

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E  
METEOROLOGIA  
PROGRAMA DE PÓS GRADUAÇÃO EM SENSORIAMENTO  
REMOTO

**MODELAGEM DA PRODUTIVIDADE PRIMÁRIA LÍQUIDA UTILIZANDO  
DADOS COLETADOS DE SENSORES REMOTOS: AVALIAÇÃO DE IMPACTOS E  
PERDAS EM ÁREA AGRÍCOLA**

Grazieli Rodigheri

Porto Alegre

2020

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E  
METEOROLOGIA  
PROGRAMA DE PÓS GRADUAÇÃO EM SENSORIAMENTO  
REMOTO

**MODELAGEM DA PRODUTIVIDADE PRIMÁRIA LÍQUIDA UTILIZANDO  
DADOS COLETADOS DE SENSORES REMOTOS: AVALIAÇÃO DE IMPACTOS E  
PERDAS EM ÁREA AGRÍCOLA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto para obtenção do título de Mestre em Sensoriamento Remoto.

Área de Concentração: Sensoriamento Remoto aplicado.

Grazieli Rodigheri

**Orientadora:** Prof.<sup>a</sup> Dr.<sup>a</sup> Denise Cybis Fontana

Porto Alegre

2020

### CIP - Catalogação na Publicação

Rodigheri, Grazieli  
MODELAGEM DA PRODUTIVIDADE PRIMÁRIA LÍQUIDA  
UTILIZANDO DADOS COLETADOS DE SENSORES REMOTOS:  
AVALIAÇÃO DE IMPACTOS E PERDAS EM ÁREA AGRÍCOLA /  
Grazieli Rodigheri. -- 2020.  
86 f.  
Orientadora: Denise Cybis Fontana.

Dissertação (Mestrado) -- Universidade Federal do  
Rio Grande do Sul, Centro Estadual de Pesquisas em  
Sensoriamento Remoto e Meteorologia, Programa de  
Pós-Graduação em Sensoriamento Remoto, Porto Alegre,  
BR-RS, 2020.

1. Modelagem da produtividade primária líquida da  
soja. 2. Dados meteorológicos de reanálise. 3. Dados  
de sensoriamento remoto. 4. Avaliação da apropriação  
humana da NPP. I. Fontana, Denise Cybis, orient. II.  
Título.

## FOLHA DE APROVAÇÃO

Grazieli Rodigheri

### **MODELAGEM DA PRODUTIVIDADE PRIMÁRIA LÍQUIDA UTILIZANDO DADOS COLETADOS DE SENSORES REMOTOS: AVALIAÇÃO DE IMPACTOS E PERDAS EM ÁREA AGRÍCOLA**

Dissertação de Mestrado apresentada ao  
Programa de Pós-Graduação em Sensoriamento  
Remoto para obtenção do Título de Mestre em  
Sensoriamento Remoto.

Área de Concentração: Sensoriamento Remoto  
aplicado.

Aprovado em 21 de fevereiro de 2020

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Tatiana Mora Kuplich – PPGSR/UFRGS

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Bernadete Radin – UFRGS

---

Prof. Dr. Juliano Schirmbeck – UNIVATES

---

Dr. Elias Berra – Pósdoc/UFRGS

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Denise Cybis Fontana – UFRGS (Orientadora)

Dedico este trabalho à minha família, pais, irmãos e namorado, que sempre estiveram dando apoio e não mediram esforços para que eu chegasse até esta etapa importante de minha vida.

## AGRADECIMENTOS

Primeiramente quero agradecer aos meus pais, por sempre me incentivarem a conquistar meus objetivos. Por ensinarem que os nossos erros servem como exemplo para aprendizado e para seguir em frente, que a vida é simples, mas devemos ter sempre responsabilidade sobre ela. Quero agradecê-los por todo amor, carinho, compreensão, ajuda e por serem tão especiais.

A minha orientadora, Denise, pela oportunidade de trabalharmos juntas, tornando a minha experiência no mestrado um grande aprendizado. Por todo o apoio e troca de ideias nesse período que convivemos e, também, pelo exemplo como pessoa e realização profissional. Agradeço por sempre me incentivar e estar disposta a ajudar, tornando as coisas mais simples e bonitas. Sempre paciente, atenciosa e com um mundo de conhecimentos a difundir. Agradeço a amizade e por me proporcionar tantas coisas boas. Grande parte do meu crescimento devo a ela.

A minha família, principalmente avós e tios, que sempre me apoiam e torcem pela realização dos meus sonhos. Sempre muito carinhosos e amáveis, buscando ajudar no que for preciso.

Agradeço a todas as pessoas que fizeram parte desta etapa, e que, de alguma forma, contribuem para tornar-me melhor. Aos meus amigos, que são muitos, mas aos que estiveram mais presentes, a Laís, a Muni, a Rafa, o Alan, o Nunes e o Samuca entre vários outros, que sempre estiveram me apoiando e dando força para enfrentar os momentos difíceis. Eles que também fazem parte dos momentos alegres da vida, e me fazem sentir segura de nunca estar só. Agradeço em especial ao Alan, que sempre esteve muito presente nestes dois anos e que, sempre muito disposto a ajudar e a ouvir, se tornou um grande amigo. Obrigada pela amizade, pelos conselhos e ajuda, pela companhia e pelos momentos bons.

Aos amigos e colegas de trabalho, do LEAA e da Agrometeorologia, principalmente aqueles que foram essenciais na realização deste trabalho, sempre ajudando de alguma forma, Laura, Dani, Lucimara, Juliano, Tales, Bernadete, Homero, Ricardo e os demais.

Quero muito agradecer a minha segunda família, a família Becker da Luz, por tornarem minha caminhada mais completa e mais feliz. Agradeço o carinho, apoio e por todos os momentos bons que tem me proporcionado.

A todos os professores, colegas e amigos do PPGSR, por contribuírem para meu crescimento pessoal e profissional. Pelo tanto de conhecimento compartilhado, pela amizade e pelo acolhimento.

Agradeço a UFRGS e a CAPES, pela oportunidade de realizar um curso de Pós-Graduação, com incentivo a congressos, exposições, ampliando o conhecimento e as experiências de vida.

Por fim, e não menos importante, quero agradecer a três pessoas que são muito importantes na minha vida. Ao meu irmão, Lucas, pelo apoio de sempre e pela ajuda. Também, por sempre descontraír minha vida, com diversão. E por me ensinar a lidar com as diferenças.

A minha irmã, Mareli, por ser sempre tão atenciosa e amável, torcendo para o meu crescimento pessoal e profissional, me ajudando em tudo o que pode. Por me ensinar e dar exemplo, que é estudando que se aprende e que quando se tem determinação alcança-se os sonhos. Por todo amor e atenção, pelos momentos bons, por ser paciente e por essa interação de sentimentos que temos, que faz bem e não se explica, se vive.

Enfim, agradeço por tudo. E, ao meu namorado e companheiro de vida, Leonardo, que está comigo em todos os momentos, sejam eles difíceis ou bons. Agradeço, em especial, por toda a ajuda e apoio de sempre, por me acompanhar nas muitas vezes que estive sozinha trabalhando, até de madrugada. Por me ensinar tudo sobre componentes eletrônicos, programação, aviação e que conhecimento variado é fundamental. Agradeço por essa troca de experiência ao longo desses anos juntos. Por fim, por me ensinar os sentimentos mais nobres que existem e sempre me dar apoio e suporte para realizar meus sonhos, sempre com muito carinho, companheirismo e amor

*“Um cientista em um laboratório não é um mero técnico: ele também é uma criança que confronta fenômenos naturais que o impressionam como se fossem contos de fada.”*

[Marie Curie – 1867 - 1934]



# MODELAGEM DA PRODUTIVIDADE PRIMÁRIA LÍQUIDA UTILIZANDO DADOS COLETADOS DE SENSORES REMOTOS: AVALIAÇÃO DE IMPACTOS E PERDAS EM ÁREA AGRÍCOLA<sup>1</sup>

**Resumo:** A Produtividade Primária Líquida (Net Primary Productivity - NPP) é um parâmetro de importância global, devido ao papel que desempenha no ciclo do carbono. Muitos modelos têm sido desenvolvidos nos últimos anos, principalmente para integrar dados de sensores remotos e facilitar a estimativa de NPP. No entanto, alguns ajustes ainda são necessários para que estes modelos consigam representar eficientemente os dados reais na superfície. Assim, o objetivo desta pesquisa foi o teste e o desenvolvimento de metodologias capazes de quantificar e mapear a NPP através de dados coletados de sensores remotos, nas condições ambientais do Noroeste do Rio Grande do Sul. Sendo assim, foram feitas estimativas de NPP potencial, através do modelo Thornthwaite, para um período de 10 anos, incorporando dados climáticos obtidos de Estações Meteorológicas e dados de reanálise do ERA-Interim. As estimativas de NPP potencial foram similares aquelas obtidas com dados medidos na superfície, indicando que estes podem ser utilizados nas estimativas do potencial de NPP. Para a estimativa de NPP real, utilizou-se o modelo Carnegie-Ames-Stanford Approach (CASA), baseado em dados de superfície e de sensores remotos. O modelo CASA produziu estimativas acuradas da NPPreal quando comparadas aos dados medidos de superfície e se mostraram adequadas para representar o perfil temporal da soja durante o ciclo de desenvolvimento da cultura. Além disso, utilizou-se o Índice de Umidade de Superfície (TVDI) como alternativa ao coeficiente de estresse hídrico para compor o modelo CASA, o que produziu estimativas acuradas de NPP em relação ao modelo original. Existe vantagem no uso da abordagem que introduz o TDVI, em função dos resultados com maior detalhamento espacial, além de utilizar dados exclusivamente de sensores remotos para rodar o modelo CASA. O uso do sensoriamento remoto ajuda a capturar pequenas mudanças hídricas e seus efeitos sobre a vegetação de forma mais precisa e com maior detalhamento. As estimativas de NPP potencial e NPP real foram comparadas para verificar as mudanças causadas na produção agrícola na região de estudo. Observou-se que quando realizado apenas um cultivo agrícola anual, a apropriação poder chegar a até 28% da NPP potencial. A quantificação da HANPP permite verificar se existem perdas ou ganhos de NPP potencial e, assim, subsidiar a busca de estratégias de gerenciamento para incremento da produtividade dos cultivos e minimização da demanda de terras novas de produção agrícola.

**Palavras-chave:** TVDI, ERA-Interim, Google Earth Engine, Carbono, Soja, NDVI, Temperatura Superficial

# **MODELING OF NET PRIMARY PRODUCTIVITY USING DATA COLLECTED FROM REMOTE SENSORS: ASSESSMENT OF IMPACTS AND LOSSES OF AGRICULTURAL AREAS**

**Abstract:** Net Primary Productivity (NPP) is a parameter of global importance, due to the role it plays in the carbon cycle. Many models have been developed in recent years, mainly to integrate data from remote sensors and facilitate the estimation of NPP. However, some adjustments are still necessary for these models to be able to efficiently represent the actual data on the surface. Thus, the objective of this research was to test and develop methodologies capable of quantifying and mapping NPP through data collected from remote sensors, in the environmental conditions of northwest Rio Grande do Sul. Therefore, estimates of potential NPP were made, through the Thornthwaite model, for a period of 10 years, incorporating climatic data obtained from Meteorological Stations and reanalysis data from ERA-Interim. The estimates of potential NPP were similar to those obtained with data measured on the surface, indicating that these can be used in estimates of the potential of NPP. For estimating real NPP, the Carnegie-Ames-Stanford Approach (CASA) model was used, based on surface data and remote sensors. The CASA model produced accurate estimates of the actual NPP when compared to the measured surface data and proved to be adequate to represent the soybean temporal profile during the crop development cycle. In addition, the Temperature-Vegetation Dryness Index (TVDI) was used as an alternative to the water stress coefficient to compose the CASA model, which produced accurate NPP estimates in relation to the original model. There is an advantage in using the approach that introduces TDVI, due to the results with greater spatial detail, in addition to using data exclusively from remote sensors to run the CASA model. The use of remote sensing helps to capture small water changes and their effects on vegetation more precisely and in greater detail. The estimates of potential NPP and actual NPP were compared to verify the changes caused in agricultural production in the study area. It was observed that when there is only one annual agricultural crop, the appropriation can reach up to 28% of the potential NPP. The quantification of the HANPP allows to verify if there are losses or gains of potential NPP and, therefore, to subsidize the search for management strategies to increase the productivity of the crops and minimize the demand for new agricultural production lands.

**Keywords:** TVDI, ERA-Interim, Google Earth Engine, Carbon, Soybean, NDVI, Superficial Temperature

# SUMÁRIO

1.	INTRODUÇÃO.....	19
1.1	OBJETIVO .....	20
1.1.1	Objetivos específicos .....	20
2.	ORGANIZAÇÃO DA DISSERTAÇÃO.....	22
3.	REVISÃO BIBLIOGRÁFICA.....	23
3.1	PRODUTIVIDADE PRIMÁRIA DO ECOSISTEMA .....	23
3.2	IMPACTOS E PERDAS SOBRE A NPP DOS ECOSISTEMAS.....	24
3.3	MODELAGEM E ESTIMATIVA DA NPP .....	27
3.3.1	Uso de sensoriamento remoto para estimativa da NPP .....	28
3.3.1.1	Estimativa de NPP potencial.....	29
3.3.1.2	Estimativa da NPP real através da detecção remota .....	30
3.3.1.3	Espacialização do modelo.....	34
4.	REFERÊNCIAS .....	35
5.	DESENVOLVIMENTO .....	42
5.1	Artigo 1 - Modelagem da Produtividade Primária Líquida (NPP) utilizando dados meteorológicos de reanálise ERA-Interim: avaliação dos efeitos das atividades humanas sobre a produtividade da soja. ....	42
5.2	Artigo 2 - Estimativa da Produtividade Primária Líquida em ecossistemas agrícolas no Sul do Brasil utilizando o TVDI como parâmetro de estresse hídrico. ....	67
6.	CONSIDERAÇÕES FINAIS .....	90

## LISTA DE FIGURAS

Figura 1 - Produtividade Primária Líquida potencial do ambiente (NPPpot) e real (NPPact). A diferença entre elas retorna a Apropriação Humana da NPP pelo uso da terra (HANPPluc) e a diferença entre NPPreal e NPP colhida (HANPPharv) retorna a NPP disponível naquele ecossistema (NPPeco). .....	26
Figura 2 - Representação esquemática do triângulo evaporativo dado pela relação entre Ts e NDVI .....	34
Figura 3 - Produtividade Primária Líquida potencial (NPPpot) calculada com a evapotranspiração real estimada pelo modelo de Thornthwaite (To) e pelo Balanço Hídrico (TBH), ambos com dados meteorológicos obtidos da Estação Automática Meteorológica do INMET (EM) e com dados de reanálise do ERA Interim (ERA).....	54
Figura 4 – Total anual de Precipitação pluvial e Temperatura do ar média anual para os anos agrícolas de 2009 a 2018. Carazinho-RS .....	56
Figura 5 – Produtividade Primária Líquida observada a campo (NPPreal_campo), utilizando dados de APAR de campo (NPPreal_APAR_campo) e utilizando dados de NDVI para estimar a PAR (NPPreal_APAR_NDVI) para o cultivo da soja. ....	57
Figura 6 – Dispersão entre resultados de Produtividade Primária Líquida (NPP) observada a campo (NPPreal_campo) e estimada utilizando dados de APAR medidos a campo (NPPreal_APAR_campo), e estimada a partir do NDVI (NPPreal_APAR_NDVI) medido para a cultura da soja. ....	58
Figura 7 – Estimativas de Produtividade Primária Líquida potencial (NPPpot), real (NPPact), Apropriação Humana da NPP pelo uso da terra (HANPPluc), NPP colhida (HANPPharv) e NPP disponível naquele ecossistema (NPPeco). (Com base em Haberl; Erb e Krausmann, 2014).....	59
Figura 8 – Área cultivada com soja em 2017 na mesorregião agrícola do Noroeste do Estado do Rio Grande do Sul e localização da área experimental no município de Carazinho. ....	71
Figura 9 – Dispersão entre a NPP modelada $NPP_{real\_W\varepsilon_{TVDI}}$ e $NPP_{real\_W\varepsilon_0}$ observada $NPP_{real\_campo}$ . Obtidas através de imagens e estimadas a partir de dados de superfície, respectivamente. Valores de coeficiente de correlação (R) e do erro quadrático médio (RMSE).....	76

<p>Figura 10 - Comparação do perfil temporal entre a NPP observada a campo e modelada pelo modelo CASA utilizando o TVDI <math>NPP_{real\_W_{\epsilon TVDI}}</math> e utilizando <math>W_{\epsilon}</math> original <math>NPP_{real\_W_{\epsilon o}}</math>.....</p>	77
<p>Figura 11 – Distribuição espacial das estimativas de Produtividade Primária Líquida (NPP) mensais e acumulado ao longo do ciclo para o modelo <math>NPP_{real\_W_{\epsilon TVDI}}</math> (esquerda) e <math>NPP_{real\_W_{\epsilon o}}</math> (direita).....</p>	78
<p>Figura 12 – Espacialização do modelo <math>NPP_{real\_W_{\epsilon TVDI}}</math> (esquerda) e <math>NPP_{real\_W_{\epsilon o}}</math> (direita) para a mesorregião agrícola do noroeste do estado do Rio Grande do Sul, utilizando dados MODIS.....</p>	80
<p>Figura 13 – Espacialização do modelo <math>NPP_{real\_W_{\epsilon TVDI}}</math> (esquerda) e <math>NPP_{real\_W_{\epsilon o}}</math> (direita) para a mesorregião agrícola do noroeste do estado do Rio Grande do Sul, utilizando dados MODIS.....</p>	81
<p>Figura 14 – Diagrama de caixas do perfil de NPP ao longo do ciclo de cultivo da soja para os modelos <math>NPP_{real\_W_{\epsilon TVDI}}</math> (a) e <math>NPP_{real\_W_{\epsilon o}}</math> (b). As caixas delimitam o primeiro e o terceiro percentil do conjunto de dados, e a linha centralizada sobre elas indica a mediana referente a estes. As linhas contínuas indicam os demais dados dentro do conjunto e os círculos indicam os outliers ou pontos que estão afastados demais do conjunto ou inconsistentes. Dados normalizados.....</p>	82

## LISTA DE TABELAS

<b>Tabela 1</b> – Avaliação da NPP potencial (NPPpot) para as fontes de dados do ERA-Interim (ERA) e da Estação Meteorológica (EM), para os métodos de cálculo de NPPpot de Thornthwaite (To) e do Balanço Hídrico (TBH).....	54
---	----

## LISTA DE ABREVIATURAS E SIGLAS

APAR	Absorbed Photosynthetically Active Radiation Radiação Fotossinteticamente Ativa Absorvida
CASA	Carnegie Ames Stanford Approach
ESA	European Space Agency Agência Espacial Européia
FPAR	Fraction of Photosynthetically Active Radiation Fração da Radiação Fotossinteticamente Ativa
GPP	Gross Primary Productivity Produtividade Primária Bruta
LAI	Leaf Area Index Índice de Área Foliar
LUE	Light Use Efficiency Eficência do Uso da Luz
MSI	Multispectral Instrument
NDVI	Normalized Difference Vegetation Index Índice de Vegetação por Diferença Normalizada
NIR	Near-Infrared Infravermelho-próximo
NPP	Net Primary Productivity Produtividade Primária Líquida
OLI	Operational Land Imager
PAR	Photosynthetically Active Radiation Radiação Fotossinteticamente Ativa
SWIR	Short-wave infrared Infravermelho de Ondas Curtas
TIR	Thermal Infrared Infravermelho Termal
TIRS	Thermal Infrared Sensor
TVDI	Temperature Vegetation Dryness Index Índice de Umidade da Superfície
USGS	United States Geological Survey Serviço Geológico dos Estados Unidos

# 1. INTRODUÇÃO

Nos últimos anos, o crescimento populacional e o desenvolvimento econômico aumentaram as demandas humanas na superfície terrestre, como por exemplo, a produção de alimentos e bioenergia. Como resultado disso, houve um aumento da expansão agrícola que, em muitos casos, se deram sobre ecossistemas naturais. O aumento da produção e extensão agrícola, deve-se principalmente aos recentes avanços nas técnicas de manejo das culturas, uso de tecnologias modernas e novos insumos agrícolas.

