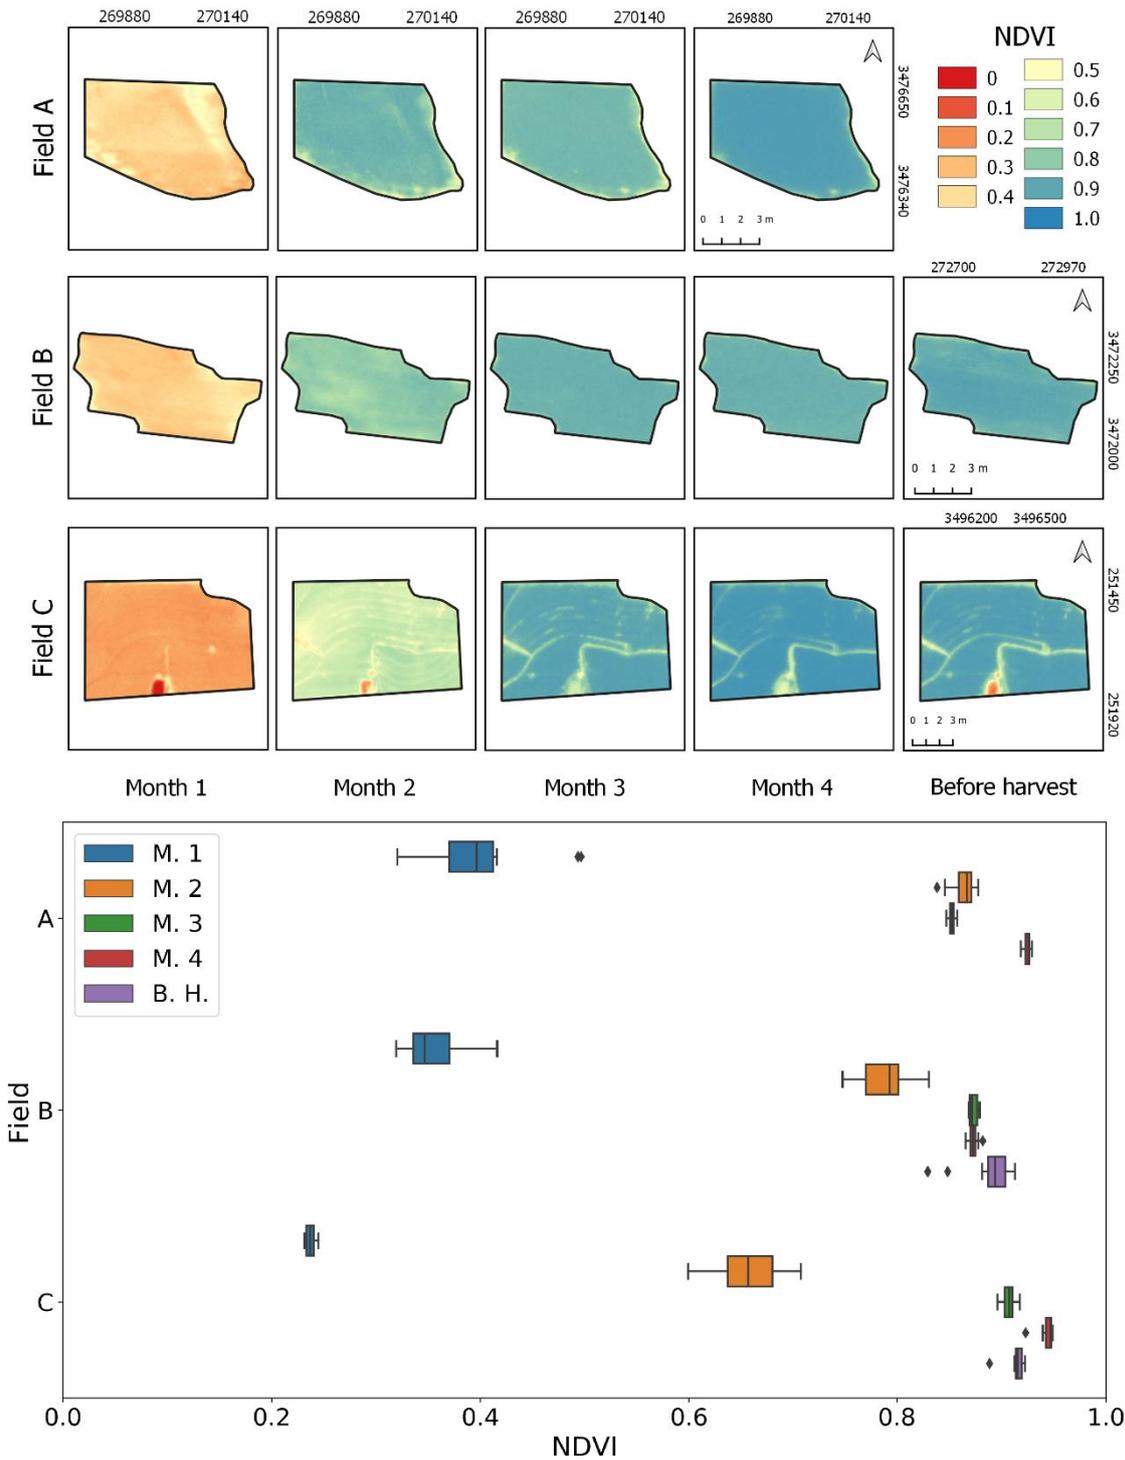


Figura 3. Avaliação temporal do NDVI em diferentes períodos de desenvolvimento do amendoim. A – Campo A; B – campo B; e C – Campo C. (M – mês; B.H – antes da colheita).