No entanto, boa parte destas expansões ocorreram sem planejamento logístico e tecnológico, impulsionando diversas mudanças ambientais globais em todas as escalas. Embora inevitável, a expansão agrícola em ecossistemas naturais leva a perdas significativas de serviços ecossistêmicos, como por exemplo, o armazenamento de carbono pela vegetação (Foley et al., 2005), perda de biodiversidade, entre outros. Atualmente, muitos estudos científicos e tecnológicos demonstraram a mitigação destes feitos, tendo como objeto principal de estudo a remoção do carbono atmosférico.

A assimilação do carbono atmosférico é feita pela vegetação através do processo de fotossíntese e denominada como sendo a Produtividade Primária Líquida (NPP) da vegetação (Gang et al., 2015). Assim, a NPP pode ser entendida como a quantidade de matéria orgânica que foi produzida pelas plantas a partir da energia solar em determinado tempo e espaço.

Um dos aspectos mais importantes da NPP, é que esta não reflete apenas a produtividade de uma comunidade de plantas em seu ambiente natural, mas também sua capacidade de sequestro de carbono. O equilíbrio entre a absorção e a liberação de carbono desempenha um papel fundamental nos ciclos de carbono biogeoquímicos globais (Wang et al., 2009). Nesse sentido, quantificar a NPP dos sistemas agrícolas é um importante passo para conciliar a produtividade agrícola e a sustentabilidade ambiental.

Embora as medições de NPP possam ser realizadas à campo, elas são frequentemente demoradas e trabalhosas e restritas a pequenas áreas. Portanto, é necessário avaliar métodos alternativos de estimativa de NPP para substituir ou suplementar abordagens tradicionais na coleta de dados ecológicos (Pachavo e Murwira, 2014). O desenvolvimento das técnicas de sensoriamento remoto criou condições para incrementar a capacidade de estudar e entender os ecossistemas com maior precisão fornecendo diversas ferramentas para a estimativa de NPP em escalas regional e global.



Nos últimos anos, com o aumento da disponibilidade de dados de sensoriamento remoto, diversos métodos e modelos têm sido desenvolvidos para estimar a NPP em diversos locais e escalas espaciais e temporais. Estes modelos são executados de maneira relativamente simples, e podem fornecer dados de cobertura total da área de estudo, além de informações precisas sobre mudanças da dinâmica da NPP. No entanto, ainda são necessários estudos no sentido de se obter um aprimoramento destes modelos e uma melhor precisão das estimativas de NPP para os diferentes ecossistemas do Planeta.

Além disso, a garantia de estimativas espacialmente definidas de NPP para terras agrícolas são necessárias para melhorar as estimativas dos fluxos de carbono (West et al., 2010), dos impactos ambientais da produção agrícola e do quanto a NPP de um ecossistema pode ser apropriada em função das atividades humanas diretas. Partindo-se da premissa de que para uma maior produtividade dos sistemas agrícolas, aliada à sustentabilidade do meio ambiente, é imperativo criar ferramentas apropriadas para monitorar as atividades atuais e delinear estratégias adequadas para lidar com as mudanças esperadas no futuro.

Muitos dos modelos de estimativa de NPP desenvolvidos fornecem abordagens eficazes para avaliar a dinâmica da NPP em escalas regionais a globais. No entanto, o uso destes modelos ainda possui algumas incertezas, principalmente quando aplicado em escalas locais, uma vez que a NPP é bastante influenciada por fatores que variam espacial e temporalmente.

Assim, torna-se indispensável a realização de testes localmente, permitindo avaliar o desempenho do modelo baseado em dados remotos frente a dados coletados a campo para estimativas de NPP. A grande vantagem da validação destes modelos encontra-se na possibilidade de espacialização de estimativas de NPP mais precisas e que possam caracterizar melhor as variações espaço-temporais regional e globalmente.

## **1.1 OBJETIVO**

O presente trabalho, teve como objetivo principal o teste e a validação de metodologias capazes de quantificar e mapear a Produtividade Primária Líquida através de dados coletados de sensores remotos, nas condições ambientais do Noroeste do Rio Grande do Sul.

### **1.1.1 Objetivos específicos**

Para as condições ambientais da região de estudo, especialmente relacionadas ao clima, solo, relevo, uso e cobertura e manejo, busca-se:

- Caracterizar e analisar a NPP potencial através do modelo Thornthwaite (Lieth, 1975), utilizando dados meteorológicos medidos e estimados (ERA-Interim);

- Avaliar e validar o modelo CASA para estimativa da NPP real frente aos dados de campo, usando dados meteorológicos estimados (ERA-Interim);

- Verificar as mudanças causadas pelas variações das condições meteorológicas na NPP potencial e avaliar as mudanças causadas por atividades humanas no sistema de produção agrícola da soja;

- Avaliar o desempenho do modelo CASA, a partir da introdução do índice TVDI como coeficiente de estresse de umidade, para quantificar a dinâmica da NPP;

- Analisar o padrão médio e a variabilidade espacial e temporal da NPP em lavouras de soja no Noroeste do Estado do Rio Grande do Sul.

## 2. ORGANIZAÇÃO DA DISSERTAÇÃO

Este trabalho está organizado em duas seções principais, sendo a primeira delas o referencial teórico e bibliográfico sobre conceitos abordados e estudados para o desenvolvimento do trabalho. A revisão bibliográfica apresentará alguns estudos e definições a respeito da estimativa da NPP utilizando técnicas de medições remotas, e os impactos causados por atividade humanas e variabilidades climáticas.

A segunda parte consta do desenvolvimento do trabalho, dividida em dois artigos, que tratam especificamente de:

**Artigo 1 – Modelagem da Produtividade Primária Líquida (NPP) utilizando dados meteorológicos de reanálise ERA-Interim: avaliação dos efeitos das atividades humanas sobre a produtividade da soja.**

**Artigo 2 – Estimativa da Produtividade Primária Líquida em ecossistemas agrícolas no Sul do Brasil utilizando o TVDI como parâmetro de estresse hídrico.**

### 3. REVISÃO BIBLIOGRÁFICA

#### 3.1 PRODUTIVIDADE PRIMÁRIA DO ECOSISTEMA

A fotossíntese é o mecanismo responsável por grande parte do fluxo global de carbono e influencia diversas funções ecossistêmicas, como a respiração e o crescimento vegetal (Beer et al., 2010). Através da fotossíntese ocorre a assimilação do carbono atmosférico ( $\text{CO}_2$ ) e, conseqüentemente, a produção de compostos orgânicos pelas plantas (Pei et al., 2013), também conhecida como sendo a Produtividade Primária Bruta (GPP) de um ecossistema (Silva, 2013). Ao descontar deste processo os gastos energéticos decorrentes da respiração autotrófica, obtém-se a Produtividade Primária Líquida (NPP) de um ecossistema (Pei et al., 2013, Zhu et al, 2017).

A NPP fornece a energia que impulsiona a maioria dos processos bióticos na Terra e representa grande parte da matéria orgânica que é consumida por micróbios e animais (Potter; Klooster e Genovese, 2012). A importância em conhecer a NPP dos ecossistemas terrestres está ligada ao papel central que esta desempenha no ciclo do carbono e no fluxo de energia em diversos ecossistemas (Rosa e Sano, 2013). Pois, assim como abordou Zhu et al. (2017), este parâmetro não apenas descreve quantitativamente a entrada de energia na biosfera e a quantidade de assimilação de  $\text{CO}_2$ , mas também reflete o processo cíclico do fluxo de carbono na atmosfera, nos ecossistemas terrestres e no solo. Desta forma, a NPP torna-se a base de grande parte das interações materiais e energéticas no ecossistema, sendo responsável por manter a circulação do carbono na atmosfera.

Como a NPP é um componente essencial do ciclo do carbono, diversas questões científicas relevantes para a humanidade, tem como ponto inicial a avaliação este parâmetro, como, por exemplo, aquelas relacionadas à degradação ambiental (desertificação, desmatamento e os impactos da poluição e das mudanças climáticas (Running et al., 2004)). Como ressaltaram Gao et al. (2013), a NPP é uma variável ecológica fundamental, não apenas porque mede a entrada de energia na biosfera e na assimilação do dióxido de carbono terrestre, mas também devido à sua importância em indicar a condição da superfície da terra e o status de uma ampla gama de processos ecológicos.

Este parâmetro pode ser determinado pela estrutura (distribuição e aspectos sazonais da vegetação) e função (por exemplo, em ciclos biogeoquímicos) da vegetação que, por sua vez, são afetados por variáveis ambientais como radiação solar, concentração de  $\text{CO}_2$ , temperatura, precipitação e fertilidade do solo (Wang et al., 2009; Pei et al., 2013). Deste modo, as

variabilidades climáticas podem influenciar diretamente o crescimento da vegetação, já que mudanças de temperatura e precipitação podem determinar as condições hidrotérmicas do crescimento da vegetação, especialmente para os ecossistemas secos (Li et al., 2015).

Além disso, a NPP pode ser afetada por fatores antropogênicos (Running et al., 2004; Wang et al., 2009), sendo a influência mais óbvia aquela causada pelas mudanças no uso da terra e no tipo de cobertura, consequências de diversas atividades humanas. Nesse sentido, a modelagem e o monitoramento da NPP são relevantes para a compreensão do ciclo global do carbono, assim como, na avaliação dos efeitos da variação climática interanual, da mudança no uso e cobertura da terra e perturbações antropogênicas no ciclo do carbono terrestre, e na segurança alimentar e sustentabilidade no ecossistema regional (Gao et al., 2013)

A compreensão e entendimento dos papéis relativos que o clima e as atividades humanas desempenham no padrão e variabilidade da NPP (Ugbaje et al., 2016), entre diferentes ecossistemas, é fundamental para avaliar os impactos e perdas na produtividade da vegetação. Isso ganha ainda mais importância para os seres humanos, principalmente por causa de preocupações sobre até que ponto a NPP de ecossistemas gerenciados pode fornecer alimentos e fibras adequados para uma população humana em crescimento (Potter; Klooster e Genovese, 2012). Neste quesito, as terras cultiváveis desempenham um papel importante no balanço global de carbono, contribuindo para NPP, característica vital para a função do ecossistema (Piana e Civeira, 2017).

### **3.2 IMPACTOS E PERDAS SOBRE A NPP DOS ECOSISTEMAS**

A degradação da terra é uma questão global que levou à deterioração da estrutura, função e serviços do ecossistema, causando sérios problemas ambientais (Gibbs e Salmon, 2015). Grande parte das áreas agrícolas recém-expandidas nos trópicos vieram à custa de áreas naturais de grande importância ambiental, como o bioma Cerrado, na região Norte do Brasil (Spera et al., 2016). A expansão agrícola sobre áreas naturais e sem o manejo e técnicas de cultivo adequadas pode provocar impactos e desequilíbrios ambientais.

Como resultado disso, diversos indicadores para avaliar o impacto e a intensidade do uso da terra foram desenvolvidos, como por exemplo, o indicador de Apropriação Humana da NPP (HANPP), que foi calculada pela primeira vez por Whittaker e Likens (1973) e, mais tarde, aprofundado por Haberl et al. (1997). A HANPP refere-se à proporção da produção anual de biomassa vegetal apropriada ou perdida em função da atividade humana e foi sugerida como

uma medida da intensidade do uso da terra por Vitousek et al. (1986). Assim, este indicador pode medir a quantidade de NPP perdida após a intervenção humana, devido a biomassa colhida e mudanças de funções da terra (Taelman et al., 2016).

A estrutura do HANPP engloba vários indicadores, baseados em diferentes fluxos de NPP (Haberl et al., 2007; Erb et al., 2007). Entre eles estão a NPP potencial (NPP<sub>pot</sub>) da vegetação, definida como a NPP da vegetação natural que prevaleceria nos ecossistemas na ausência de uso da terra pelos seres humanos (Krauschman et al., 2013; Souza e Malhi, 2017; Lorel et al., 2019); a NPP real (NPP<sub>real</sub>), que representa a situação real da produtividade da vegetação, que pode ser controlada pelo clima e também pelas atividades humanas (Li et al., 2018); e, por fim, a NPP<sub>eco</sub>, que se refere a fração de NPP que permanece nos ecossistemas após a colheita (Souza e Malhi, 2017; Lorel et al., 2019).

A estimativa do total de HANPP, medido em unidades de carbono, é a soma de duas subcategorias: HANPP<sub>luc</sub> e HANPP<sub>harv</sub> (Krauschman et al., 2013). A HANPP<sub>harv</sub> infere sobre a quantidade de carbono em forma de biomassa que é colhida (Lorel et al., 2019; Haberl; Erb e Krausmann, 2014), incluindo culturas, madeira, resíduos de colheitas, forragem consumida pelos animais e biomassa perdida pelos incêndios induzidos por humanos (Krauschman et al., 2013). Já a HANPP<sub>luc</sub>, refere-se ao resultado de mudanças no uso da terra induzidas pelo homem, como a conversão de florestas em terras agrícolas ou infraestrutura (Krauschman et al., 2013; Haberl; Erb e Krausmann, 2014). Todos estes parâmetros foram bem representados e estudados por Haberl; Erb e Krausmann, (2014) (Figura 2).

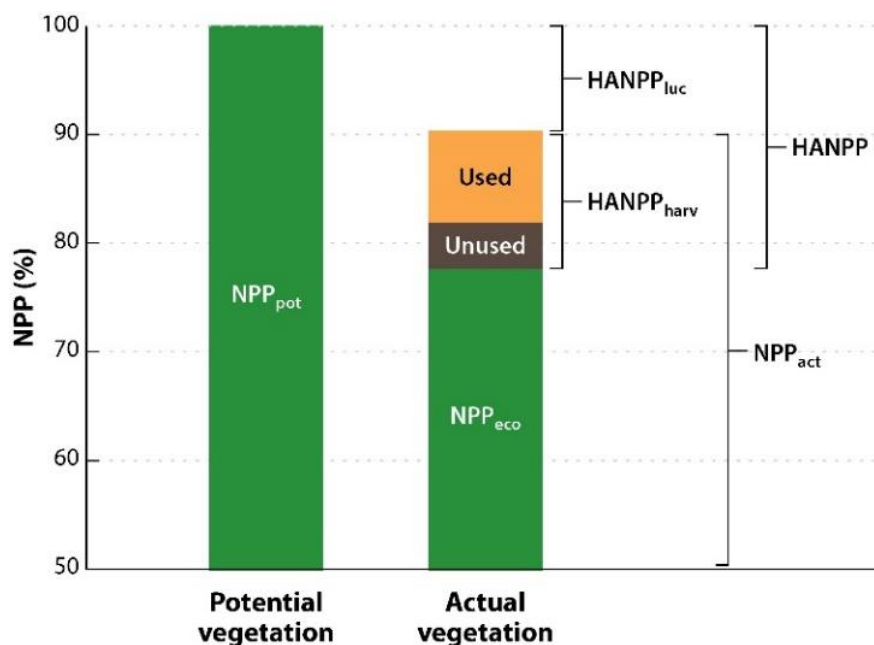


Figura 1 - Produtividade Primária Líquida potencial do ambiente ( $NPP_{pot}$ ) e real ( $NPP_{act}$ ). A diferença entre elas retorna a Apropriação Humana da NPP pelo uso da terra ( $HANPP_{luc}$ ) e a diferença entre  $NPP_{real}$  e NPP colhida ( $HANPP_{harv}$ ) retorna a NPP disponível naquele ecossistema ( $NPP_{eco}$ ).

(Fonte: Haberl; Erb e Krausmann, 2014)

Diversos estudos indicam que a HANPP da vegetação pode ser determinada comparando a  $NPP_{pot}$  com a  $NPP_{real}$ , assumindo que esta diferença representa os impactos de fatores humanos na vegetação (Fig.1) (Li et al., 2018; Zhou et al., 2017; Wessels; Prince e Reshef, 2008). Portanto, um estudo sobre o impacto de fatores humanos determinantes na dinâmica de mudanças de produção da vegetação pode ser realizado comparando-se as tendências de variação da  $NPP_{pot}$ ,  $NPP_{real}$  e HANPP ao longo de períodos (Wu et al., 2017).

Muitos dos ambientes cultivados, certamente apresentam NPP superior ao que o mesmo apresentava naturalmente. Em contrapartida, podem existir locais em que a NPP dos cultivos agrícolas está abaixo do que o ambiente potencializa (Haberl et al., 2004). O uso da terra é um dos principais impulsionadores da mudança na cobertura da terra (Erb et al., 2007) e nos padrões de produtividade da vegetação dos ecossistemas, causando mudanças ambientais globais.

A cultura da soja (*Glycine max*0. (L.) Merr.) é uma das principais culturas colhidas em todo o mundo, ocupando uma vasta diversidade de climas e solos (FAO, 2014). O Brasil, que possui uma das maiores reservas de carbono de base florestal do planeta, também está enfrentando pressão para a transformação da terra em larga escala para a produção agrícola (Chaplin-Kramer et al., 2015). Um dos cultivos que mais se intensificou nas últimas décadas foi o cultivo da soja, tornando o Brasil um dos maiores produtores (EMBRAPA, 2018). Porém

ainda são poucas as diretrizes sobre o avanço destas áreas em ecossistemas naturais de grande importância ambiental, fazendo-se necessário compreender os impactos ambientais futuros da produção agrícola no país e como alcançar maiores produtividades com impactos menores e maior preservação de ecossistemas de alto valor ambiental.

Existe um amplo consenso de que a produção agrícola global é e será significativamente afetada pelas mudanças climáticas (Parry et al., 2004). Assim, o monitoramento e a previsão da produção da vegetação agrícola são importantes para o manejo agrícola (Mulla, 2013), segurança alimentar (Meroni et al., 2014) e pesquisa do ciclo do carbono (Gitelson et al., 2014). A gestão da demanda por novas terras agrícolas é importante, e abordagens de modelagem preditiva para o desenvolvimento e gerenciamento da terra são urgentes e necessárias para melhor informar os tomadores de decisão (Chaplin-Kramer et al., 2015).

### **3.3 MODELAGEM E ESTIMATIVA DA NPP**

Muitas abordagens já foram desenvolvidas para modelar a NPP em diversos sistemas de cultivo (Li; Chen e Tong, 2014). As principais abordagens utilizadas nestas pesquisas abrangem: o monitoramento de parcelas amostrais, a utilização de modelos de simulação de ecossistemas terrestres (Adams, White e Lenton, 2004), modelos baseados em clima (Gang et al., 2018) e modelos baseados em dados de sensoriamento remoto (Running et al., 2004).

Apesar de ser o método mais confiável e de alta precisão, a abordagem de parcelas amostrais é limitada pela considerável carga de trabalho, período de investigação necessário (Fang; Wang e Shao, 2015) e limitação na capacidade de cobrir áreas espaciais maiores para fins de coleta de informações. Este é um método adequado somente para estudos em pequenas parcelas (Li; Chen e Tong, 2014).

Já os modelos de simulação de NPP têm sido amplamente relatados durante as últimas décadas (Gang et al., 2018). Entre estes estão os modelos baseados em: (i) clima, como por exemplo o modelo de Miami (Lieth, 1975) e o modelo Thornthwaite (Lieth e Box, 1972 apud Lieth, 1975); (ii) modelos baseados em processos, como por exemplo, o Biome – BGC (Running e Hunt, 1993); (iii) os modelos baseados no conceito de Eficiência de Uso da Luz (LUE), como por exemplo, o modelo CASA (Potter et al., 1993) e o modelo Global Production Efficiency Model (GLO-PEM) (Prince, 1991).

Técnicas e modelos para estimar a NPP de um ecossistema baseados em sensoriamento remoto visam simular e melhorar as estimativas de NPP em escalas locais a globais. Boa parte



deles, foram desenvolvidos para estudar a dinâmica da produtividade da vegetação e suas respostas às mudanças climáticas e atividades antrópicas (Bao et al., 2016). Entre os modelos mais conhecidos estão o modelo CASA (Potter et al., 1993), o modelo GLO-PEM (Prince, 1991), o modelo VPM (Xiao et al., 2004), o modelo Biome-BGC (Running e Hunt, 1993) e o modelo MOD17A3 do sensor MODIS (NASA, 2019a). Muitos destes modelos utilizam o conceito de LUE (Lees et al., 2018).

O conceito de LUE na estimativa de NPP foi estudado primeiramente por Monteith, (1972). O autor observou que, em uma ampla variedade de culturas e condições ambientais, a proporção de luz absorvida e assimilação de carbono durante a estação de crescimento é relativamente constante. Então, um modelo de eficiência de produção foi desenvolvido para estimar o crescimento das culturas a partir de Radiação Fotossinteticamente Ativa Absorvida pela vegetação (APAR) e a Eficiência Máxima de Uso da Luz (LUE<sub>máx</sub>) (Running et al., 2004). Estudos subsequentes melhoraram ainda mais o modelo, expressando a LUE<sub>máx</sub> em função de um ou mais fatores: clima, temperatura, água e estresse nutricional (Xiao et al., 2004).

### **3.3.1 Uso de sensoriamento remoto para estimativa da NPP**

O sensoriamento remoto apresenta vantagens em relação aos estudos de campo tradicionais, em particular, custo, escala e visualização de locais remotos (Lees et al., 2018), mostrando-se como um método efetivo para capturar mudanças temporais e espaciais na dinâmica da vegetação. Além disso, possui a vantagem de permitir que os pesquisadores possam estudar um ambiente enquanto minimizam a exposição aos riscos do trabalho de campo e maximizam a utilidade dos recursos disponíveis (Malenovský et al., 2015).

No entanto, a detecção remota possui algumas limitações, e uma delas, como destacou Lees et al. (2018), é que os sensores remotos medem apenas a energia incidente no sensor, cuja distribuição deve ser usada para inferir características de interesse. Segundo os autores, tais técnicas não podem medir fluxos de gás diretamente e dependem de modelos para estimar propriedades, como por exemplo a NPP.

A absorção de luz no espectro visível por pigmentos vegetais produz uma assinatura única de refletância espectral (Ustin et al., 2009). Devido as características típicas da folha, a assinatura espectral é influenciada pelo teor de pigmentos de folhas, estrutura celular e teor de água (Cárdenas et al., 2015). A região visível está associada à absorção de clorofila, enquanto as regiões de borda vermelha e NIR (Infravermelho Próximo) são principalmente modeladas

por mudanças estruturais nas folhas, e a região SWIR (Infravermelho de Ondas Curtas) é dominada por características de absorção de água (Qi et al., 2014).

Existem diversos satélites em órbita atualmente que foram projetados para usos de Observação da Terra. Muitos deles, disponíveis para os pesquisadores, possibilitam medições de fluxo de carbono na atmosfera. Entre as diversas possibilidades, destacam-se dois, os quais são seguramente os mais utilizados nas estimativas de NPP:

- O programa **Landsat** é um conjunto de satélites, tendo os satélites Landsat 7 e 8 em operação atualmente. Ambos os satélites, operados pelo Serviço Geológico dos Estados Unidos (USGS), cobrem a Terra a cada 16 dias, coletando dados em várias bandas nas faixas de onda do visível/NIR e TIR (Infravermelho Termal) em uma resolução de 30 m e 100m, respectivamente (USGS, 2019). Este conjunto de dados torna-se especialmente relevante para pesquisadores que estudam mudanças ao longo do tempo.

- Terra e Aqua são satélites administrados pela NASA, sendo que ambas plataformas possuem acopladas o sensor **MODIS** (*Moderate-Resolution Imaging Spectroradiometer*). Este sensor fornece alta sensibilidade radiométrica (12 bits), obtendo dados em 36 bandas espectrais (de 0,4 a 14,4  $\mu\text{m}$ ) e cobrindo a maior parte da superfície da Terra a cada 1-2 dias, com uma resolução espacial de 250 m – 1 km (NASA, 2019b). O MODIS desempenha papel vital no desenvolvimento de modelos de sistemas terrestres interativos, globais e validados, capazes de prever mudanças globais com precisão suficiente para ajudar os formuladores de políticas a tomar decisões acertadas sobre a proteção do meio ambiente (NASA, 2019b).

Por fim, as técnicas de sensoriamento remoto, orbital ou aerotransportadas, tornaram-se um meio eficaz de obter dados ecológicos devido às vantagens exclusivas para observações que abrangem e detalham grandes áreas, a geração de imagens em várias bandas espectrais e a sua repetitividade no tempo. No entanto, o período da observação e as dificuldades na identificação de espécies podem limitar a precisão destas técnicas ao estimar mudanças na NPP da vegetação (Fang; Wang e Shao, 2015).

Não obstante, em estudos sobre cultivos agrícolas, muitas vezes há a necessidade de fundir dados de mais de um sensor para caracterizar a variabilidade temporal e espacial de uma determinada cultura. Isto ocorre pelo fato de muitos sensores apresentarem baixa resolução temporal e, também, pela excessiva quantidade de nuvens em alguns períodos.

### 3.3.1.1 Estimativa de NPP potencial

A maioria dos modelos utilizados para estimar a NPP potencial são baseados em elementos climáticos. O primeiro modelo proposto e amplamente utilizado foi o modelo de Miami (Lieth, 1975), que é derivado das correlações entre os dados de NPP medidos e os dados correspondentes de temperatura do ar e precipitação pluvial (Zhou et al., 2015). O modelo de Thornthwaite foi estabelecido com base nos dados usados no modelo de Miami, mas modificado para incluir o modelo de evapotranspiração potencial de Thornthwaite (Lieth e Box, 1972 apud Lieth, 1975).

O modelo de Thornthwaite pode ser expresso por (Equação 1):

$$NPP = 3000[1 - e^{0,0009695(v-20)}] \quad (1)$$

Em que NPP é a NPP anual e  $v$  é evapotranspiração média anual (mm) obtida através das seguintes equações 2 e 3:

$$v = \frac{1,05r}{\sqrt{1 + (1+1,05r/L)^2}} \quad (2)$$

$$L = 3000 + 25t + 0,05t^3 \quad (3)$$

sendo  $L$  a média anual de evapotranspiração (mm),  $r$  a precipitação pluvial total anual e  $t$  a temperatura do ar média anual (°C).

Assim, o modelo de Thornthwaite requer apenas dados de precipitação pluvial e temperatura do ar como dados de entrada, que apesar de simples, tem sido um método utilizado para estimar a NPP potencial (Yin et al., 2020). Embora o modelo tenha uma formulação simples, muitas vezes os dados de entrada não estão disponíveis em determinadas regiões onde há uma carência de Estações Meteorológicas. Assim, uma das dificuldades geralmente encontradas nestas simulações, é a representação espacial detalhada das variáveis de entrada, podendo comprometer os resultados finais do modelo.

### 3.3.1.2 Estimativa da NPP real através da detecção remota

Uma maneira de estimar a NPP em escalas mais amplas são os modelos baseados na LUE, devido aos parâmetros prontamente acessíveis derivados de dados oriundos de satélite (Gang et al., 2018).

Conceitualmente, a quantidade de fotossíntese ou produção primária de um dossel é amplamente determinada pela quantidade de radiação fotossinteticamente ativa (PAR) absorvida pela vegetação (APAR). Isso é modificado ainda mais pela eficiência com a qual essa luz absorvida é convertida em carbono, eficiência no uso da luz (LUE) (Gitelson; Arkebauer e Suyker, 2018). Em termos gerais, a radiação absorvida está relacionada à estrutura da vegetação e aos pigmentos presentes nela, já o termo eficiência refere-se à fisiologia (Gitelson e Gamon, 2015).

A vantagem dos modelos LUE sobre os modelos mais detalhados baseados em processos ecossistêmicos é sua formulação relativamente simples e sua fácil adaptação para assimilar dados obtidos a partir de observações de satélites (Kross; Seaquist e Roulet, 2016). As principais limitações dos modelos LUE são que eles exigem um parâmetro LUE específico para cada tipo de vegetação, ou epsilon ( $\epsilon$ ), e estimativas precisas de absorção de energia solar pela vegetação. Este parâmetro foi estudado e estabelecido para alguns dos principais ecossistemas, incluindo florestas e pastagens (Kross; Seaquist e Roulet, 2016), mas pouca atenção foi dada às culturas agrícolas.

Portanto, é imprescindível que modificações e validações com diferentes parâmetros sejam feitas, afim de tornar estes modelos ainda mais eficazes na caracterização da distribuição de NPP em um dado ecossistema.

Entre os modelos que utilizam o conceito da LUE, está o modelo CASA, que é bastante utilizado nas estimativas de NPP usando imagens de satélite e já sofreu diversas modificações desde sua elaboração. Segundo Bao et al. (2016), o conceito fundamental de NPP para uma dada localização  $x$  e tempo  $t$  neste modelo é uma variante do modelo LUE originalmente proposto por Monteith (1972), dado pela equação 4, em que a NPP ( $\text{gC m}^{-2} \text{ano}^{-1}$ ) é o produto da radiação fotossinteticamente ativa ( $\text{MJ m}^{-2}$ ) (PAR) pela porção desta absorvida pela vegetação verde (FPAR) e pela LUE ou  $\epsilon$  ( $\text{g C MJ}^{-1}$ ):

$$NPP_{(x,t)} = PAR_{(x,t)} \times FPAR_{(x,t)} \times \epsilon_{(x,t)} \quad (4)$$

Foi demonstrado em estudos anteriores que a APAR ( $PAR \times FPAR$ ) é relativamente fácil de estimar a partir de dados de sensoriamento remoto (Bao et al., 2016). Pois, a PAR pode ser medida como a quantidade de radiação solar incidente nos comprimentos de onda em que as plantas são capazes de absorver e usar para fotossíntese (0,4 a 0,7  $\mu\text{m}$ ). Em geral utiliza-se

um fator de 0,5, aproximadamente metade da radiação solar incidente situa-se na faixa de comprimento de ondas PAR (Pei et al., 2013).

Em muitos modelos LUE, a FPAR é modelada como uma função de um índice de vegetação, e assume-se muitas vezes ter uma relação linear com o Índice de Vegetação da Diferença Normalizada (NDVI) (Huemmrich et al., 2010). FPAR também está relacionada ao índice de área foliar (LAI), pois isso determina parcialmente quanta energia é absorvida pelo dossel (Yuan et al., 2007).

Sims et al. (2006) determinaram a FPAR utilizando o NDVI e obtiveram alto grau de correlação ( $r^2 = 0,95$ ), utilizando a equação 5:

$$FPAR = 1,24 \times NDVI - 0,168 \quad (5)$$

sendo o NDVI obtido através da normalização das reflectâncias nas bandas do NIR e vermelho (*Red*), conforme equação 6 proposta por Rouse et al. (1973):

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (6)$$

Já o  $\varepsilon$  expressa a quantidade de C fixada (por exemplo, GPP) ou convertida em biomassa (por exemplo, NPP) por unidade de PAR absorvido (APAR) (Kross; Seaquist e Roulet, 2016). Frequentemente este parâmetro é calculado a partir de uma constante de  $\varepsilon_{m\acute{a}x}$  para um bioma específico (por exemplo, pastagem, floresta, área cultivada) ajustado para fatores limitantes (equação 7), como temperatura e disponibilidade de umidade (Garbulsky et al., 2011).

$$\varepsilon(x, t) = \varepsilon_{m\acute{a}x} \times T_{\varepsilon_1}(x, t) \times T_{\varepsilon_2}(x, t) \times W_{\varepsilon}(x, t) \quad (7)$$

Genericamente, os dois  $T_{\varepsilon}$ , que denotam os coeficientes de estresse térmico, são calculados com relativa facilidade usando a temperatura média mensal e a temperatura ideal para o crescimento das plantas, que é a temperatura durante o mês de máximo NDVI (Bao et al., 2016). Já o  $W_{\varepsilon}$ , coeficiente de estresse hídrico, pode ser calculado pela equação 8:

$$W_{\varepsilon}(x, t) = 0.5 + 0.5 \times \frac{EET(x,t)}{PET(x,t)} \quad (8)$$

em que EET e PET representam a evapotranspiração real e potencial (mm), respectivamente.

No entanto, não existem muitas informações sobre o uso de sensoriamento remoto nas estimativas de  $W_{\varepsilon}$ , ao contrário das estimativas de APAR e  $T_{\varepsilon}$  que incluem dados de satélites (Bao et al, 2016). Assim, este é um parâmetro que ainda pode ser estudado para melhorar a precisão das estimativas de NPP e fornecer uma saída contínua com a mesma resolução temporal e espacial que os dados de APAR e  $T_{\varepsilon}$ .

Em seu estudo, Bao et al. (2016) propuseram a utilização do Índice de Água da Superfície Terrestre (LSWI) e obtiveram resultados similares aos dados medidos a campo, com uma cobertura espacial contínua e alto grau de variabilidade espacial no padrão das estimativas de NPP utilizando o modelo CASA. Porém, os autores ressaltam que o uso do LSWI como indicador de conteúdo de água foliar e umidade do solo pode servir como uma amostra representativa de regiões com um clima árido e semiárido, estando, portanto, sujeito a incertezas em regiões de climas úmidos.

Uma alternativa a isto, seria o uso do índice TVDI que também pertence à categoria dos índices que estimam a umidade da superfície e utiliza somente informações de satélites. Este índice foi desenvolvido por Sandholt; Rasmussen e Andersen (2002) e está baseado em uma parametrização empírica da relação entre Temperatura Superficial ( $T_s$ ) e o índice de vegetação NDVI.

Esta relação entre  $T_s$  e NDVI produz um espaço de pontos de dispersão, em que o índice é baseado, que podem ser moldados como um triângulo evaporativo ou trapezoide, dependendo da condição climática e da cobertura vegetal (Price, 1990). Como destacaram Schirmbeck; Fontana e Schirmbeck, (2018), o modelo TVDI permite normalizar o estado de água da vegetação entre os limites úmido e seco do triângulo evaporativo, com valores entre 0 (limite úmido) e 1 (limite seco) (Figura 2), e pode ser definido através da Equação 9:

$$TVDI = \frac{T_s - T_{smín}}{a + b * NDVI - T_{smín}} \quad (9)$$

Onde  $T_{smín}$  é a temperatura de superfície mínima no triângulo, que define a borda úmida,  $T_s$  é a temperatura de superfície observada num dado pixel e  $a$  e  $b$  são os parâmetros que definem a borda seca, sendo modelados como um ajuste linear aos dados (Figura 2).

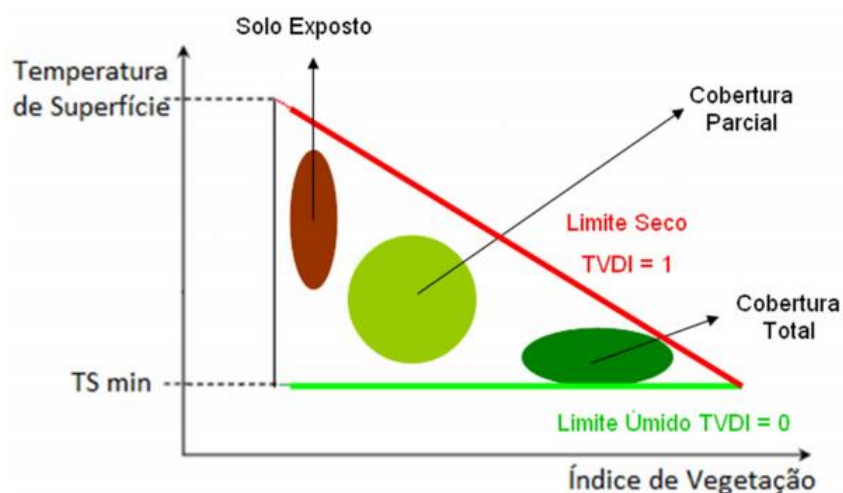


Figura 2 - Representação esquemática do triângulo evaporativo dado pela relação entre  $T_s$  e NDVI

Fonte: (Schirmbeck, 2016)

Assim, o TDVI tem potencial de ser usado como um indicador da umidade da superfície, já que as informações contidas nos comprimentos de onda do termal e do V/NIR (através do NDVI) provaram ser adequadas e complementares para monitorar o estado da vegetação e o estresse hídrico (Sandholt; Rasmussen e Andersen, 2002), o que precisa ser testado.