Tratando-se de radiação global e temperatura média do ar, os campos B e C apresentaram comportamento muito semelhante, com temperaturas médias mantendo-se, em

boa parte do ciclo, dentro da faixa ideal (25 e 30 °C) para crescimento e desenvolvimento vegetativo e reprodutivo do amendoim (Williams e Boote, 1995 apud Prasad et al., 2000). A menor temperatura média observada para esses campos foi de aproximadamente 15° C aos 3 DAS e 12 DAS nos campos B e C, respectivamente. No campo A, a temperatura manteve-se entre 20 e 30 °C na maior parte do tempo, com queda de aproximadamente 2° C nos 2 dias que antecederam o arranquio. Para a radiação global, o valor médio diário ao longo do ciclo nas três áreas foi de aproximadamente 19 MJ.m².

Em relação à precipitação, observa-se maior chuva acumulada no Campo C (Figura 2C), sendo inclusive superior ao acúmulo de evapotranspiração de referência, em aproximadamente 30 mm. Nas demais áreas, a chuva acumulada não supriu a evapotranspiração de referência, acarretando em déficit hídrico. Além disso, em todas as áreas verificou-se períodos sem chuva, sendo necessária a irrigação.

Com exceção da precipitação, os parâmetros climáticos aqui apresentados mantiveram-se semelhantes nas três áreas. A irrigação ameniza a possível variabilidade entre campos decorrente das diferenças de precipitação. Entretanto, no Campo C, a disposição dos pivôs centrais fez com que parte da área central do grid amostral não fosse irrigada, o que proporcionou desuniformidade no desenvolvimento das plantas.

O índice de vegetação da diferença normalizada (NDVI) é um dos parâmetros de entrada no modelo SAFER, e além de auxiliar na identificação de variabilidade entre campos, possibilita a identificação de variabilidade espacial em cada um deles (Figura 3). Uma vez que as imagens foram adquiridas em distintos momentos, a utilização dos meses de obtenção: mês 1 (31 DAS), mês 2 (55 – 63 DAS), mês 3 (91 – 101 DAS), mês 4 (109 – 126 DAS) foram adotadas para apresentação dos resultados. A última imagem utilizada no campo A foi obtida aos 109 DAS, em razão da cobertura de nuvens sobre a área nos demais dias do ciclo. Para os

campos B e C, estas imagens foram adquiridas aos 126 e 121 DAS, respectivamente, e ainda foram obtidas imagens antes da colheita aos 155 e 146 DAS, respectivamente.

Ao analisar de maneira geral, observa-se que, após o primeiro mês da semeadura, o NDVI encontra-se abaixo de 0.4 em decorrência da maior proporção de solo na cena Planet Scope. Isso ocorreu devido as plantas ainda estarem no período vegetativo, com pouca biomassa. Com o desenvolvimento da cultura, a proporção de solo nos pixels das imagens foi reduzida, uma vez que o amendoim é uma cultura rasteira com muitas ramificações e tende a ocupar o espaço das entrelinhas. Este comportamento gerou incremento nos valores de NDVI, condição observada em todas as áreas, o que é demonstrado por meio do azul mais intenso nos mapas (Figura 3).

Com o processo de senescência do amendoim, é comum que haja redução da biomassa das plantas e, conseqüentemente, do NDVI (Rutkoski et al., 2016; Morlin Carneiro et al., 2020), conforme foi observado no campo C na imagem anterior ao arranquio. Esse cenário dificulta a criação de modelos globais de estimativa de maturação somente com índices de vegetação, já que o PMI tende a aumentar e o NDVI pode aumentar, diminuir ou se manter constante ao final do ciclo (Santos et al., 2021).

Ainda no campo C, é perceptível a presença de falhas, o que não ocorre nos demais campos que, dentre vários fatores, podem ser decorrentes de uma semeadura inadequada, pois, além das falhas observadas em campo, em alguns pontos da lavoura, foi identificada alta população de plantas. Os altos valores de NDVI que tendem à saturação, principalmente no mês do arranquio, podem ser atribuídos a esse fator. Essa condição prejudica as estimativas de maturação, uma vez que a variabilidade encontrada em campo não é acompanhada pelas variações de NDVI.

3.2 Evapotranspiração real estimada

Por se tratar de três campos distintos, a evapotranspiração atual foi calculada separadamente e correlacionada com seus respectivos índices de maturação (PMI) (Tabela 2). A evapotranspiração estimada a partir do modelo SAFER apresentou correlação moderada a alta em três dos quatro cenários propostos. Nos campos A e B, as correlações foram de 0.757 e 0.796, respectivamente. No campo C, a correlação não foi significativa. Com base nisso, e buscando um modelo capaz de englobar diferentes áreas, o quarto cenário foi proposto de maneira a unir os dados dos campos A e B, tendo este apresentado correlação de 0.665.

Tabela 2. Correlação entre evapotranspiração e PMI.

Correlation ET/PMI	Field A – PMI	Field B - PMI	Field C - PMI	Fields A and B – PMI
Field A - ET	0.757*			
Field B - ET		0.796*		
Field C - ET			0.370	
Fields A and B - ET				0.665*

* - correlação significativa a 5% de probabilidade.

Quanto aos valores estimados pelo SAFER (Figura 4 – eixo X), estes são inferiores ao que de fato seria a evapotranspiração acumulada ao final do ciclo do amendoim, sendo inferior inclusive à evapotranspiração de referência (Figura 2). Em nenhum dos campos, a evapotranspiração atual acumulada ultrapassou 260 mm, mas ainda assim, essa variável conseguiu expressar com êxito o comportamento do PMI nos campos A e B e no modelo gerado a partir destes dois campos (Figura 4). Os baixos valores de ET estimados pelo SAFER podem ser atribuídos ao fato de o SAFER ter sido desenvolvido para condições que não condizem com a desse trabalho (cultura e clima). Com base nisso, a calibração do modelo contribuiria para estimativas de ET mais precisas. Ainda assim, como o intuito com este trabalho é a estimativa da maturação, a correlação encontrada entre as variáveis analisadas é capaz de gerar modelos com potencial para estimar a maturação das vagens de amendoim.

Dentre os campos, o que apresentou regressão linear com maior R^2 foi o Campo A com 0.570, seguido do campo B com 0.497. O modelo composto dos dados dos campos A e B apresentou R^2 de 0.415. A junção destes dois campos não prejudicou a precisão do modelo de regressão linear, de modo a demonstrar que os fatores temporal e regional foram amenizados pela utilização de dados climáticos e pelo manejo similar. Já o campo C, de manejo distinto, foi o que apresentou um modelo menos preciso, com R^2 de apenas 0.081.

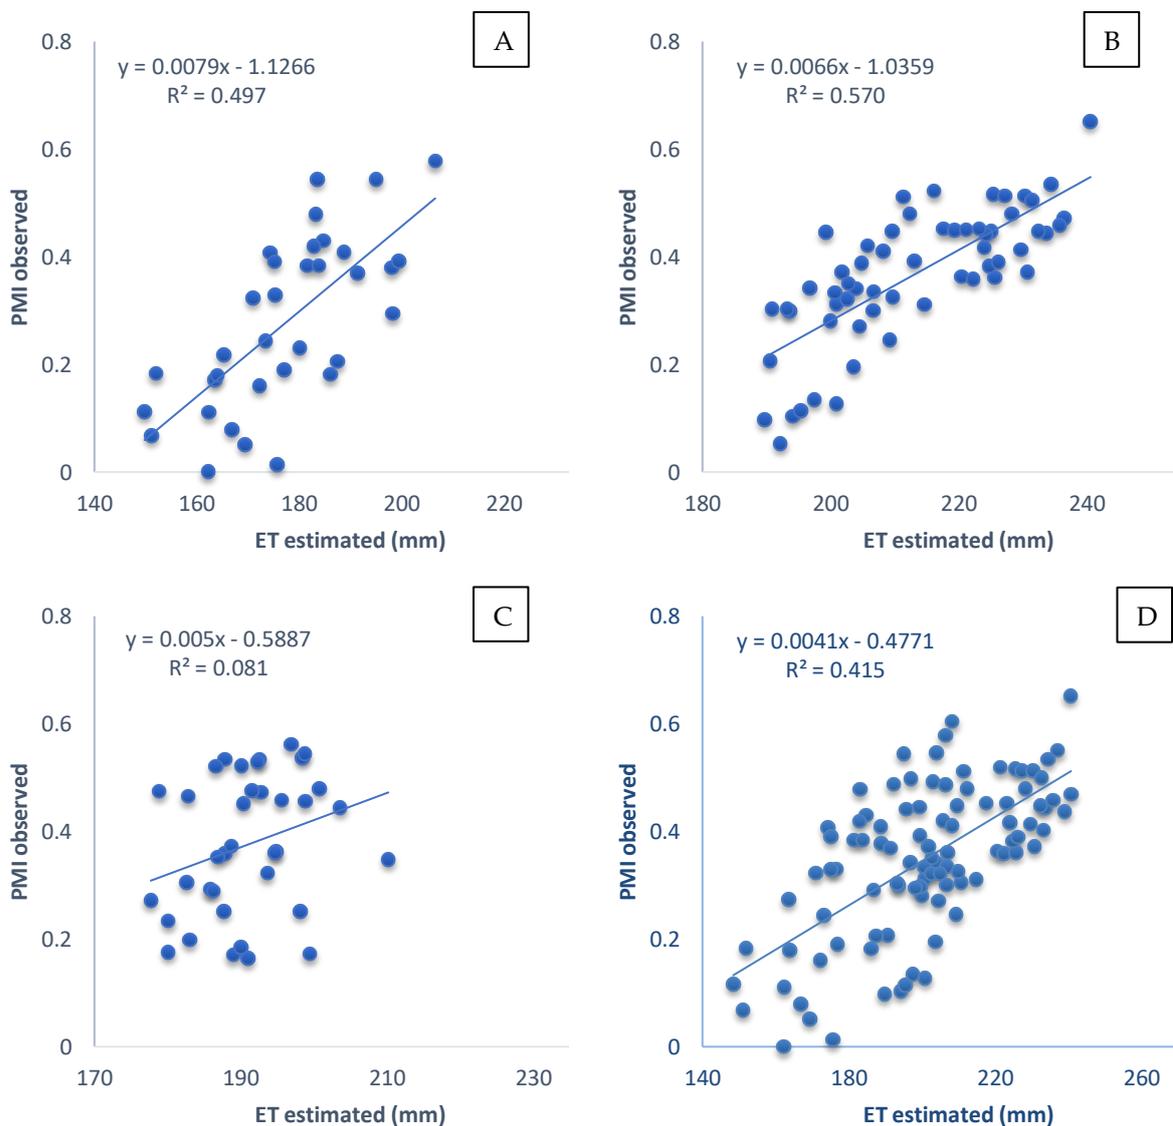
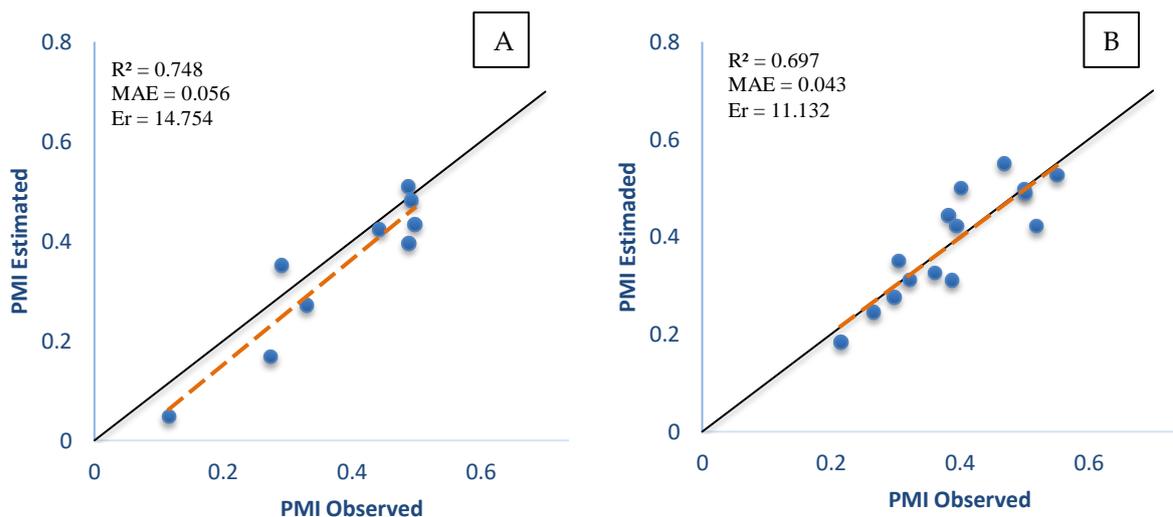