### 3.3.1.3 Espacialização do modelo

Muitos dos modelos de estimativa de NPP utilizam dados meteorológicos de entrada, que nem sempre estão disponíveis para algumas regiões de estudo. A disponibilidade de dados medidos ainda é limitada, já que uma das principais dificuldades encontradas para estudos climáticos, sobretudo em um país de proporções continentais como o Brasil, está na existência de um conjunto de dados observacionais, que apresente significativa qualidade e disponibilidade (Sanches, 2015).

Diante desses problemas, alguns centros de previsão do tempo e clima disponibilizam produtos de reanálise, que são séries de dados meteorológicos obtidos através da assimilação e reanálise de dados observados em superfície (estações), aviões, navios, imagens de satélite, imagens de radar e radiossondagens em todo o planeta (Kalnay et al., 1996). Estes dados apresentam como vantagens a repetitividade e coleta sistemática, frequência de amostragem superior ao da rede convencional/automática de estações meteorológicas, além de fornecer informações sobre a distribuição espacial do dado (Paz e Collinschonn, 2011).

Uma reanálise do clima, produzida pela combinação de modelos com observações, dá uma descrição numérica do clima, sendo as estimativas produzidas para todos os locais da Terra e abrangendo um longo período de tempo que pode se estender por décadas ou mais. Ele contém estimativas de elementos atmosféricos, como temperatura do ar, pressão e vento em diferentes altitudes e parâmetros de superfície, como chuva, umidade do solo e temperatura da superfície do mar. A reanálise oferece um bom potencial para extrair o máximo de informações sobre o clima recente a partir do registro instrumental total, usando modelos para relacionar e combinar informações de outras observações díspares (Dee et al., 2014).

Uma das mais recentes reanálises, a ERA-Interim é uma reanálise atmosférica global que compreende o período desde 1979 e foi prorrogada até agosto de 2019. Produzida pelo Centro Europeu de Previsão de Tempo Médio (ECMWF), os produtos de dados em grade do ERA-Interim incluem uma grande variedade de elementos climáticos da superfície atmosférica, do mar e da superfície terrestre, incluindo muitos que não são diretamente observados (Dee et al., 2011).

Embora os dados de reanálise possuam diversas vantagens em relação ao dado amostrado, ainda são necessários ajustes destes com os dados medidos para uma maior precisão das informações a serem trabalhadas.

#### 4. REFERÊNCIAS

ADAMS, B.; WHITE, A.; LENTON, T. M. An analysis of some diverse approaches to modelling terrestrial net primary productivity. **Ecological Modelling**, Amsterdam, v. 177, n. 3/4, p. 353-391, 2004.

BAO, G. *et al.* Modeling net primary productivity of terrestrial ecosystems in the semi-arid climate of the Mongolian Plateau using LSWI-based CASA ecosystem model. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 46, p. 84-93, 2016.

BEER, C. *et al.* Terrestrial gross carbon dioxide uptake: global distribution and covariation with climate. **Science**, Washington, DC, v. 329, n. 5993, p. 834-838, 2010.

CÁRDENAS, J. L. S. *et al.* Geospatial technologies to support coniferous forests research and conservation efforts in Mexico. *In*: WEBER, R. P. (ed.). **Old-growth forests and coniferous forests: ecology, habitat and conservation**. New York: Nova Science, 2015. cap. 5, p. 67-123.

CHAPLIN-KRAMER, R. *et al.* Spatial patterns of agricultural expansion determine impacts on biodiversity and carbon storage. **Proceedings of the National Academy of Sciences**, Washington, DC, v. 112, n. 24, p. 7402-7407, 2015.



DEE, D. P. M. *et al.* Toward a consistent reanalysis of the climate system. **Bulletin of the American Meteorological Society**, Boston, v. 95, p. 1235-1248, 2014.

DEE, D. P. *et al.* The ERA-Interim reanalysis: configuration and performance of the data assimilation system. **Quarterly Journal of the Royal Meteorological Society**, London, v. 137, p. 553-597, 2011.

ERB, K.-H. *et al.* A comprehensive global 5 min resolution land-use data set for the year 2000 consistent with national census data. **Journal of Land Use Science**, London, v. 2, p. 191–224, 2007.

FAO - FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. [Base de dados FAOSTAT: statistics database]. Rome, 2014. Disponível em: <http://www.fao.org/faostat/>. Acesso em: 11 dez. 2019.

FANG, O.; WANG, Y.; SHAO, X. The effect of climate on the net primary productivity (NPP) of *Pinus koraiensis* in the Changbai Mountains over the past 50 years. **Trees**, Berlin, v. 30, n. 1, p. 281-294, 2015.

FOLEY, J. A. *et al.* Global consequences of land use. **Science**, Washington, DC, v. 309, n. 5734, p. 570-574, 2005.

GAO, Y. *et al.* Vegetation net primary productivity and its response to climate change during 2001–2008 in the Tibetan Plateau. **The Science of the Total Environment**, Amsterdam, v. 444, p. 356-362, 2013.

GANG, C. *et al.* Comparative assessment of grassland NPP dynamics in response to climate change in China, North America, Europe and Australia from 1981 to 2010. **Journal of Agronomy and Crop Science**, Berlin, v. 201, n. 1, p. 57-68, 2015.

GANG, C. *et al.* The impacts of land conversion and management measures on the grassland net primary productivity over the Loess Plateau, Northern China. **The Science of the Total Environment**, Amsterdam, v. 645, p. 827-836, 2018.

GARBULSKY, M. F. *et al.* The photochemical reflectance index (PRI) and the remote sensing of leaf, canopy and ecosystem radiation use efficiencies: a review and meta-analysis. **Remote Sensing of Environment**, New York, v. 115, n. 2, p. 281-297, 2011.

GIBBS, H. K.; SALMON, J. M. Mapping the world's degraded lands. **Applied Geography**, Sevenoaks, v. 57, p. 12-21, 2015.

GITELSON, A. A. *et al.* Relationships between gross primary production, green LAI, and canopy chlorophyll content in maize: implications for remote sensing of primary production. **Remote Sensing Environmental**, New York, v. 144, p. 65–72, 2014.

GITELSON, A. A.; GAMON, J. A. The need for a common basis for defining light-use efficiency: implications for productivity estimation: implications for productivity estimation. **Remote Sensing of Environment**, New York, v. 156, p. 196-201, 2015.

- GITELSON, A. A.; ARKEBAUER, T. J.; SUYKER, A. E. Convergence of daily light use efficiency in irrigated and rainfed C3 and C4 crops. **Remote Sensing of Environment**, New York, v. 217, p. 30-37, 2018.
- HABERL, H. Human appropriation of net primary production as an environmental indicator: implications for sustainable development. **Ambio**, Stockholm, v. 26, n. 3, p. 143-146, 1997.
- HABERL, H. *et al.* Human appropriation of net primary production and species diversity in agricultural landscapes. **Agriculture, Ecosystems & Environment**, Amsterdam, v. 102, n. 2, p. 213-218, 2004.
- HABERL, H. *et al.* Quantifying and mapping the human appropriation of net primary production in earth's terrestrial ecosystems. **Proceedings of the National Academy of Sciences**, Washington, DC, v. 104, n. 31, p. 12942-12947, 2007.
- HABERL, H.; ERB, K. H.; KRAUSMANN, F. Human appropriation of net primary production: patterns, trends, and planetary boundaries. **Annual Review of Environment and Resources**, Palo Alto, v. 39, p. 363-391, 2014.
- HUEMMRICH, K. F. *et al.* Remote sensing of tundra gross ecosystem productivity and light use efficiency under varying temperature and moisture conditions. **Remote Sensing of Environment**, New York, v. 114, n. 3, p. 481-489, 2010.
- KALNAY, E. *et al.* The ncep/ncar 40-year reanalysis project. **Bulletin of the American Meteorological Society**, Boston, v. 77, p. 37-471, 1996.
- KRAUSMANN, F. *et al.* Global human appropriation of net primary production doubled in the 20th century. **Proceedings of The National Academy of Sciences**, Washington, DC, v. 110, n. 25, p. 10324-10329, jun. 2013.
- KROSS, A.; SEAQUIST, J. W.; ROULET, N. T. Light use efficiency of peatlands: variability and suitability for modeling ecosystem production. **Remote Sensing of Environment**, New York, v. 183, p. 239-249, 2016.
- LEES, K. J. *et al.* Potential for using remote sensing to estimate carbon fluxes across northern peatlands – a review. **The Science of the Total Environment**, Amsterdam, v. 615, p. 857-874, 2018.
- LI, H.; CHEN, J.; TONG, C. Comparison of NPP estimation by remote sensing-based parametric model and ecological processed model over forest at regional scale. *In*: 2014 THIRD INTERNATIONAL WORKSHOP ON EARTH OBSERVATION AND REMOTE SENSING APPLICATIONS (EORSA), 2014, Changsha, China. [**Proceedings ...**]. Piscataway: IEEE, 2014.
- LI, Z. *et al.* Potential impacts of climate change on vegetation dynamics in Central Asia. **Journal of Geophysical Research: Atmospheres**, Hoboken, v. 120, n. 24, p. 12345-12356, 2015.

LI, L. *et al.* Current challenges in distinguishing climatic and anthropogenic contributions to alpine grassland variation on the Tibetan Plateau. **Ecology and Evolution**, Oxford, v. 8, n. 11, p. 5949-5963, 2018.

LIETH, H.; BOX, E. Evapotranspiration and primary productivity. **Publications in Climatology**, New Jersey, v. 25, p. 37–46, 1972.

LIETH, H. Modeling the primary productivity of the world. *In*: LIETH, H.; WHITTAKER, R. H. **Primary productivity of the biosphere**. New York: Springer, 1975. cap. 12, p. 237-263.

LOREL, C. *et al.* Linking the human appropriation of net primary productivity-based indicators, input cost and high nature value to the dimensions of land-use intensity across French agricultural landscapes. **Agriculture, Ecosystems & Environment**, Amsterdam, v. 283, p.106565-106565, 2019.

MALENOVSKÝ, Z. *et al.* Antarctic moss stress assessment based on chlorophyll content and leaf density retrieved from imaging spectroscopy data. **New Phytologist**, Oxford, v. 208, n. 2, p. 608-624, 2015.

MERONI, M. *et al.* A phenology-based method to derive biomass production anomalies for food security monitoring in the Horn of Africa. **International Journal of Remote Sensing**, London, v. 35, p. 2472–2492, 2014.

MONTEITH, J. Solar radiation and productivity in tropical ecosystems. **Journal of Applied Ecology**, Oxford, v. 9, n. 3, p. 747–766, 1972.

MULLA, D. J. Twenty-five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. **Biosystems Engineering**, London, v. 114, p. 358–371, 2013.

NASA. **MODIS Gross Primary Production (GPP)/Net Primary Production (NPP)**. Washington, DC, [2019a]. Disponível em: <https://modis.gsfc.nasa.gov/data/dataproduct/mod17.php>. Acesso em: 15 mar. 2019.

NASA. **MODIS: Moderate Resolution Imaging Spectroradiometer**. Washington, DC, [2019b]. Disponível em: <https://modis.gsfc.nasa.gov/>. Acesso em: 15 out. 2019.

PACHAVO, G.; MURWIRA, A. Remote sensing net primary productivity (NPP) estimation with the aid of GIS modelled shortwave radiation (SWR) in a Southern African Savanna. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 30, p. 217-226, ago. 2014.

PARRY, M. L. *et al.* Effects of climate change on global food production under SRES emissions and socio-economic scenarios. **Global Environmental Change**, Oxford, v. 14, p. 53–67, 2004.

PAZ, A. R.; COLLINSCHONN, W. Avaliação de estimativas de campos de precipitação para modelagem hidrológica distribuída. **Revista Brasileira de Meteorologia**, Rio de Janeiro, v. 26, n. 1, p. 109- 120, 2011.

PEI, F. *et al.* Assessing the impacts of droughts on net primary productivity in China. **Journal of Environmental Management**, London, v. 114, p. 362-371, 2013.

PIANA, M.; CIVEIRA, G. Estimating net primary productivity and carbon inputs by soybean crops in Argentina. **Communications in Soil Science and Plant Analysis**, New York, v. 48, n. 10, p. 1105-1113, 2017.

POTTER, C. S. *et al.* Terrestrial ecosystem production: a process model based on global satellite and surface data. **Global Biogeochemical Cycles**, Washington, DC, v. 7, n. 4, p. 811-841, 1993.

POTTER, C.; KLOOSTER, S.; GENOVESE, V. Net primary production of terrestrial ecosystems from 2000 to 2009. **Climatic Change**, Dordrecht, v. 115, n. 2, p. 365-378, 2012.

PRICE, J. C. Using spatial context in satellite data to infer regional scale evapotranspiration. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 28, n. 5, p. 940-948, 1990.

PRINCE, S. D. A model of regional primary production for use with coarse resolution satellite data. **International Journal of Remote Sensing**, London, v. 12, n. 6, p. 1313-1330, 1991.

QI, Y. *et al.* Spectroscopic analysis of seasonal changes in live fuel moisture content and leaf dry mass. **Remote Sensing of Environment**, New York, v. 150, p. 198-206, 2014.

ROSA, R.; SANO, E. E. Determinação da produtividade primária líquida (NPP) de pastagens na bacia do rio Paranaíba, usando imagens MODIS. **GeoFocus**, Madrid, n. 13-1, p. 367-395, 2013.

ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. *In: EARTH RESOURCES TECHNOLOGY SATELLITE SYMPOSIUM*, 3., 1973, Washington. **Proceedings** [...]. Washington, DC: NASA, 1973. p. 309-317.

RUNNING, S. W.; HUNT, E. R. Generalization of a forest ecosystem process model for other biomes, BIOME-BGC, and an application for global-scale models. *In: EHLERINGER, James E.; FIELD, Christopher B. (ed.). Scaling physiological processes: leaf to globe: a volume in physiological ecology*. San Diego: Academic Press, 1993. p. 141-158.

RUNNING, S. W. *et al.* A continuous satellite-derived measure of global terrestrial primary production. **Bioscience**, Washington, DC, v. 54, n. 6, p. 547-560, 2004.

SANCHES, F.O. O Geógrafo-Climatologista e as mudanças climáticas: uma proposta metodológica. **Revista Equador**, Teresina, v. 4, p. 101-118, 2015.

SANDHOLT, I.; RASMUSSEN, K.; ANDERSEN, J. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. **Remote Sensing of Environment**, New York, v. 79, n. 2/3, p. 213-224, 2002.

SCHIRMBECK, L. W. **Padrão espaço temporal do TVDI em área de cultivo de soja.** 2016. Dissertação (Mestrado) - Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

SCHIRMBECK, L. W.; FONTANA, D. C.; SCHIRMBECK, J. Two approaches to calculate TVDI in humid subtropical climate of southern Brazil. **Scientia Agricola**, Piracicaba, v. 75, n. 2, p. 111-120, 2018.

SILVA, F. B. **Modelagem da produtividade primária bruta na Amazônia.** 2013. Tese (Doutorado) - Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, 2013.

SOUZA, P.; MALHI, Y. Land use change in India (1700-2000) as examined through the lens of human appropriation of net primary productivity. **Journal of Industrial Ecology**, Cambridge, v. 22, n. 5, p. 1202-1212, ago. 2017.

SPERA, S. A. *et al.* Land-use change affects water recycling in Brazil's last agricultural frontier. **Global Change Biology**, Oxford, v. 22, p. 3405-3413, 2016.

TAELMAN, S. E. *et al.* Accounting for land use in life cycle assessment: the value of NPP as a proxy indicator to assess land use impacts on ecosystems. **The Science of the Total Environment**, Amsterdam, v. 550, p. 143-156, 2016.

UGBAJE, S. U. *et al.* Assessing the spatio-temporal variability of vegetation productivity in Africa: quantifying the relative roles of climate variability and human activities. **International Journal of Digital Earth**, Abingdon, v. 10, n. 9, p. 879-900, 2016.

USGS – UNITED STATES GEOLOGICAL SURVEY. **Landsat satellite missions.** Reston, [2019]. Disponível em: [https://www.usgs.gov/land-resources/nli/landsat/landsat-satellite-missions?qt-science\\_support\\_page\\_related\\_con=2#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/land-resources/nli/landsat/landsat-satellite-missions?qt-science_support_page_related_con=2#qt-science_support_page_related_con). Acesso em: 15 mar. 2019.

USTIN, Susan L. *et al.* Retrieval of foliar information about plant pigment systems from high resolution spectroscopy. **Remote Sensing of Environment**, New York, v. 113, p. 67-77, 2009.

VITOUSEK, Peter M. *et al.* Human appropriation of the products of photosynthesis. **Bioscience**, Washington, DC, v. 36, n. 6, p. 368-373, jun. 1986.

WANG, H. *et al.* Monitoring the effects of land use and cover changes on net primary production: a case study in China's Yongding River basin. **Forest Ecology and Management**, Amsterdam, v. 258, n. 12, p. 2654-2665, 2009.

WESSELS, K. J.; PRINCE, S. D.; RESHEF, I. Mapping land degradation by comparison of vegetation production to spatially derived estimates of potential production. **Journal of Arid Environments**, London, v. 72, n. 10, p. 1940-1949, 2008.

WEST, T. O. *et al.* Cropland carbon fluxes in the United States: increasing geospatial resolution of inventory-based carbon accounting. **Ecological Applications**, Tempe, v. 20, n. 4, p. 1074-1086, 2010.

WHITTAKER, R. H.; LIKENS, G. E. Primary production: the biosphere and man. **Human Ecology**, Ithaca, v. 1, p. 357-369, 1973.

WU, J. *et al.* Identifying the relative contributions of climate and grazing to both direction and magnitude of alpine grassland productivity dynamic from 1993 to 2011 on the Northern Tibetan Plateau. *In: EGU GENERAL ASSEMBLY CONFERENCE*, 19., 2017, Vienna. **Proceedings** [...]. Vienna: EGU, 2017. p. 136.