Figura 4. Regressão linear entre Evapotranspiração estimada (ET) pelo modelo SAFER e o PMI. A – Campo A; B – Campo B; C – Campo C; D – Campos A e B.

3.3 Avaliação dos modelos de regressão linear

A estimativa do PMI utilizando o modelo SAFER apresentou resultados satisfatórios para todos os campos avaliados, exceto o campo C (Figura 5). O melhor desempenho foi observado para o Campo B, em que a reta ajustada sobrepôs a linha 1:1. Além disso, o modelo em questão obteve maior acurácia que os demais, com erro relativo de 11.132% (Figura 5B). Por outro lado, a maior precisão foi verificada no Campo A, com R^2 de 0.748. Em contra partida, o modelo gerado a partir dos campos A e B obteve erro relativo de 13.164%. Esses resultados indicam que esse modelo é o mais indicado para estimar o PMI, uma vez que possui relativamente alta acurácia e precisão, e ter sido obtido a partir de dados coletados em duas áreas, o que traz mais robustez nas estimativas.



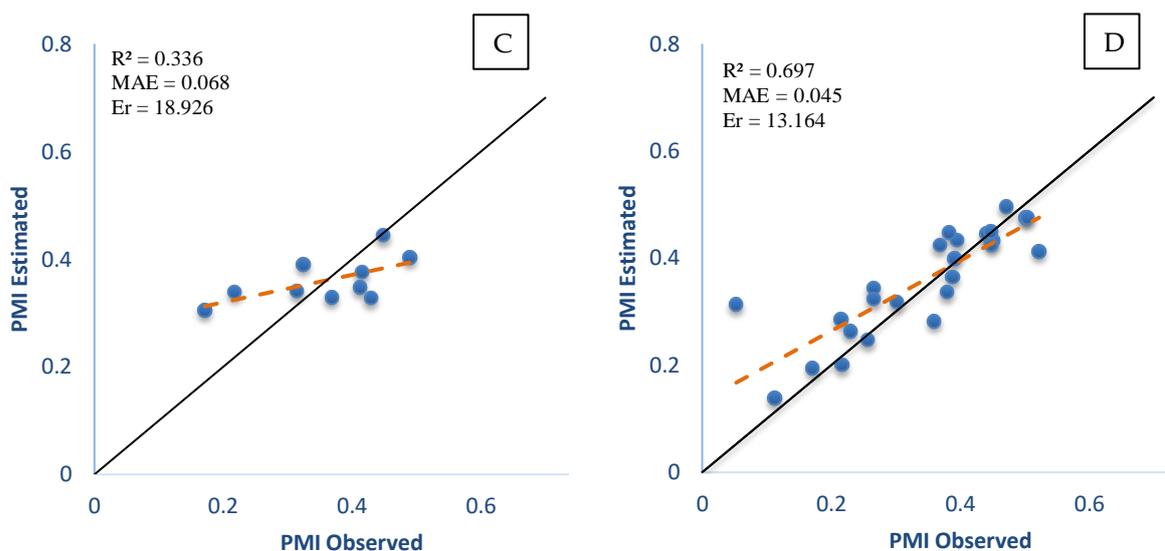


Figura 5. Relação entre o PMI observado e estimado. A – Campo A; B – Campo B; C – Campo C; D – Campos A e B.

4. Discussão

A busca por meios de estimar o PMI baseia-se na dificuldade e imprecisão no método atual de obtenção desta variável, o Hull Scrape. O método que consiste na coleta de plantas *in situ*, retirada das vagens, remoção do exocarpo e identificação das cores do mesocarpo da vagem é subjetivo (Rowland et al. 2006; Colvin et al. 2013; Santos et al., 2021) e interfere no momento ideal para o arranquio da cultura do campo.

Apesar de já existirem propostas alternativas capazes de identificar a coloração das vagens com sensores hiperespectrais (Zou et al., 2019; Yu et al., 2021), o método continua sendo moroso, destrutivo, e exige um grande número de plantas para considerar a variabilidade do PMI da lavoura. Com isso, o ideal é a elaboração de um método que considere a alta variabilidade decorrente do crescimento indeterminado do amendoim (Sanders et al., 1980).