XIAO, X. Modeling gross primary production of temperate deciduous broadleaf forest using satellite images and climate data. **Remote Sensing of Environment**, New York, v. 91, n. 2, p. 256-270, 2004.

YUAN, W. *et al.* Deriving a light use efficiency model from eddy covariance flux data for predicting daily gross primary production across biomes. **Agricultural and Forest Meteorology**, Amsterdam, v. 143, n. 3/4, p. 189-207, 2007.

ZHOU, W. *et al.* Quantitative assessment of the individual contribution of climate and human factors to desertification in northwest China using net primary productivity as an indicator. **Ecological Indicators**, New York, v. 48, p. 560-569, 2015.

ZHOU, W. *et al.* Grassland degradation remote sensing monitoring and driving factors quantitative assessment in China from 1982 to 2010. **Ecological Indicators**, New York, v. 83, p. 303-313, 2017.

ZHU, Q. *et al.* Remotely sensed estimation of Net Primary Productivity (NPP) and Its spatial and temporal variations in the Greater Khingan Mountain Region, China. **Sustainability**, Basel, v. 9, n. 7, p. 1213-1229, 2017.

## **5. DESENVOLVIMENTO**

**5.1 Artigo 1 - Modelagem da Produtividade Primária Líquida (NPP) utilizando dados meteorológicos de reanálise ERA-Interim: avaliação dos efeitos das atividades humanas sobre a produtividade da soja.**

## **MODELAGEM DA PRODUTIVIDADE PRIMÁRIA LÍQUIDA (NPP) UTILIZANDO DADOS METEOROLÓGICOS DE REANÁLISE ERA-INTERIM: AVALIAÇÃO DOS EFEITOS DAS ATIVIDADES HUMANAS SOBRE A PRODUTIVIDADE DA SOJA**

**RESUMO:** A Produtividade Primária Líquida (NPP) pode ser utilizada como um indicador para quantificar o papel relativo do clima e das atividades humanas na dinâmica da vegetação. Muitos modelos de estimativa de NPP foram desenvolvidos para tornar este parâmetro mais preciso, mas muitos dos dados requeridos, ainda são limitados. Diante disso, este trabalho teve como objetivo validar e avaliar o desempenho do modelo Carnegie–Ames–Stanford Approach (CASA) em estimar a NPP de cultivos de soja, baseado em dados meteorológicos de reanálise ERA-Interim, e analisar as mudanças causadas pela variabilidade climática e pelas atividades humanas. Para isso, foram obtidos dados de NPP medida a campo em cultivo de soja em Carazinho, no Rio Grande do Sul. Foram feitas estimativas de NPP potencial, dos últimos 10 anos, e estimativas de NPP real, utilizando o modelo CASA, referente ao ano de estudos a campo, incorporando dados do ERA-Interim. Posteriormente, as estimativas de NPP potencial e real foram comparadas para avaliar as mudanças causadas pelo uso da terra em função das atividades agrícolas, através da Apropriação Humana da NPP (HANPP). Ao avaliar as estimativas de NPP potencial, foi observado que não houve diferença significativa entre as fontes de dados utilizadas, evidenciando a eficiência dos dados meteorológicos de reanálise do ERA-Interim. O modelo CASA de estimativa de NPP real, utilizando dados reanálise, apresentou dados consistentes em relação aos dados medidos a campo, demonstrando o uso potencial da reanálise para estimativas mais precisas de NPP. O estudo da HANPP mostrou que a apropriação humana, quando realizado apenas um cultivo anual, pode chegar até 28% do potencial de NPP. Assim, ainda há espaço de investigação de técnicas e estratégias de gerenciamento para melhorar a produtividade dos cultivos, para que se concilie a demanda de terras novas para a produção agrícola, menos impactos sejam provocados e mais produtivos sejam os ambientes já existentes.

**PALAVRAS-CHAVE:** NPP, APAR, NDVI, Soja

### **1. INTRODUÇÃO**

As projeções mais recentes mostram que a produção de alimentos precisa aumentar 70% até 2050 (Sentelhas et al., 2015), para atender a população humana em crescimento. Isto representa um desafio à segurança alimentar e energética global, uma vez que a área agrícola deve aumentar em cerca de 42 milhões de hectares até 2027, se as tendências atuais forem mantidas (Santos e Naval, 2020). Portanto, monitorar e prever a produção agrícola são etapas críticas para lidar com os problemas de segurança alimentar em escala global (Huang et al., 2019).

Entre as regiões em desenvolvimento, a América Latina é a que possui maior potencial de desenvolvimento agrícola (Santos e Naval, 2020). Nas últimas duas décadas, a região apresentou um crescimento substancial e o Brasil foi um dos líderes, com média de 4,1% entre



1991 e 2015 (FAO, 2019). No país, um dos indicadores que ilustra a trajetória recente da agricultura é a produção de grãos. Entre 1975 e 2017, ela cresceu mais de seis vezes, passando de 38 milhões de toneladas para 236 milhões, enquanto a área cultivada apenas dobrou de tamanho (EMBRAPA, 2018). A soja foi um dos cultivos que mais expandiu e intensificou o rendimento de grãos nas últimas décadas, chegando a dobrar sua produção (EMBRAPA, 2018) e tornando o Brasil um dos maiores exportadores do produto do mundo (Santos e Naval, 2020).

Uma das estratégias mais comumente proposta para controlar a expansão dos sistemas de produção, poupando ecossistemas naturais, é a intensificação agrícola, já que produtividades mais altas resultam em menor necessidade de áreas de produção (Lambin e Meyfroidt, 2011). Além disso, o aumento da área agrícola é limitado em muitas regiões, onde o incremento da produtividade é a única maneira de aumentar a produção de alimentos (Battisti; Bender e Sentelhas, 2019). No entanto, os custos e benefícios da intensificação agrícola variam muito, estando sujeitos, geralmente, às condições climáticas e práticas agronômicas (Foley et al., 2011). A produção agrícola é altamente dependente do clima, e eventos climáticos extremos e adversos podem ter impacto dramático sobre a mesma (Hearkness et al., 2020) e sobre o ambiente no seu entorno. Isso sugere que as decisões sobre formas e locais de intensificação devem possuir um equilíbrio entre a busca do potencial de produção agrícola e a manutenção da biodiversidade e serviços ecossistêmicos (DeFries; Foley e Asner, 2004; Kennedy, 2016).

Nesse sentido, o uso de estimativas de Produtividade Primária Líquida (NPP) do ecossistema se torna uma ferramenta importante, afim de identificar a magnitude e as causas das lacunas de produção (Sentelhas et al., 2015). A NPP refere-se à quantidade de carbono fixada através da fotossíntese por uma determinada comunidade vegetal por unidade de tempo e espaço (Zhu et al., 2017; Liang et al., 2015; Potter; Klooster e Genovese, 2012). Este parâmetro é um indicador importante do crescimento da vegetação e da saúde do ecossistema (Liang et al., 2015; Running et al., 2004), funcionando como um indicador dinâmico da situação de degradação do solo (Zhou et al., 2017), possibilitando a busca de soluções, mediante a definição de zonas de manejo do agroecossistema (Breunig, 2020).

No estudo da produtividade de um ecossistema, dois parâmetros principais são importantes. A NPP potencial (NPP<sub>pot</sub>), que é controlada apenas por determinantes climáticos e representa as condições potenciais de crescimento da vegetação na ausência de interferência humana (Krauschman et al., 2013; Souza e Malhi, 2017; Lorel et al., 2019); E a NPP real, que representa a situação real da produtividade da vegetação, a qual pode ser controlada pelo clima e também pelas atividades humanas (Li et al., 2018). A influência antropogênica mais óbvia é

aquela causada pelas mudanças no uso da terra e no tipo de cobertura criada pelas atividades humanas, que alteram o ambiente natural (Running et al., 2004). Assim, a NPP pode ajudar a separar e quantificar o papel relativo da variação climática e das atividades humanas na dinâmica da vegetação (Ugbaje et al., 2016).

Um dos indicadores derivados da NPP e utilizados para avaliar o impacto e a intensidade do uso da terra é a Apropriação Humana da NPP (HANPP), que foi calculado pela primeira vez por Whittaker e Likens, (1973) e, mais tarde, aprofundado por Haberl et al. (2007). A HANPP refere-se à proporção da produção anual de biomassa vegetal natural, que é apropriada pelas atividades humanas, principalmente, devido a mudanças das funções de uso da terra, mediante a colheita da biomassa (Taelman et al., 2016). Diversos estudos indicam que a HANPP da vegetação natural pode ser determinada comparando a  $NPP_{pot}$  com a  $NPP_{real}$ , assumindo que esta diferença representa os impactos de fatores humanos na vegetação. (Li et al., 2018; Zhou et al., 2017). Nesse sentido, encontrar e melhorar métodos de estimativas de NPP pode ajudar a quantificar os efeitos individuais de fatores humanos e de variações climáticas nas mudanças de  $NPP_{pot}$  e  $NPP_{real}$  dos cultivos agrícolas e, assim, identificar onde e como estes fatores afetam a dinâmica dos cultivos agrícolas no Brasil.

A estimativa da HANPP, em unidades de carbono (C), é a soma de duas subcategorias: HANPP<sub>luc</sub> e HANPP<sub>harv</sub> (Krauschman et al., 2013). A HANPP<sub>harv</sub> representa a quantidade de carbono que é colhida pelos seres humanos em forma de biomassa (Lorel et al., 2019; Haberl; Erb e Krausmann, 2014), incluindo culturas agrícolas, madeira, resíduos de colheitas, forragem consumida pelos animais e biomassa perdida pelos incêndios induzidos por humanos (Krauschman et al., 2013). Já a HANPP<sub>luc</sub> é o resultado de mudanças no uso da terra induzidas pelo homem, como a conversão de florestas em terras agrícolas ou infraestrutura (Krauschman et al., 2013; Haberl; Erb e Krausmann, 2014). Todos estes parâmetros foram bem representados e estudados por Haberl; Erb e Krausmann, (2014).

Um dos grandes problemas enfrentados nas estimativas de NPP é a disponibilidade de dados meteorológicos medidos, que ainda é limitada no Brasil, tanto na escala temporal, quanto em densidade espacial (Battisti; Bender e Sentelhas, 2019). Geralmente, quando isso acontece em região com escassez de observações, os dados meteorológicos são interpolados e, em seguida, usados para conduzir o modelo, mesmo que estes processos contenham incertezas (Chen et al., 2012). Outra estratégia é a utilização de dados meteorológicos oriundos de produtos de reanálise, em complementação aos dados já existentes ou utilizados isoladamente como entrada nos modelos. Estes dados apresentam como vantagens a repetibilidade e coleta

sistemática, frequência de amostragem superior ao da rede convencional/automática de estações meteorológicas, além de fornecer informações sobre sua distribuição espacial (Paz e Collinschonn, 2011).

Entre as mais recentes reanálises atmosféricas que ofertam dados meteorológicos com cobertura global está o ERA - Interim, produzida pelo Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF). O ERA - Interim atual, abrange o período de janeiro de 1979 até agosto de 2019. Os produtos de dados disponibilizados incluem uma grande variedade de parâmetros de superfície e os parâmetros do ar superior (Dee et al., 2011), conforme descrição detalhada disponibilizada por Berrisford et al. (2009). Embora estes dados sejam fornecidos em escala ampla e precisa, ainda há a necessidade de validações locais, visto que estes podem apresentar discrepâncias quando comparados com dados observacionais.

Apesar da importância dos estudos *in loco* da NPP, o sensoriamento remoto tem se mostrado um método efetivo para capturar mudanças temporais e espaciais na dinâmica da vegetação, com vantagens em relação aos estudos de campo, em particular, menor custo, maior escala e visualização de locais remotos (Lees et al., 2018). No entanto, a detecção remota possui algumas limitações, e uma delas, como destacou Lees et al. (2018), é que os sensores remotos medem apenas a energia incidente no sensor, cuja distribuição deve ser usada para inferir características de interesse. Segundo o autor, tais técnicas não podem medir fluxos de gás diretamente e dependem de modelos para estimar propriedades, como por exemplo a NPP.

Diversos métodos e modelos de estimativas NPP de um ecossistema foram desenvolvidos, visando estudar a dinâmica da produtividade da vegetação natural e suas respostas às mudanças climáticas e atividades antrópicas (Bao et al., 2016). Estes métodos apresentam potencialidades e limitações associadas aos seus contextos de elaboração, escala temporal e espacial de aplicação (Fang; Wang e Shao, 2015), disponibilidade de dados de entrada no modelo, entre outras características (Bao et al., 2016), o que dificulta uma abordagem dinâmica para compreender a complexidade envolvida na informação de NPP. Por isso, nas últimas décadas tem sido amplamente relatado o desenvolvimento e o uso de modelos de simulação de NPP, que conseguem integrar grande parte dos fatores de variabilidade desta variável (Gang et al., 2018). Entre eles, destaca-se o modelo CASA (*Carnegie–Ames–Stanford Approach*) desenvolvido por Potter et al. (1993) e modificado em diversos estudos para incorporar dados de Sensoriamento Remoto, obtidos por diversos satélite orbitais (Bao et al., 2016; Pei et al., 2013).

Neste contexto, este trabalho teve como objetivos principais (I) avaliar diferentes métodos de estimativa de variáveis de entrada no modelo e fontes de dados para obtenção da NPPpot da vegetação natural, (II) verificar as mudanças da NPPpot em função das variações das condições meteorológicas de temperatura média do ar e precipitação pluvial média anuais.; (III) validar o modelo CASA para estimativa de NPPreal no cultivo de soja, utilizando dados meteorológicos de reanálise do ERA-Interim e, (IV) quantificar a apropriação humana da NPPpot em função da alteração do uso e cobertura do solo.

## **2. MATERIAL E MÉTODOS**

### **2.1 Área de estudo**

A área de estudo utilizada para o trabalho situa-se no município de Carazinho, localizado no norte do Estado do Rio Grande do Sul ( $28^{\circ}13'43.89''$  S e  $52^{\circ}54'15.93''$  O, elevação 560m). Trata-se de uma propriedade comercial cultivada com soja, que desenvolve pesquisa em parceria com a EMBRAPA Trigo, unidade da Empresa Brasileira de Pesquisa Agropecuária. A propriedade está situada em uma região de intensa atividade agrícola do Rio Grande do Sul, cuja principal cultura é a soja.

O clima da região, segundo a classificação climática de Köppen (1936), é do tipo Cfa, clima subtropical predominantemente temperado, mesotérmico e úmido, com temperatura do ar média do mês mais quente superior a  $22^{\circ}\text{C}$ . Possui estação de inverno e verão bem definida e as precipitações pluviais são distribuídas durante o ano, sem estação seca, mas com alta variabilidade interanual e espacial, principalmente no verão.

### **2.2 Dados utilizados no trabalho**

#### **2.2.1 Dados meteorológicos**

Os dados meteorológicos foram obtidos de duas fontes: (i) Estação Meteorológica (EM) do Instituto Nacional de Meteorologia (INMET), localizada no município de Passo Fundo ( $28^{\circ}13'37.09''$ S e  $52^{\circ}24'12.44''$ O, elevação 670m); e (ii) dados de reanálise do ERA-Interim (ERA), para a coordenada da propriedade, disponibilizados pelo ECMWF e extraídos através de scripts usando IDL (*Interactive Data Language*). Os dados EM e ERA foram obtidos para simular medições locais e dados de extrapolação para a região, respectivamente. Os elementos

meteorológicos utilizados foram: precipitação pluvial (mm), temperatura do ar (°C), umidade relativa do ar (%), velocidade do vento ( $\text{m s}^{-1}$ ) e radiação solar global ( $\text{MJ m}^{-2} \text{ dia}^{-1}$ ).

Com os dados meteorológicos EM e ERA foi calculado o Balanço Hídrico (BH) meteorológico, conforme proposto por Thornthwaite e Matter (1955), com a Evapotranspiração Potencial (ETP) calculada pelo método de Pennam-Monteith (Allen et al., 1998). A Capacidade de Armazenamento de Água disponível (CAD) foi definida como sendo 75 mm para Latossolos Vermelhos com teor de argila superior a 35%, conforme observado por Cunha et al. (2001).

### 2.2.2 Dados de campo

Para o experimento de campo foi utilizada a cultivar de soja DM 5958 RSF IPRO, com data de semeadura em 13/11/2017 e colheita em 03/04/2018. Durante o período experimental foram medidos aos componentes da radiação fotossinteticamente ativa incidente ( $PAR_{inc}$ ), transmitida ( $PAR_t$ ) e refletida ( $PAR_{ref}$ ) pela cultura. Para a  $PAR_{inc}$  foi utilizado um sensor, modelo SQ-110, da marca Apogee Instruments, Logan, UT, USA, instalado a 2 m de altura. E para a  $PAR_t$  e  $PAR_{ref}$  foram utilizados sensores manufaturados de um metro de comprimento contendo cinco células de silício amorfo, dispostas em paralelo e espaçadas em 20 cm (Pandolfo, 1995). A  $PAR_t$  foi medida a 5 cm de altura do solo utilizando cinco sensores e a  $PAR_{ref}$  foi medida com seis sensores instalados a 1,5 m de altura do solo, com a face dos sensores voltados para o dossel. Os sensores foram conectados a um multiplexador de canais, modelo AM16/32B e este a um *data logger*, modelo CR 1000, ambos da Campbell Scientific, Inc. O *data logger* foi programado para realizar leituras contínuas ao longo do ciclo da soja a cada 30 segundos e as médias foram armazenadas a cada 15 minutos. A partir destes dados foi determinada a PAR ( $\text{MJ m}^{-2}$ ) absorvida (APAR) ( $\text{MJ m}^{-2} \text{ mês}^{-1}$ ), pela equação 1.

$$APAR = PAR_{inc} - PAR_t - PAR_{ref} \quad (1)$$

A fração de PAR absorvida pela vegetação (FPAR) foi calculada através da equação 2:

$$FPAR = \frac{APAR}{PAR_{inc}} \quad (2)$$

Além dos dados de PAR foi medido o Índice de Vegetação por Diferença Normalizada (NDVI), visando o ajuste de funções para a estimativa da FPAR. O NDVI foi obtido de sensores

de radiação incidente (Decagon SRS NDVI Hemisférico) e refletida (Decagon SRS NDVI com Limitador de Visão) no espectro do vermelho (0,6 a 0,7  $\mu\text{m}$ ) e do infravermelho próximo (NIR) (0,805 a 0,815  $\mu\text{m}$ ). Estes sensores espectrais foram instalados em um mastro no centro da área experimental, a uma altura de 1 m acima do topo do dossel, ajustável ao longo do ciclo da soja. Foram coletados dados em 3 diferentes pontos da lavoura em intervalos de tempo de 15 minutos, tendo sido utilizados neste estudo apenas os dados médios das 10h15min, 10h30min e 10h45min, correspondendo ao dado obtido durante as passagens do satélite Landsat em torno das 10h30min.

A Matéria Seca (MS) acumulada pela soja foi determinada semanalmente, da emergência das plantas ao final do ciclo. Para isso foram coletadas quatro repetições de um metro linear de plantas, em secções de linhas no transecto central da área reservada para avaliações. A biomassa verde foi colocada em embalagens de papel e levada para estufa para secagem de material vegetal na temperatura de 70°C até massa constante. A MS foi pesada e massa a foi expressa em  $\text{g m}^{-2}$ . Após a maturação fisiológica foram feitas quatro amostragens de biomassa de 9  $\text{m}^2$  para determinação da produtividade de grãos. Os grãos de cada parcela foram separados das impurezas e pesados. A produtividade de grãos foi corrigida a 13% de umidade e calculada para uma área de um hectare.

### 2.3 Estimativa de NPP potencial

O modelo Thornthwaite (Lieth, 1975) foi utilizado para estimar NPP potencial natural, como uma função exponencial da evapotranspiração, conforme a equação 3:

$$NPP_{pot} = 3000[1 - e^{-(0,0009696*(ETR-20)}] \quad (3)$$

em que  $NPP_{pot}$  é a NPP potencial natural anual expressa em  $\text{g m}^{-2} \text{ano}^{-1}$ ;  $e$  é a base do logaritmo natural; 3.000 refere-se à produtividade máxima alcançada nos diferentes ambientes da Terra;  $ETR$  é a Evapotranspiração Real (mm). No presente estudo o período anual foi considerando um ano agrícola, iniciando em novembro de 2017 e finalizando em outubro de 2018, em que a soja foi o único cultivo praticado na área.

A  $ETR$  foi obtida de duas formas. Em uma das formas foram utilizadas as Equações 4 e 5, proposta por Lieth (1975):

$$ETR = \frac{1,05r}{\sqrt{1 + (1+1,05r/L)^2}} \quad (4)$$

$$ETP = 3000 + 25t + 0,05t^3 \quad (5)$$

sendo  $ETP$  a evapotranspiração potencial média anual (mm),  $r$  a precipitação pluvial total anual e  $t$  a temperatura média anual do ar ( $^{\circ}\text{C}$ ). Na outra forma, a ETR foi obtida como variável derivada do BH. Para diferenciar as duas abordagens, foi definido o método de Thornthwaite com ETR derivada pelas equações 4 e 5, como sendo Thornthwaite original (To) e o método considerando a ETR derivada do BH como sendo Thornthwaite BH (TBH).

Para estas duas abordagens de obtenção da ETR, foram utilizados os dados meteorológicos da EM e do ERA. Todas as estimativas foram feitas em escala mensal e, posteriormente, estas foram somadas e totalizadas em escala anual. Esta etapa do estudo envolveu o cálculo da  $NPP_{\text{pot}}$  para dez anos agrícolas (2009 a 2018), afim de se obter uma estimativa do padrão médio anual para a região e, com isso, caracterizar as condições do ano do experimento. Os valores obtidos através da equação 3 foram convertidos em incremento de carbono, utilizando o fator de conversão 0,40 (Pillon; Mielniczuk e Martin Neto, 2004).

Foi feita análise de variância da estimativa de  $NPP_{\text{pot}}$  (ANOVA), considerando os 10 anos como repetições, afim de avaliar as diferenças das bases de dados e dos métodos de estimativa da ETR, e o teste Tukey para avaliar quais médias apresentavam diferenças estatisticamente significativas, a um nível de 5% de probabilidade de erro.

### 2.3.1 Avaliação das variações climáticas frente a $NPP_{\text{pot}}$

Para verificar as mudanças de  $NPP_{\text{pot}}$  nos 10 anos de estudos, foram feitas comparações do padrão anual da  $NPP_{\text{pot}}$  em função das variações das condições meteorológicas, caracterizadas pelos elementos de temperatura do ar e precipitação pluvial. Esta etapa teve o objetivo apenas de enfatizar a relação entre os dados de  $NPP_{\text{pot}}$  e dos elementos meteorológicos, avaliando-se a influência da precipitação e da temperatura foram positivas ou negativas.

## 2.4 Estimativa de NPP real

Para o cálculo da  $NPP_{real}$ , foram avaliados dois diferentes enfoques, um utilizando a biomassa acima do solo (AGB) medida a campo e o outro utilizando a modelagem. No primeiro, o incremento de AGB medido no experimento foi convertido em conteúdo de carbono usando o fator de conversão de 0,40 (Pillon; Mielniczuk e Martin Neto, 2004), obtendo-se, assim, a  $NPP_{real}$  ( $NPP_{real\_campo}$ ) ( $gC\ m^{-2}\ ano^{-1}$ ). No segundo, a  $NPP_{real}$  foi estimada utilizando o modelo CASA, que considera a NPP, como uma variante do modelo de Eficiência do Uso da Luz (LUE), originalmente proposto por Monteith (1972), conforme a equação 6. A  $NPP_{real(x,t)}$  ( $gC\ m^{-2}\ ano^{-1}$ ) é o produto da  $APAR_{(x,t)}$  ( $MJ\ m^{-2}$ ) pela eficiência de conversão da radiação em biomassa ( $LUE_{(x,t)}$  ou  $\epsilon_{(x,t)}$ ,  $g\ C\ MJ^{-1}$ ) (Bao et al., 2016):

$$NPP_{real(x,t)} = APAR_{(x,t)} \times \epsilon_{(x,t)} \quad (6)$$

em que  $x$  é localização espacial e  $t$  é o tempo. Para a estimativa de  $NPP_{real(x,t)}$  do modelo CASA, foram utilizadas duas abordagens de obtenção da  $APAR_{(x,t)}$ . Na primeira, a  $APAR_{(x,t)}$  obtida através dos dados de PAR medidos a campo ( $NPP_{real\_APAR\_campo}$ ), utilizando a equação 1. Na segunda abordagem, a  $APAR_{(x,t)}$  foi obtida através de uma metodologia alternativa, utilizando dados de NDVI para compor a estimativa de  $APAR$  ( $NNP_{real\_APAR\_NDVI}$ ). Para tanto, foi utilizada a equação 2,  $APAR = FPAR \times PAR_{inc}$ , sendo a  $FPAR$  obtida a partir do ajuste de uma regressão linear entre a  $FPAR$  e o NDVI medidos a campo, originando a Equação 7, com  $R^2$  de 0,98.

$$FPAR = 1,1755 \times NDVI - 0,14 \quad (7)$$

O NDVI foi calculado pela diferença das reflectâncias nas bandas do infravermelho próximo ( $\rho_{NIR}$ ) e do vermelho ( $\rho_{RED}$ ), normalizado pela soma das mesmas, conforme equação 8 proposta por Rouse et al. (1973):

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (8)$$

A  $PAR_{inc}$  foi obtida pela conversão da RG do ERA-Interim em PAR, através do fator de conversão 0.5, pois foi verificado que os dados de  $APAR$  medidos a campo correspondiam a 50% dos dados de RG ( $PAR = RG \times 0,5$ ). Além disso, Pei et al. (2013) destacaram que



aproximadamente metade da RG incidente situa-se na faixa de comprimento de ondas PAR (Pei et al., 2013).

A estimativa da Eficiência de Conversão  $\varepsilon_{(x,t)}$ , que expressa a capacidade das plantas de converter luz em carbono (C) fixo (Sims et al., 2008). O cálculo foi feito a partir da constante de  $\varepsilon_{m\acute{a}x}$ , ajustada a fatores limitantes (equação 9), como temperatura do ar e água (Garbulsky et al., 2011). A constante  $\varepsilon_{m\acute{a}x}$  foi definida como sendo 40%, baseado em Pillon; Mielniczuk e Martin Neto (2004), do coeficiente angular, obtido da relação linear entre MS e APAR.

$$\varepsilon(x,t) = \varepsilon_{m\acute{a}x} \times T_{\varepsilon_1}(x,t) \times T_{\varepsilon_2}(x,t) \times W_{\varepsilon}(x,t) \quad (9)$$

Os termos  $T_{\varepsilon_i(x,t)}$  denotam os coeficientes de estresse térmico e foram calculados (equações 10 e 11) usando a temperatura média mensal do ar (T) (°C) e a temperatura ideal para o crescimento das plantas ( $T_{opt}$ ) (°C), que é a temperatura durante o mês de máximo NDVI (Bao et al., 2016; Yu et al., 2011). Já o termo  $W_{\varepsilon(x,t)}$  é o coeficiente de estresse hídrico, calculado pela equação 12 (Yu et al., 2011).

$$T_{\varepsilon_1}(x,t) = 0,8 + 0,02T_{opt} - 0,0005T_{opt}^2 \quad (10)$$

$$T_{\varepsilon_2}(x,t) = \frac{1}{1+\exp\{0,2(T_{opt}-10+T)\}} \times \frac{1}{1+\exp\{0,3(-T_{opt}-10+T)\}} \quad (11)$$

$$W_{\varepsilon}(x,t) = 0,5 + 0,5 \times \frac{ETR(x,t)}{ETP(x,t)} \quad (12)$$

em que ETR e ETP foram obtidas dos dados meteorológicos do ERA-Interim, pelo cálculo do BH.

## 2.5 Estimativa de HANPP

A HANPP<sub>Pharv</sub> foi obtida a partir da produtividade de grãos, medidas durante o cultivo da soja. Para tanto, os dados de produtividade de grãos foram convertidos para conteúdo de carbono, utilizando o fator de 0.4 (Pillon; Mielniczuk e Martin Neto, 2004) e considerados como sendo a HANPP<sub>Pharv</sub>. Já a HANPP<sub>Pluc</sub> foi calculada pela diferença entre a NPP<sub>pot</sub> e a NPP<sub>real</sub>, (Equação 13):

$$HANPPluc = NPP_{pot} - NPP_{real\_campo} \quad (13)$$

sendo que, a  $NPP_{pot}$  representa a média das estimativas anuais obtidas de  $NPP_{pot\_TBH\_ERA}$ , enquanto para a  $NPP_{real}$  foram utilizados somente os dados de  $NPP_{real\_campo}$ , pois apresentavam dados de produtividade de grãos. Desta forma, uma  $HANPPluc$  negativa representa um incremento de NPP produzido por atividades humanas, enquanto que um valor positivo representa a apropriação da NPP em função das atividades humanas, pelas mudanças de uso e cobertura do solo, (Li et al., 2016).

### 3. RESULTADOS E DISCUSSÕES

#### 3.1 NPP Potencial

A maior variabilidade da  $NPP_{pot}$  em cada ano esteve associada ao método de cálculo da ETR, ou através da proposta de Thornthwaite (To) ou através do cálculo do BH (TBH). Isto, provavelmente esteja associado ao fato do modelo de Thornthwaite (To) usar apenas dados de precipitação pluvial e temperatura do ar para estimar a ETP, enquanto o método TBH leva em consideração diversos elementos meteorológicos, como umidade do ar, velocidade do vento e radiação solar na estimativa da ETP. Por outro lado, para um mesmo método, as fontes de dados EM e ERA geraram resultados bastante similares (Figura 3). De forma geral, o método TBH gerou valores menores que o método To, em média de 7,5%, corroborando em parte resultados observados por Schweig et al. (2009). De acordo com estes autores, o modelo Thornthwaite (também denominado modelo Montreal) foi o que apresentou estimativas mais próximas à NPP potencial, medida a campo em florestas naturais na região sul do Brasil, com valores da ordem de  $1.600 \text{ g m}^{-2} \text{ ano}^{-1}$  (em torno de  $640 \text{ gC m}^{-2} \text{ ano}^{-1}$ ), equivalendo a 3,8% superior à mata nativa.

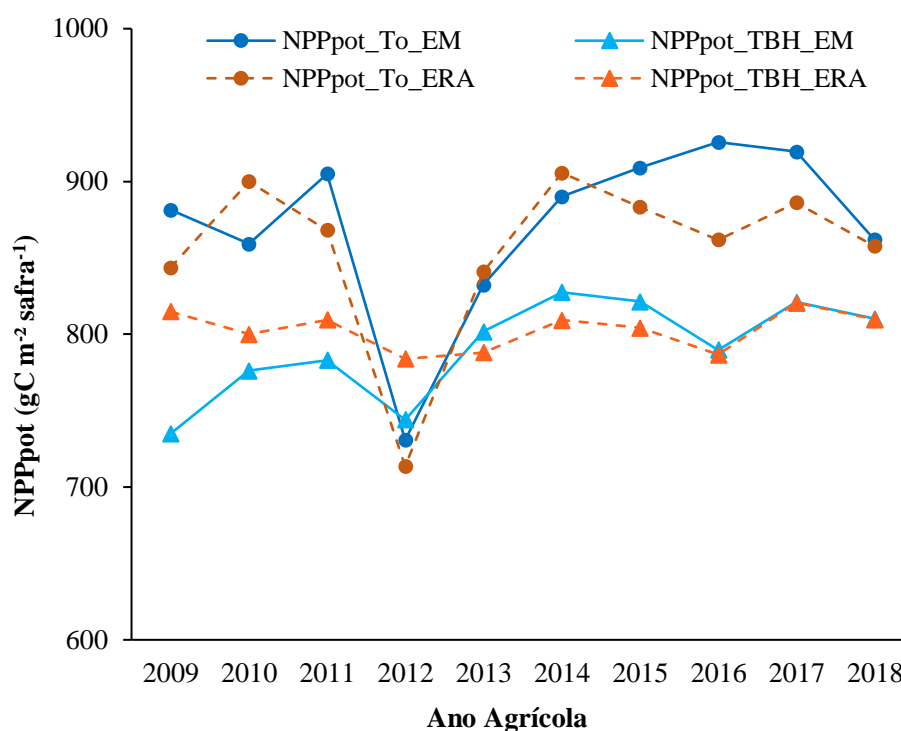


Figura 3 - Produtividade Primária Líquida potencial (NPPpot) calculada com a evapotranspiração real estimada pelo modelo de Thornthwaite (To) e pelo Balanço Hídrico (TBH), ambos com dados meteorológicos obtidos da Estação Automática Meteorológica do INMET (EM) e com dados de reanálise do ERA Interim (ERA).

A NPPpot média estimada não apresentou diferença significativa entre as fontes de dados EM e ERA, evidenciando a acurácia dos dados ERA-Interim quando comparados aos do EM ( $p > 0,05$ ) (Tabela 1). Esses resultados indicam que as reanálises de dados do ERA-Interim podem ser utilizados para estimativas de NPPpot de diferentes locais na região Sul do Brasil. Isso é especialmente importante para melhorar as estimativas em regiões que possuem carência ou falta de estações meteorológicas. Os dados de reanálise fornecem um registro multivariado, espacialmente completo e coerente da circulação atmosférica global (Dee et al., 2011).

**Tabela 1** – Avaliação da NPP potencial (NPPpot) para as fontes de dados do ERA-Interim (ERA) e da Estação Meteorológica (EM), para os métodos de cálculo de NPPpot de Thornthwaite (To) e do Balanço Hídrico (TBH).

Fonte de dados	Método de cálculo da ETR	
	To	TBH
<b>EM</b>	871,48 <sup>aA</sup> ± 57,56	790,93 <sup>bB</sup> ± 32,06
<b>ERA</b>	856,05 <sup>aA</sup> ± 54,68	802,66 <sup>bB</sup> ± 12,67

Valores médios de análise realizados para as 10 safras ± desvio padrão. Letras minúsculas iguais na mesma coluna e letras maiúsculas iguais na mesma linha indicam que não houve diferença significativa ao nível de 5% de probabilidade de erro.

Os dois métodos de cálculo da ETR apresentaram diferença significativa na estimativa da NPPpot média pelo modelo de Thornthwaite ( $p < 0,05$ ). De fato, incertezas permanecem no processo de simulação da NPPpot usando modelos estatísticos, como o de Thornthwaite, pois, como explicam Wang et al. (2016), modelos de estimativas baseados no clima, que usam apenas precipitação pluvial e temperatura do ar como variáveis de entrada podem gerar super ou subestimativas (Wang et al., 2016), dependendo das condições ambientais do local em que é aplicado. Além disso, Zhang et al. (2020) observaram que no modelo To os níveis de umidade foram determinantes no potencial de NPP, controlando as variações de NPPpot em relação direta com a precipitação pluvial. Ao utilizar a ETR calculado pelo BH, a NPPpot estimada pareceu não sofrer a influência das variações da precipitação pluvial de forma acentuada (Figura 3). No modelo TBH, ao incorporar outros dados de clima, como a radiação solar, velocidade do vento e umidade relativa do ar, a demanda evaporativa da atmosfera melhor caracterizada e, em consequência, há uma melhor caracterização do fluxo evaporativo de determinada região e, assim, as estimativas de NPP tendem a ser mais precisas (Schweig et al., 2009).

Pode-se observar que variações meteorológicas implicaram em variações nas estimativas da NPPpot nos 10 anos avaliados (Figuras 3 e 4). Isto fica evidenciado nos valores de NPPpot da safra de 2012, os quais estiveram abaixo do padrão das demais safras, podendo estar relacionado ao grande período de estiagem ocorrido na época. Entre o final de 2011 e meados de 2012 ocorreu um evento extremo de La Niña (Rodrigues e McPhaden, 2014) ocasionando períodos de estiagem na região, com baixa precipitação pluvial e também mais dias consecutivos sem precipitação pluvial (Radin; Schönhofen e Tazzo, 2017). Em consequência da restrição hídrica, observou-se diminuição dos valores de NPPpot. Além da restrição de água no solo, nesta safra ocorreram altas temperaturas do ar, aumentando a demanda evaporativa da atmosfera, causando déficit hídrico e prejudicando o crescimento da vegetação. Sabe-se que a variabilidade climática pode influenciar diretamente o crescimento da vegetação, pois alterações de temperatura do ar e precipitação pluvial podem determinar as condições hidrotérmicas do crescimento da vegetação, especialmente para os ecossistemas secos (Li et al., 2015).

É amplamente conhecido que a precipitação pluvial é um fator importante que regula a NPPpot e sua variação em regiões secas (Piao et al., 2011; Chen et al., 2014), sendo menos importante em regiões úmidas, como a região do presente estudo. No entanto, restrições hídricas como a ocorrida em 2012 acarretaram em prejuízos ou perdas de produtividade. Além disso, a instabilidade do clima subtropical, que ora se comporta como clima temperado, ora como clima

tropical (Denardim, 2018), resulta em impactos claramente perceptíveis pelas oscilações da NPPpot no período analisado.