Diversos são os fatores que afetam o desenvolvimento das culturas. Tratando-se da cultura do amendoim, variáveis climáticas, como temperatura, possuem relação direta com o processo de maturação (Bell & Wright, 1998; Awal et al., 2003; Rowland et al., 2006). Diante

disso, agregar estas variáveis a dados espectrais, capazes de considerar a variabilidade dos campos, pode ser uma forma promissora de gerar modelos de estimativa.

O modelo SAFER utilizado nesse trabalho tem como intuito a estimativa da evapotranspiração atual. Por possuir como input diversos fatores atrelados à maturação das vagens de amendoim, foi aplicado com esta finalidade. Apesar de não ter permitido uma estimativa de evapotranspiração atual condizente com a realidade, os resultados apresentaram alta correlação com o PMI em dois dos três campos avaliados (A e B), mostrando-se uma ferramenta promissora.

Os baixos valores de evapotranspiração atual obtidos podem ser atribuídos à necessidade de calibração do modelo SAFER para as condições do meio analisado e a cultura do amendoim. O SAFER foi originalmente desenvolvido e validado com culturas frutíferas no semiárido brasileiro. Com isso, a equação de relação entre evapotranspiração atual e de referência, que compõe o SAFER, teve seus coeficientes calibrados de acordo com a cultura e as condições climáticas dessa região (Teixeira, 2012). Venâncio et al. (2021) confirmaram isso, ao obterem estimativas mais consistentes de evapotranspiração do milho no semiárido da Bahia, após a calibração do modelo SAFER. Essa etapa de calibração não foi realizada neste trabalho, uma vez que o objetivo é utilizar o comportamento da variável na estimativa do PMI, e não atingir valores reais de evapotranspiração.

Ao analisar as correlações entre ET estimada e PMI nos quatro cenários propostos, observa-se que o campo C foi o único em que a correlação não foi significativa. Pode-se atribuir isso a vários fatores que causam a heterogeneidade da lavoura, como relevo, irrigação, número de plantas. Ademais, o campo em questão era composto de pontos que recebiam e outros que não recebiam irrigação (material complementar).

Quanto ao número de plantas, o campo C apresentou alta variabilidade, podendo esta ser atribuída a problemas com a semeadura. De acordo com Kurachi et al., 1989 e Coelho, 1996,

espaçamentos de 0.5 a 1.5 vezes o espaçamento médio esperado ($E_e = 0,05$ m) são considerados aceitáveis. Valores acima de 1.5 vezes o E_e indicam espaçamentos falhos (claramente indicado no campo C na Figura 3), e abaixo de 0.5 múltiplos do E_e , ou seja, com população de plantas maior do que o recomendado. Além de contribuir com a desuniformidade, a alta intensidade de plantas em alguns pontos da lavoura, aliada à volumosa biomassa do amendoim, pode promover a saturação do NDVI (Chen et al., 2019; Carneiro et al., 2019). Essa situação é verificada no boxplot da Figura 3, em que o NDVI do campo C, do terceiro mês em diante, é maior do que nos demais campos. Apesar de o modelo SAFER considerar também outras variáveis, a saturação do NDVI pode ter dificultado a identificação da variabilidade de PMI existente na área. 10 - m

Nos demais campos, A e B, observou-se maior uniformidade da lavoura, irrigação e relevo, e também maior correlação entre PMI e ET. Esses resultados indicam que estimativas de PMI baseadas na evapotranspiração possuem maior potencial em lavouras mais homogêneas.

Diante de um comportamento diretamente proporcional entre as variáveis ET e PMI, optou-se pela utilização de regressão linear. O campo B destacou-se pelo melhor desempenho entre os modelos, além de maior acurácia e precisão. A segunda maior acurácia observada foi para o modelo composto dos Campos A e B, com MAE de 0.045. A utilização dos dados de duas áreas de forma combinada permite chegar a um modelo mais robusto de estimativa de PMI e com possibilidade de aplicação em diferentes campos de amendoim.

Diversas são as vantagens do modelo SAFER em relação a modelos de estimativa de parâmetros biofísicos encontrados na literatura, fundamentados no uso exclusivo de índices de vegetação. A aplicação de dados climáticos faz com que o modelo tenha maior capacidade adaptativa a diferentes regiões. Outra grande vantagem frente aos IVs está relacionada ao comportamento crescente do PMI ao longo do ciclo e, de forma contrária, à tendência a diminuir

dos índices de vegetação com a senescência da cultura (Rutkoski et al., 2016; Santos et al., 2021). Essa condição pode ser verificada no campo C, o que não foi observado nos demais campos. Com isso, a criação de um modelo capaz de englobar a possibilidade do IV de aumentar, diminuir ou estabilizar torna-se mais complexo. No SAFER, como há um somatório da evapotranspiração diária, as variáveis sempre apresentarão um comportamento de crescimento diretamente proporcional ao PMI.

Além disso, a pequena variabilidade dos IVs facilita a obtenção de equívocos na estimativa, já que qualquer mínima alteração na resposta espectral da planta, por fatores inerentes ao PMI, como por exemplo resquícios de defensivos, afetaria muito a estimativa dessa variável. Resultados obtidos por Santos et al. (2021) confirmam isso, em que a alta variabilidade nos níveis de maturação encontrados foram condizentes a uma variação de apenas 0.05 no índice de vegetação SAVI (índice de vegetação ajustado ao solo). Ao basear-se na evapotranspiração, a amplitude é maior, tendo variado aproximadamente 100 mm no cenário composto dos Campos A e B.