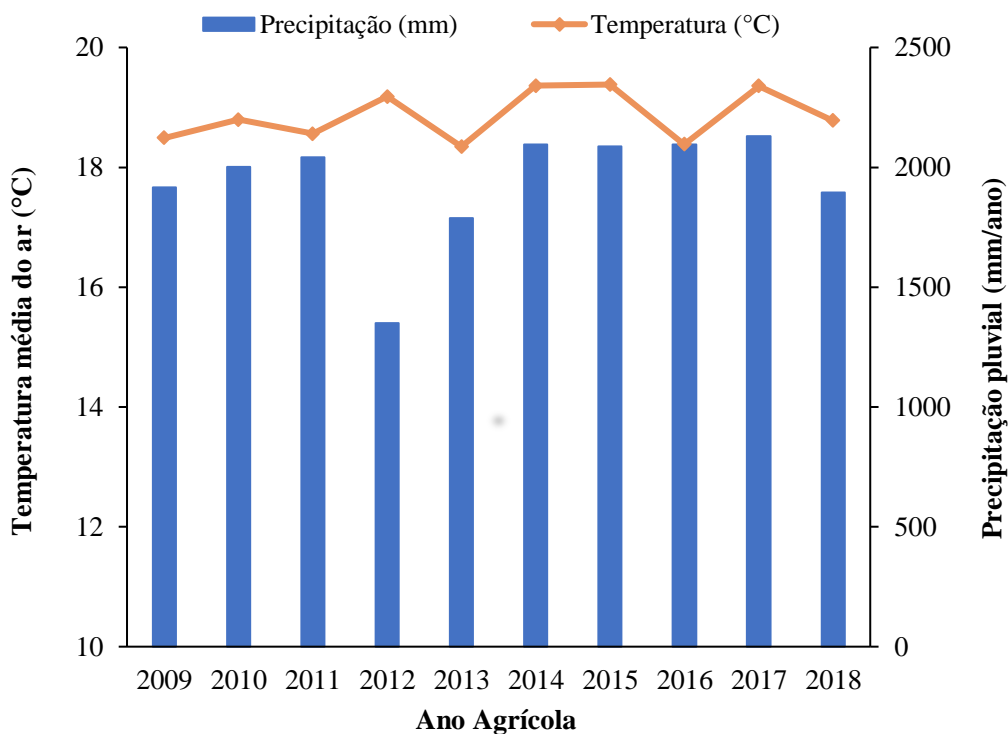


Figura 4 – Total anual de Precipitação pluviométrica e Temperatura do ar média anual para os anos agrícolas de 2009 a 2018. Carazinho-RS

O ano agrícola de 2018 (nov/2017 a out/2018), em que se desenvolveram os trabalhos de campo, apresentou valores de NPPpot de acordo com o padrão médio da série temporal. Assim, este ano agrícola foi utilizado no restante do trabalho para a estimativa da NPPreal.

### 3.2 NPP Real

A principal diferença encontrada entre as estimativas da NPPreal pelo modelo CASA e NPPreal\_campo, foi a magnitude dos resultados do modelo. No estágio de pleno desenvolvimento da cultura soja, em especial, o modelo CASA subestimou a NPPreal a campo em mais de 40gC m<sup>-2</sup>. Enquanto a NPPreal\_campo da soja atingiu aproximadamente 203 gC m<sup>2</sup> mês<sup>-1</sup>, nos meses de máximo crescimento da cultura, as estimativas do modelo CASA, para NPPreal\_APAR\_campo e NPPreal\_APAR\_NDVI, atingiram apenas 163 e 149 gC m<sup>2</sup> mês<sup>-1</sup>, respectivamente. (Figura 5).

Ao estudar a NPPreal da vegetação no platô tibetano, Gao et al. (2013) relataram que o resultado da validação entre a NPPreal modelada e a NPPreal medida em campo mostrou que a primeira foi mais baixa em aproximadamente 35% em relação à segunda. No presente estudo, a diferença entre NPPreal\_campo da soja e NPPreal estimada variou entre 15 a 27%, para NPPreal\_APAR\_campo e NPPreal\_APAR\_NDVI, respectivamente. Piana e Civeira (2017), ao simular a NPPreal da soja para regiões do bioma Pampa na Argentina, encontraram valores de até  $210 \text{ gC m}^{-2} \text{ ano}^{-1}$ . Já Civeira (2016), que estudou a NPPreal de diversas culturas na Argentina, encontrou valores máximos de NPPreal para a soja de  $320 \text{ gC m}^{-2} \text{ ano}^{-1}$ , para o sul do país. Estes valores se aproximam do total de NPPreal\_APAR\_NDVI obtidos neste trabalho, de aproximadamente  $373 \text{ gC m}^{-2} \text{ ano}^{-1}$ . Para as demais estimativas de NPPreal\_campo e NPPreal\_APAR\_campo, foram obtidos resultados mais distantes aos da literatura, de 510 e  $435 \text{ gC m}^{-2} \text{ ano}^{-1}$ , respectivamente.

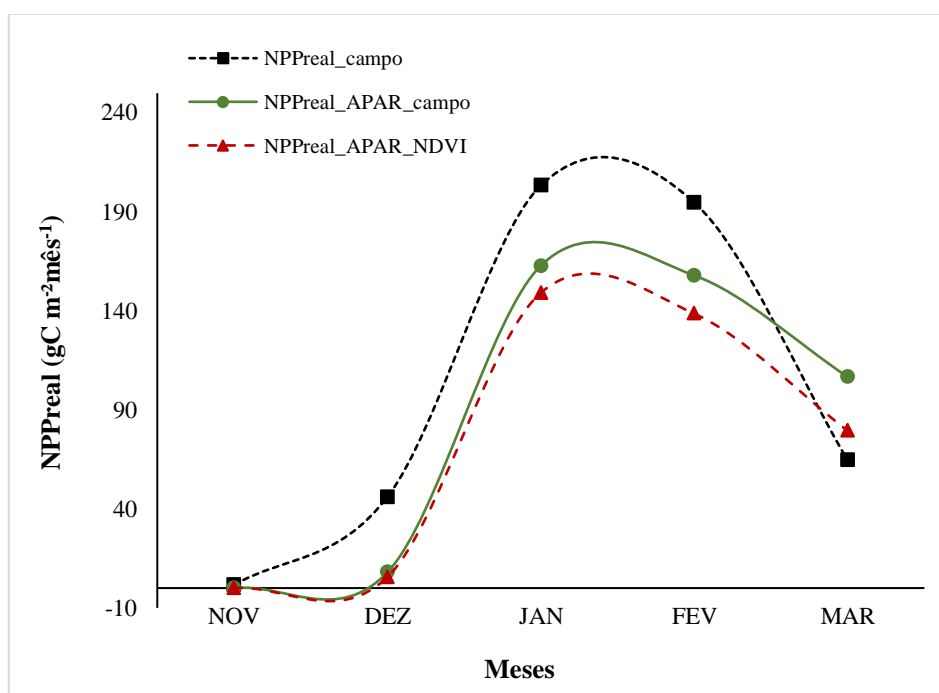


Figura 5 – Produtividade Primária Líquida observada a campo (NPPreal\_campo), utilizando dados de APAR de campo (NPPreal\_APAR\_campo) e utilizando dados de NDVI para estimar a PAR (NPPreal\_APAR\_NDVI) para o cultivo da soja.

A correlação entre os resultados observados a campo e os resultados estimados pelo modelo CASA, NPPreal\_APAR\_campo e NPPreal\_APAR\_NDVI, foi alta, resultando em boa associação entre os mesmos ( $r = 0,922$  e  $0,953$ ), ou seja, a correspondência destes dados com a NPP observada foi bastante consistente (Figura 6). Chen et al. (2019), ao avaliarem o desempenho do modelo CASA para simular NPPreal comparada a NPP medida em campo,

obtiveram um  $R^2$  de 0,74 ( $p < 0,001$ ). Os autores, concluíram que a NPP estimada pelo modelo CASA era confiável e podia ser aplicada em etapas e análises futuras.

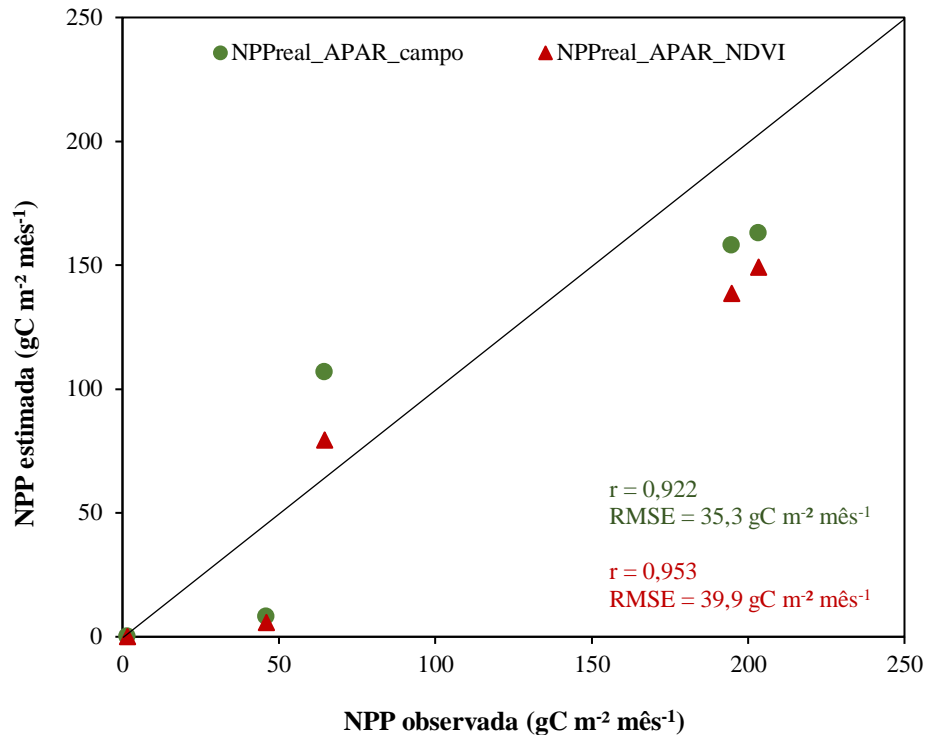


Figura 6 – Dispersão entre resultados de Produtividade Primária Líquida (NPP) observada a campo (NPPreal\_campo) e estimada utilizando dados de APAR medidos a campo (NPPreal\_APAR\_campo), e estimada a partir do NDVI (NPPreal\_APAR\_NDVI) medido para a cultura da soja.

### 3.3 HANPP

De acordo com as estimativas de NPP<sub>pot</sub> e NPP<sub>real\_campo</sub>, a HANPP<sub>luc</sub>, derivada apenas do uso e cobertura do solo pelas atividades humanas, alcançou 28%. Isto evidencia que, quando realizado apenas um cultivo anual, cerca de um terço da produção primária potencial deste ecossistema foi apropriada pelas atividades humanas associadas ao cultivo de grãos na área (Figura 7). As estimativas de HANPP<sub>luc</sub>, a partir da NPP<sub>real</sub> estimada pelo modelo CASA (NPP<sub>real\_APAR\_campo</sub> e NPP<sub>real\_APAR\_NDVI</sub>), foram maiores do que a HANPP<sub>luc</sub> calculada a partir da NPP<sub>real\_campo</sub>, chegando a atingir até metade da NPP<sub>pot</sub> (45% e 53%, respectivamente). Haberl et al. (2012), ao avaliarem a HANPP para diferentes atividades, verificaram que a maior parte da apropriação foi associada à produção agrícola. Os autores mesmo identificaram, na Áustria, que aproximadamente 50% da HANPP<sub>luc</sub> estava relacionada às terras cultiváveis. Na Ásia Central, Chen et al. (2019) observaram que 34,4% da área

apresentava NPP alterada pela transformação em pastagens. Também Huang, Luo e Han (2018), encontraram uma contribuição das atividades humanas nas mudanças de NPP em pastagem na ordem de 34%.

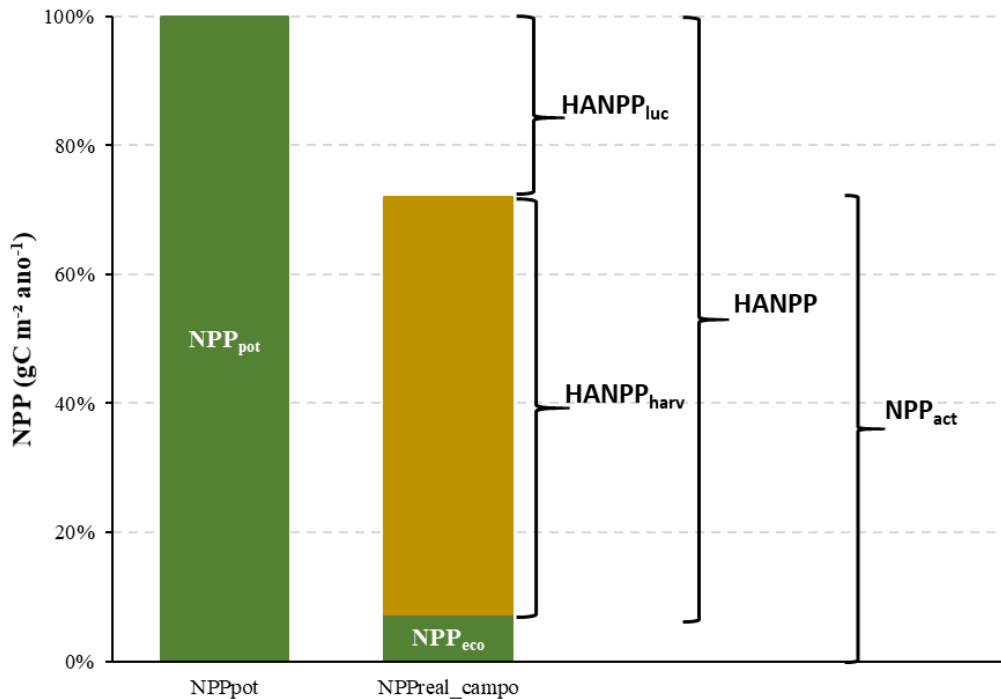


Figura 7 – Estimativas de Produtividade Primária Líquida potencial (NPP<sub>pot</sub>), real (NPP<sub>act</sub>), Apropriação Humana da NPP pelo uso da terra (HANPP<sub>luc</sub>), NPP colhida (HANPP<sub>harv</sub>) e NPP disponível naquele ecossistema (NPP<sub>eco</sub>). (Com base em Haberl; Erb e Krausmann, 2014)

No entanto, é importante considerar que, em boa parte do Brasil, a produção agrícola anual é composta por mais de um cultivo agrícola. Em geral, na região de estudo, também são cultivados cereais de inverno (julho a outubro), como trigo, aveia, cevada, pastagens como o azevém e também a canola. Essas culturas, cultivadas na mesma área da soja em sucessão, contribuem para o aumento da NPP<sub>real</sub> produzida ao longo do ano, tornando as perdas relacionadas a mudança de uso da terra (NPP<sub>pot</sub> não apropriada) menores do que aquelas observadas. Nestas condições de dois cultivos anuais, a NPP<sub>real</sub> pode ser superior à NPP<sub>pot</sub> do ambiente.

A apropriação da NPP<sub>real</sub> em função da remoção das culturas (HANPP<sub>harv</sub>) para consumo humano deixa na lavoura apenas o material colhido que não é utilizado para consumo humano e que fica disponível naquele ecossistema. Assim, a mudança no uso da terra, através da introdução e retirada de cultivos agrícolas, aumenta a participação da produção primária



destinada ao consumo humano, diminuindo a fração disponível para outras funções do ecossistema (DeFries; Foley e Asner, 2004). Nesse contexto, é necessário adotar práticas de agricultura que visem manter a cobertura contínua do solo, perturbações mínimas do solo e rotação de culturas (Soares, 2020), para minimizar os efeitos da apropriação humana em função da colheita de biomassa.

A avaliação da HANPP é de grande importância, por permitir relacionar a produtividade potencial de um ecossistema na ausência de interferências humanas, com a produção atual agrícola do agroecossistema formado, decorrente das mudanças de uso da terra (Wessels; Prince e Reshef, 2008). A análise dos parâmetros como a NPP<sub>pot</sub>, NPP<sub>real</sub> e HANPP, estimados por modelos teóricos, pode ser utilizada não apenas para indicar a contribuição relativa de fatores naturais e antropogênicos, mas também para direcionar a regulação (Feng et al., 2017) e a intensificação agrícola nos cenários atuais e futuros. Nesse sentido, mais estudos devem ser feitos no sentido de avaliar os efeitos das atividades humanas e das variações climáticas sobre a NPP de agroecossistemas. As lacunas de produção precisam ser preenchidas considerando a sustentabilidade a longo prazo dos agroecossistemas, para uma gestão adequada dos recursos do ambiente, necessários para a produção agrícola, minimizando impactos ambientais associados a estas atividades (Weinzettel; Vačkářo e Medková, 2019).

#### **4. CONCLUSÕES**

As estimativas de NPP potencial mostram sensibilidade quanto ao método de obtenção da ETR e refletem a influência das variações interanuais das condições meteorológicas sobre o potencial de crescimento da vegetação na ausência de interferência humana.

Dada a similaridade dos dados meteorológicos de reanálise ERA-Interim e os dados medidos na superfície, estes podem ser utilizados como dados de entrada no modelo Thornthwaite de estimativa da NPP potencial, assim como no modelo CASA de estimativa da NPP<sub>real</sub>, com a vantagem de permitir um maior detalhamento espacial dos modelos.

O modelo CASA gera estimativas acuradas da NPP<sub>real</sub>, fornecendo um meio para avaliar a dinâmica de fixação de carbono através da fotossíntese ao longo do ciclo produtivo.

O estudo da Apropriação Humana da NPP se mostra eficiente em identificar as perdas ou ganhos de produtividade em um determinado ecossistema que foi modificado pelas atividades humanas. A avaliação da HANPP<sub>pluc</sub> e HANPP<sub>harv</sub> consegue separar as perdas ou

ganhos referentes a diferentes ações humanas, como a mudança de uso e cobertura do solo e da colheita de biomassa.

## 5. AGRADECIMENTOS

Este trabalho foi apoiado pela Coordenação de Aperfeiçoamento de Pessoas – CAPES. Agradecimentos em especial ao Laboratório de Agrometeorologia da Empresa Brasileira de Pesquisa Agropecuária unidade da Embrapa Trigo, pela parceria na condução do experimento e aos que trabalharam na área experimental coletando os dados.