Para geração de modelos com IVs, as imagens necessitam ser do dia da coleta do PMI *in situ*, ou datas próximas, o que é mais um limitante tratando-se de uma plataforma orbital, altamente afetada pela presença de nuvens e sombras (Zhu & Helmer, 2018). Em alguns casos, essa alta cobertura de nuvens impede completamente a análise da lavoura no final do ciclo, momento em que a identificação do PMI é mais importante. No campo A, por exemplo, a última imagem do ciclo da cultura disponível foi de 109 DAS, com isso, a partir dessa data, não seria mais possível estimar o PMI. Com o modelo aqui proposto, são utilizados dados diários de estação meteorológica e dados mensais espectrais, o que aumenta o intervalo de aquisição de imagens e permite que situações como a do campo A sejam contornadas.

Dito isso, o SAFER mostrou-se uma ferramenta com potencial para solucionar um importante gargalo da cultura do amendoim, a identificação do PMI, funcionando como indicador do momento ideal do arranquio da cultura.

5. Conclusão

Esse estudo propôs utilizar o modelo SAFER para a estimativa do Peanut Maturity Index, visando prever o momento mais adequado para o arranquio da cultura. A ferramenta, que integra dados meteorológicos e espectrais, mostrou-se promissora na geração de um modelo robusto de estimativa de PMI, capaz inclusive de considerar as condições locais, possibilitando sua aplicação em diferentes regiões. Além de ter apresentado boa acurácia, o modelo pode solucionar um importante gargalo quando o assunto é a utilização de imagens orbitais, a dificuldade de aquisição em regiões e períodos de alta cobertura de nuvens. O modelo SAFER se adequa a essa situação porque não exige imagens dos dias exatos em que se deseja estimar o PMI, aumentando o intervalo de aquisição de imagens e permitindo que situações adversas possam ser contornadas. A acurácia do modelo gerado a partir dos campos A e B, com erro relativo de 13.164%, capacita-o para reduzir a subjetividade e morosidade do método tradicional de estimativa da maturação do amendoim.

6. Referências

Andrade, R.G., Teixeira, A.H.C., Leivas, J.F., Nogueira, S.F. 2016. Analysis of evapotranspiration and biomass in pastures with degradation indicatives in the Upper Tocantins River Basin, in Brazilian Savanna. *Revista Ceres*, 63(6), 754-760.

Awal, M.A., Ikeda, T., Itoh, R. 2003. The effect of soil temperature on source-sink economy in peanut (*Arachis hypogaea*). *Environmental and Experimental Botany*, 50, 41–50. [https://doi.org/10.1016/S0098-8472\(02\)00111-9](https://doi.org/10.1016/S0098-8472(02)00111-9).

- Avilez, A.M.A., Hernandez, F.B.T., Galvão, Í.M., Castro Teixeira, A.H. 2020. Determinação dos coeficientes de cultivo e a evapotranspiração real da cana-de-açúcar com o uso do modelo SAFER. *Agrometeoros*, 28. <http://dx.doi.org/10.31062/agrom.v28.e026831>.
- Bayma-Silva, G., Teixeira, A.H.C., Victoria, D.C., Nogueira, S.F., Leivas, J.F., Coaguila, D.N., Herling, V.R. 2016. Energy balance model applied to pasture experimental areas in São Paulo State, Brazil. In: *Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII*. International Society for Optics and Photonics, 99981C.
- Bell, M.J., Wright, G.C. 1998. Groundnut growth and development in contrasting environments 2. Heat unit accumulation and photo-thermal effects on harvest index. *Expl. Agric.* 34, 113–124. <https://doi.org/10.1017/S0014479798001082>.
- Carneiro, F.M., Furlani, C.E., Zerbato, C., Menezes, P.C.D., Gírio, L.A.D.S. 2019. Correlations among vegetation indices and peanut traits during different crop development stages. *Engenharia Agrícola*, 39, 33-40. <https://doi.org/10.1590/1809-4430-Eng.Agric.v39nep33-40/2019>.
- Chen, A., Orlov-Levin, V., Meron, M. 2019. Applying high-resolution visible-channel aerial imaging of crop canopy to precision irrigation management. *Agricultural water management*, 216, 196-205. <https://doi.org/10.1016/j.agwat.2019.02.017>.
- Coelho, J.L.D. 1996. Ensaio e certificação de máquinas para a semeadura. In: MIALHE, L.G. *Máquinas agrícolas: ensaio e certificação*. Piracicaba: Fundação de Estudos Agrários “Luiz de Queiroz”. 55-70.
- Colvin, B., Rowland, D., Ferrell, J., Faircloth, W.H. 2014. Development of a digital analysis system to evaluate peanut maturity. *Peanut Science*, 41(1), 8–16. <https://doi.org/10.3146/PS13-9.1>.
- Köppen, W., Geiger, R. 1928. *Klimate der Erde; Wall-Map 150cmx200cm*; Verlag Justus Perthes: Gotha, Germany, 91–102. <https://doi.org/10.1590/0034-737X201663060002>.

Kurachi, H.A.S.; Costa, J.A. S.; Bernardi, J.A.; Coelho, J.L.D.; Silveira, G.M. 1989. Avaliação tecnológica de semeadoras e/ou adubadoras: tratamento de dados de ensaios e regularidade de distribuição longitudinal de sementes. *Bragantia*, Campinas, 2(48), 249-62. <https://doi.org/10.1590/S0006-87051989000200011>.

Li, R., Zhao, Z., Monfort, W. S., Johnsen, K., Zion, T.T., Leo, D.J. 2021. Development of a smartphonebased peanut data logging system. *Precision Agriculture*, <https://doi.org/10.1007/s11119-020-09758-8>.

Morlin Carneiro, F., Angeli Furlani, C.E., Zerbato, C., Menezes, P.C., Gírio, L.A.S., Oliveira, M.F. 2020. Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. *Precision Agric* 21, 979–1007. <https://doi.org/10.1007/s11119-019-09704-3>.

Prasad, P.V.V., Craufurd, P.Q., Summerfield, R.J., Wheeler, T.R. 2000. Effects of short episodes of heat stress on flower production and fruit - set of groundnut (*Arachis hypogaea* L.). *Journal of experimental botany*, 51(345), 777-784. <https://doi.org/10.1093/jexbot/51.345.777>.

Rowland, D.L., Sorensen, R.B., Butts, C.L., Faircloth, W.H. 2006. Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Science*, 33(2), 125-136. [https://doi.org/10.3146/0095-3679\(2006\)33\[125:DOMADD\]2.0.CO;2](https://doi.org/10.3146/0095-3679(2006)33[125:DOMADD]2.0.CO;2).

Rowland, D.L., Sorensen, R.B., Butts, C.L., Faircloth, W.H., Sullivan, D.G. 2008. Canopy characteristics and their ability to predict peanut maturity. *Peanut Science*, 35(1), 43-54. <https://doi.org/10.3146/PS06-052.1>.

Rutkoski, J., Poland, J., Mondal, S., Autrique, E., Pérez, L. G., Crossa, J., Reynolds, M., Singh, R. 2016. Canopy temperature and vegetation indices from high-throughput phenotyping improve accuracy of pedigree and genomic selection for grain yield in wheat. *Bethesda*, 6, 2799–2808. <https://doi.org/10.1534/g3.116.032888>.

Sanders, T.H., E.J. Williams, Schubert, A.M., Pattee, H.E. 1980. Peanut maturity method evaluations. I. Southeast. *Peanut Science* 7,78–82. <https://doi.org/10.3146/i0095-3679-7-2-5>.

Sanders, T.H., Shubert, A.M., Pattee, H.E. (1982). Maturity methodology and postharvest physiology. In H.E. Pattee C.T. Young (Eds.), *Peanut science and technology* (pp. 625–627). Tifton, GA: American Peanut Research and Education Society.

Santos, A.F., da Silva, R.P., Zerbato, C., Menezes, P.C., Kazama, E.H., Paixão, C.S.S., Voltarelli, M.A. 2019. Use of real-time extend GNSS for planting and inverting peanuts. *Precision Agric.*, 20, 840–856. <https://doi.org/10.1007/s11119-018-9616-z>.

Santos, A.F., Correa, L.N., Lacerda, L.N., Tedesco-Oliveira, D., Pilon, C., Vellidis, G., Silva, R.P. 2021. High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agric.*, 22, 1464–1478. <https://doi.org/10.1007/s11119-021-09791-1>,

Santos, A.F., Lacerda, L.N., Rossi, C., Moreno, L.A., Oliveira, M.F., Pilon, C., Silva, R., Vellidis, G. 2022. Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear Models and Artificial Neural Networks. *Remote Sens.*, 14(1), 93; <https://doi.org/10.3390/rs14010093>.

Teixeira, A.H.C., Bastiaanssen, W.G.M., Ahmad, M.D., Bos, M.G. 2008. Analysis of energy fluxes and vegetation-atmosphere parameters in irrigated and natural ecosystems of semi-arid Brazil. *Journal of Hydrology*, 362, 110–127. <https://doi.org/10.1016/j.jhydrol.2008.08.011>.

Teixeira, A.H.C. 2012. Modelling Evapotranspiration by Remote Sensing Parameters and Agro-meteorological Stations. In *Remote Sensing and Hydrology*; Neale, C.M.U., Cosh, M.H., Eds.; IAHS Publ. 352; IAHS Press: Wallingford, UK, 154–157.

Venancio, L.P., Mantovani, E.C., Amaral, C.H.D., Neale, C.M.U., Filgueiras, R., Gonçalves, I.Z., Cunha, F.F.D. 2020. Evapotranspiration mapping of commercial corn fields in Brazil using SAFER algorithm. *Scientia Agricola*, 78. <https://doi.org/10.1590/1678-992X-2019-0261>.

- Williams, E. J., Drexler, J. S. 1981. A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2), 134–141. <https://doi.org/10.3146/i0095-3679-8-2-15>.
- Yu, Chengfeng. 2021. Development of bulk peanuts maturity predictive model using hyperspectral imaging system, *Proc. SPIE 11878, Thirteenth International Conference on Digital Image Processing (ICDIP 2021)*, 1187821. <https://doi.org/10.1117/12.2601027>.
- Zhu, X., Helmer, E.H. 2018. An automatic method for screening clouds and cloud shadows in optical satellite image time series in cloudy regions. *Remote sensing of environment*, 214, 135-153. <https://doi.org/10.1016/j.rse.2018.05.024>.
- Zou, S., Tseng, Y.C., Zare, A., Rowland, D.L., Tillman, B.L., Yoon, S.C. 2019. Peanut maturity classification using hyperspectral imagery. *Biosystems Engineering*, 188, 165–177. <https://doi.org/10.1016/j.biosystemseng.2019.10.019>.

7. Material complementar

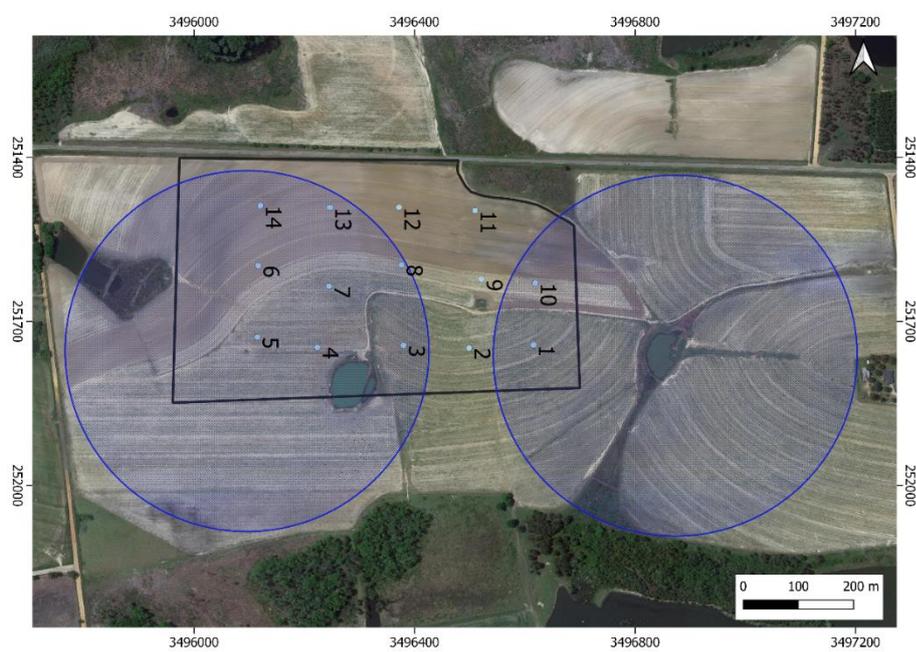


Figura 6. Disposição dos pivôs centrais no Campo C.

CAPÍTULO 4: CONSIDERAÇÕES FINAIS

Aliar ferramentas de sensoriamento remoto com dados meteorológicos pode permitir solucionar importantes gargalos do setor agrícola. Tratando-se da produção pecuária, um destes gargalos está relacionado à obtenção da massa de forragem, variável fundamental para a definição da capacidade de suporte do pasto. Comumente, esta avaliação é feita por meio do corte, secagem e pesagem da forragem. Por demandar muito tempo e mão de obra, muitos produtores acabam abrindo mão de usar a massa de forragem como apoio para a tomada de decisão. Fazendas mais tecnificadas já estão utilizando metodologias alternativas, como por exemplo a utilização de imagens de sensores orbitais para auxiliar nas decisões, entretanto, ainda é necessário buscar métodos que garantam maior precisão e acurácia às estimativas de massa de forragem.

Outro ponto a ser avaliado na utilização de sensores orbitais, está relacionado ao aumento de implantação de sistemas agroflorestais, como o silvipastoril. O componente arbóreo promove uma mistura espectral com a forragem e prejudica as estimativas de forragem que encontra-se abaixo ou sombreado pelas árvores, sendo o sensor proximal uma forma de impedir tal condição. Diante de todas essas questões, o SAFER, modelo cujas entradas são dados meteorológicos e espectrais, mostra-se uma ferramenta promissora para estimativa de massa de forragem, inclusive em sistemas silvipastoris por meio da utilização de sensor proximal.

Os resultados obtidos neste trabalho, no segundo capítulo, confirmam a hipótese levantada, sendo observada alta correlação entre os dados de massa de forragem estimadas pelo SAFER e os coletados *in situ* nos sistemas de produção animal a pleno sol e silvipastoril. Os modelos de regressão linear gerados a partir do que foi calculado pelo SAFER e os dados de campo apresentaram maior acurácia e precisão no sistema silvipastoril, quando desconsiderada a parcela de material morto da forragem, restando o que de fato tem maior valor nutritivo para o animal, as folhas e o caule.

Tratando-se da cultura do amendoim, um dos principais gargalos está na indicação do momento ideal do arranquio, que é fundamentado no ponto de maturação das vagens. O método tradicional de identificação da maturação é destrutivo, moroso, e subjetivo. Por ser influenciada pela temperatura, o processo de maturação, é outro parâmetro de cultura passível de ser estimada a partir do algoritmo SAFER.

A partir dos resultados encontrados no terceiro capítulo desta tese, observou-se que de fato existe correlação entre a evapotranspiração estimada pelo SAFER e a maturação das vagens. Com isso foi possível chegar a um modelo robusto de estimativa de maturação do amendoim, sem a necessidade de amostras destrutivas e reduzindo a subjetividade. Por se tratar de cultivo em monocultura, é possível optar por usar imagens de satélite, neste caso o PlanetScope com resolução espacial de três metros. Em regiões favoráveis ao desenvolvimento do amendoim, o período da safra é acompanhado por chuvas constantes e presença de nuvens que podem impedir a visualização dos campos de produção em imagens de satélite. Neste contexto, a aplicação do SAFER mostrou-se muito vantajosa, uma vez que utiliza imagens ao longo do ciclo da cultura e não dos dias exatos em que se deseja estimar a maturação. Com isso, amplia-se o intervalo de aquisição de imagens e impede que estimativas não sejam realizadas devido a presença de nuvens.

Diante dos resultados estimados a partir do modelo SAFER para massa de forragem, pretende-se criar uma plataforma mais intuitiva e simples para auxiliar o produtor na tomada de decisão. Em relação à cultura do amendoim, exclusivamente, a intenção é realizar este trabalho também no Brasil, uma vez que a cultura está em constante expansão. Entretanto, a escassez de estações meteorológicas no país pode ser um limitante à aplicação desta ferramenta, sendo necessário testar o modelo SAFER com dados faltantes.