## 6. REFERÊNCIAS

- ALLEN, R. G. *et al.* Crop evapotranspiration: guidelines for computing crop water requirements. Rome: FAO, 1998. 300 p. (FAO – Irrigation and Drainage Paper, 56).
- BAO, G. *et al.* Modeling net primary productivity of terrestrial ecosystems in the semi-arid climate of the Mongolian Plateau using LSWI-based CASA ecosystem model. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 46, p. 84-93, 2016.
- BATTISTI, R.; BENDER, F. D.; SENTELHAS, P. C. Assessment of different gridded weather data for soybean yield simulations in Brazil. **Theoretical and Applied Climatology**, Wien, v. 135, n. 1/2, p. 237-247, 2018.
- BERRISFORD, P. *et al.* **The ERA-Interim Archive**. Reading: European Centre for Medium-Range Weather Forecasts – ECMWF, 2009. (ERA Report Series, 1. Technical Report).
- BREUNIG, F. M. *et al.* Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 85, [art.] 102004, [p. 1-15], 2020.
- CHEN, B. *et al.* The impact of climate change and anthropogenic activities on alpine grassland over the Qinghai-Tibet Plateau. **Agricultural and Forest Meteorology**, Amsterdam, v. 189-190, p. 11-18, 2014.
- CHEN, T. *et al.* Disentangling the relative impacts of climate change and human activities on arid and semiarid grasslands in Central Asia during 1982–2015. **Science of the Total Environment**, Amsterdam, v. 653, p. 1311-1325, 2019.
- CHEN, Z. *et al.* Analysis of net primary productivity of terrestrial vegetation on the Qinghai-Tibet Plateau, based on MODIS remote sensing data. **Science China Earth Sciences**, Beijing, v. 55, p. 1306–1312, 2012.

- CIVEIRA, G. Potential Changes in Net Primary Productivity and carbon input of periurban agroecosystems treated with biosolids in Buenos Aires, Argentina. **Pedosphere**, Beijing, v. 26, n. 1, p. 98–107, 2016.
- CUNHA, G. R. *et al.* Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 9, n. 3, p. 446-459, 2001.
- DEE, D. P. *et al.* The ERA-Interim reanalysis: configuration and performance of the data assimilation system. **Quarterly Journal of the Royal Meteorological Society**, London, v. 137, p. 553-597, 2011.
- DEFRIES, R. S.; FOLEY, J. A.; ASNER, G. P. Land-use choices: balancing human needs and ecosystem function. **Frontiers in Ecology and the Environment**, Washington, DC, v. 2, n. 5, p. 249-257, 2004.
- DENARDIN, J. E. Alternativas para aumento da produtividade da lavoura de grãos no Rio Grande do Sul. *In: ALTERNATIVAS para ampliação da produtividade e da qualidade da produção agropecuária do Rio Grande do Sul: leite e grãos*. Porto Alegre: Secretaria de Planejamento, Governança e Gestão, 2018. (Futuro RS: agenda de desenvolvimento. Cadernos para o futuro, 4). p. 65-92.
- EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Visão 2030: o futuro da agricultura brasileira**. Brasília, DF: EMBRAPA, 2018. 212 p.
- FAO - FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **OECD-FAO Agricultural Outlook 2019-2028**. Disponível em: <https://doi.org/10.1787/fc22ad57-pt>. Acesso em: 11 dez. 2019.
- FANG, O.; WANG, Y.; SHAO, X. The effect of climate on the net primary productivity (NPP) of *Pinus koraiensis* in the Changbai Mountains over the past 50 years. **Trees**, Berlin, v. 30, n. 1, p. 281-294, 2015.
- FENG, Y. *et al.* Identifying the relative contributions of climate and grazing to both direction and magnitude of alpine grassland productivity dynamics from 1993 to 2011 on the northern tibetan plateau. **Remote Sensing**, Basel, v. 9, n. 2, p. 136-136, 2017.
- FOLEY, J. A. *et al.* Solutions for a cultivated planet. **Nature**, London, v. 478, n. 7369, p. 337-342, 2011.
- GANG, C. *et al.* The impacts of land conversion and management measures on the grassland net primary productivity over the Loess Plateau, Northern China. **The Science of the Total Environment**, Amsterdam, v. 645, p. 827-836, 2018.
- GAO, Y. *et al.* Vegetation net primary productivity and its response to climate change during 2001–2008 in the Tibetan Plateau. **The Science of the Total Environment**, Amsterdam, v. 444, p. 356-362, 2013.
- GARBULSKY, M. F. *et al.* The photochemical reflectance index (PRI) and the remote sensing of leaf, canopy and ecosystem radiation use efficiencies: a review and meta-analysis. **Remote Sensing of Environment**, New York, v. 115, n. 2, p. 281-297, 2011.

- HABERL, H. *et al.* Quantifying and mapping the human appropriation of net primary production in earth's terrestrial ecosystems. **Proceedings of the National Academy of Sciences**, Washington, DC, v. 104, n. 31, p. 12942-12947, 2007.
- HABERL, H. *et al.* Global effects of national biomass production and consumption: Austria's embodied HANPP related to agricultural biomass in the year 2000. **Ecological Economics**, Amsterdam, v. 84, p. 66-73, 2012.
- HABERL, H.; ERB, K. H.; KRAUSMANN, F. Human appropriation of net primary production: patterns, trends, and planetary boundaries. **Annual Review of Environment and Resources**, Palo Alto, v. 39, p. 363-391, 2014.
- HARKNESS, C. *et al.* Adverse weather conditions for UK wheat production under climate change. **Agricultural and Forest Meteorology**, Amsterdam, v. 282/283, [art.] 107862, [p. 1-13], 2020.
- HUANG, X.; LUO, G.; HAN, Q. Temporospatial patterns of human appropriation of net primary production in Central Asia grasslands. **Ecological Indicators**, New York, v. 91, p. 555-561, 2018.
- HUANG, J. *et al.* Assimilation of remote sensing into crop growth models: current status and perspectives: current status and perspectives. **Agricultural and Forest Meteorology**, Amsterdam, v. 276/277, [art.] 107609, [p. 1-16], 2019.
- KENNEDY, C. M. *et al.* Optimizing land use decision-making to sustain Brazilian agricultural profits, biodiversity and ecosystem services. **Biological Conservation**, Essex, v. 204, p. 221-230, 2016.
- KRAUSMANN, F. *et al.* Global human appropriation of net primary production doubled in the 20th century. **Proceedings of The National Academy of Sciences**, Washington, DC, v. 110, n. 25, p. 10324-10329, jun. 2013.
- KÖPPEN, W. Das geographische system der klimare. *In*: KÖPPEN, W.; GEIGER, R. (ed.). **Handbuch der klimatologie**. Berlin: GebrüderBornträger, 1936. p. 1-44.
- LAMBIN, E. F.; MEYFROIDT, P. Global land use change, economic globalization, and the looming land scarcity. **Proceedings of the National Academy of Sciences**, DC, Washingtonv. 108, n. 9, p. 3465-3472, 2011.
- LEES, K. J. *et al.* Potential for using remote sensing to estimate carbon fluxes across northern peatlands – a review. **The Science of the Total Environment**, Amsterdam, v. 615, p. 857-874, 2018.
- LI, Z. *et al.* Potential impacts of climate change on vegetation dynamics in Central Asia. **Journal of Geophysical Research: Atmospheres**, Hoboken, v. 120, n. 24, p. 12345-12356, 2015.

- LI, Q. *et al.* Quantitative assessment of the relative roles of climate change and human activities in desertification processes on the Qinghai-Tibet Plateau based on net primary productivity. **Catena**, Cremlingen, v. 147, p. 789-796, 2016.
- LI, L. *et al.* Current challenges in distinguishing climatic and anthropogenic contributions to alpine grassland variation on the Tibetan Plateau. **Ecology and Evolution**, Oxford, v. 8, n. 11, p. 5949-5963, 2018.
- LIANG, W. *et al.* Analysis of spatial and temporal patterns of net primary production and their climate controls in China from 1982 to 2010. **Agricultural and Forest Meteorology**, Amsterdam, v. 204, p. 22-36, 2015.
- LIETH, H. Modeling the primary productivity of the world. *In*: LIETH, H.; WHITTAKER, R. H. **Primary productivity of the biosphere**. New York: Springer, 1975. cap. 12, p. 237-263.
- LOREL, C. *et al.* Linking the human appropriation of net primary productivity-based indicators, input cost and high nature value to the dimensions of land-use intensity across French agricultural landscapes. **Agriculture, Ecosystems & Environment**, Amsterdam, v. 283, p. 106565-106565, 2019.
- MONTEITH, J. Solar radiation and productivity in tropical ecosystems. **Journal of Applied Ecology**, Oxford, v. 9, n. 3, p. 747-766, 1972.
- PANDOLFO, C. **Parâmetros básicos para uso na modelagem do rendimento de matéria seca em alfafa (Medicago sativa L.)**. 1995. Dissertação (Mestrado) – Programa de Pós-Graduação em Fitotecnia, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1995.
- PAZ, A. R.; COLLINSCHONN, W. Avaliação de estimativas de campos de precipitação para modelagem hidrológica distribuída. **Revista Brasileira de Meteorologia**, Rio de Janeiro, v. 26, n. 1, p. 109-120, 2011.
- PEI, F. *et al.* Assessing the impacts of droughts on net primary productivity in China. **Journal of Environmental Management**, London, v. 114, p. 362-371, 2013.
- PIANA, M.; CIVEIRA, G. Estimating net primary productivity and carbon inputs by soybean crops in Argentina. **Communications in Soil Science and Plant Analysis**, New York, v. 48, n. 10, p. 1105-1113, 2017.
- PIAO, S. *et al.* Changes in satellite-derived vegetation growth trend in temperate and boreal Eurasia from 1982 to 2006. **Global Change Biology**, Oxford, v. 17, n. 10, p. 3228-3239, 2011.
- PILLON, C. N.; MIELNICZUK J.; MARTIN NETO, L. **Ciclagem da matéria orgânica em sistemas agrícolas**. Pelotas: Embrapa Clima Temperado, 2004. (Documentos, 125).
- POTTER, C. S. *et al.* Terrestrial ecosystem production: a process model based on global satellite and surface data. **Global Biogeochemical Cycles**, Washington, DC, v. 7, n. 4, p. 811-841, 1993.

- POTTER, C.; KLOOSTER, S.; GENOVESE, V. Net primary production of terrestrial ecosystems from 2000 to 2009. **Climatic Change**, Dordrecht, v. 115, n. 2, p. 365-378, 2012.
- RADIN, B.; SCHÖNHOFEN, A.; TAZZO, I. F. Impacto da quantidade e frequência de chuva no rendimento da soja. **Agrometeoros**, Passo Fundo, v. 25, n. 1, p. 19-26, 2017.
- RODRIGUES, R. R.; MCPHADEN, M. J. Why did the 2011–2012 La Niña cause a severe drought in the Brazilian Northeast? **Geophysical Research Letters**, Washington, DC, v. 41, n. 3, p. 1012-1018, 2014.
- ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. *In: EARTH RESOURCES TECHNOLOGY SATELLITE SYMPOSIUM*, 3., 1973, Washington. **Proceedings** [...]. Washington, DC: NASA, 1973. p. 309-317.
- RUNNING, S. W. *et al.* A continuous satellite-derived measure of global terrestrial primary production. **Bioscience**, Washington, DC, v. 54, n. 6, p. 547-560, 2004.
- SANTOS, J. F. S.; NAVAL, L. P. Spatial and temporal dynamics of water footprint for soybean production in areas of recent agricultural expansion of the Brazilian savannah (Cerrado). **Journal of Cleaner Production**, Amsterdam, v. 251, [art.] 119482, 2020.
- SCHWEIG, E. *et al.* Avaliação de modelos agroclimáticos para a estimativa da Produtividade Primária Líquida (PPL) da vegetação natural. *In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA*, 16., 2009, Belo Horizonte. **Mudanças climáticas, recursos hídricos e energia para uma agricultura sustentável**. Campinas: SBA; Viçosa: UFV; Sete Lagoas: Embrapa Milho e Sorgo, 2009. V- Estatística e modelagem, trabalho 326.
- SENTELHAS, P. C. *et al.* The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **The Journal of Agricultural Science**, London, v. 153, n. 8, p. 1394-1411, 2015.
- SIMS, D. A. *et al.* A new model of gross primary productivity for North American ecosystems based solely on the enhanced vegetation index and land surface temperature from MODIS. **Remote Sensing of Environment**, New York, v. 112, p. 1633–1646, 2008.
- SOARES, M. B. *et al.* Integrated production systems: an alternative to soil chemical quality restoration in the Cerrado-Amazon ecotone. **Catena**, Cremlingen, v. 185, p. 104279-104279, 2020.
- SOUZA, P.; MALHI, Y. Land use change in India (1700-2000) as examined through the lens of human appropriation of net primary productivity. **Journal of Industrial Ecology**, Cambridge, v. 22, n. 5, p. 1202-1212, ago. 2017.
- TAELMAN, S. E. *et al.* Accounting for land use in life cycle assessment: the value of NPP as a proxy indicator to assess land use impacts on ecosystems. **The Science of the Total Environment**, Amsterdam, v. 550, p. 143-156, 2016.
- THORNTHWAITE, C. W.; MATHER, J. R. **The water balance**. Centerton, NJ: Drexel Institute of Technology - Laboratory of Climatology, 1955. 104 p. (Publications in Climatology, v. 8, n.1).

- UGBAJE, S. U. *et al.* Assessing the spatio-temporal variability of vegetation productivity in Africa: quantifying the relative roles of climate variability and human activities. **International Journal of Digital Earth**, Abingdon, v. 10, n. 9, p. 879-900, 2016.
- WANG, Z. *et al.* Quantitative assess the driving forces on the grassland degradation in the Qinghai–Tibet Plateau, in China. **Ecological Informatics**, Cambridge, v. 33, p. 32-44, 2016.
- WEINZETTEL, J.; VAČKÁŘŮ, D.; MEDKOVÁ, H. Potential net primary production footprint of agriculture: a global trade analysis. **Journal of Industrial Ecology**, Cambridge, v. 23, n. 5, p. 1133-1142, 2019.
- WESSELS, K. J.; PRINCE, S. D.; RESHEF, I. Mapping land degradation by comparison of vegetation production to spatially derived estimates of potential production. **Journal of Arid Environments**, London, v. 72, n. 10, p. 1940-1949, 2008.
- WHITTAKER, R. H.; LIKENS, G. E. Primary production: the biosphere and man. **Human Ecology**, Ithaca, v. 1, p. 357-369, 1973.
- YU, D. Y. *et al.* Forest ecosystem restoration due to a national conservation plan in China. **Ecological Engineering**, Amsterdam, v. 37, n. 9, p. 1387-1397, 2011.
- ZHANG, X. *et al.* Spatial-temporal changes in NPP and its relationship with climate factors based on sensitivity analysis in the Shiyang River Basin. **Journal of Earth System Science**, Bangalore, v. 129, n. 1, p. 1-13, 2019.
- ZHOU, W. *et al.* Grassland degradation remote sensing monitoring and driving factors quantitative assessment in China from 1982 to 2010. **Ecological Indicators**, New York, v. 83, p. 303-313, 2017.
- ZHU, Q. *et al.* Remotely sensed estimation of Net Primary Productivity (NPP) and Its spatial and temporal variations in the Greater Khingan Mountain Region, China. **Sustainability**, Basel, v. 9, n. 7, p. 1213-1229, 2017.

**5.2 Artigo 2 - Estimativa da Produtividade Primária Líquida em ecossistemas agrícolas no Sul do Brasil utilizando o TVDI como parâmetro de estresse hídrico.**



## ESTIMATIVA DA PRODUTIVIDADE PRIMÁRIA LÍQUIDA EM ECOSISTEMAS AGRÍCOLAS NO SUL DO BRASIL UTILIZANDO O TVDI COMO PARÂMETRO DE ESTRESSE HÍDRICO

**RESUMO:** A Produtividade Primária Líquida (NPP) é um parâmetro importante para avaliar o incremento de carbono (C) pelas culturas agrícolas. Muitos modelos baseados na Eficiência de Uso da Luz (LUE) foram desenvolvidos para estimar a NPP de diversas regiões. A LUE dos diferentes ecossistemas é reduzida por fatores de estresse ambientais, como aqueles causados por restrições hídricas. No entanto, poucos trabalhos utilizaram dados remotos para estimar o coeficiente de estresse hídrico. Assim, o objetivo do trabalho foi avaliar o desempenho do modelo Carnegie-Ames-Stanford-Approach (CASA), a partir da introdução do Índice de Umidade da Superfície (TVDI) como coeficiente de estresse hídrico, para quantificar a dinâmica da NPP de ecossistemas agrícolas no noroeste do estado do Rio Grande do Sul. Para a estimativa de NPP foram utilizados dados meteorológicos obtidos do ERA-Interim e de estações meteorológicas de superfície. Ainda, para compor os modelos, foram utilizados dados obtidos do Landsat/OLI e Terra/MODIS relativos a temperatura superficial ( $T_s$ ) e ao Índice de Vegetação por Diferença Normalizada (NDVI). O TVDI foi ajustado para corresponder ao coeficiente original do modelo ( $W_\epsilon$ ) e então foram feitas simulações do modelo CASA utilizando os dois enfoques, ambas comparadas aos dados de superfície. Foram obtidos resultados similares entre os dados observados a campo e os dados modelados pelo modelo CASA. Houve correspondência do padrão espacial de NPP para os modelos testados, sendo observadas variações no padrão de distribuição espacial dos dados para cada método em função do detalhamento inerente a cada um. Também, o modelo CASA mostrou eficiência em representar a variação temporal dos dados de NPP para a região.

**KEY WORDS:** Modelagem, Google Earth Engine, Soja, ERA-Interim.

### 1. INTRODUÇÃO

As terras agrícolas geralmente estão localizadas em terras produtivas, com solos férteis e geralmente embutidas em um hidrossistema, que também oferece condições favoráveis à alta biodiversidade (Lorel et al., 2019). Em função disto, a importância da agricultura para o ciclo global de carbono (C) vem sendo muito estudada e já é bem reconhecida (Neumann e Smith, 2018). O C é absorvido através da fotossíntese (Pei et al., 2013) e a quantidade líquida de C assimilado é definida como sendo a Produtividade Primária Líquida (NPP) (Pei et al., 2013; Zhu et al., 2017; Liang et al., 2015; Potter; Klooster e Genovese, 2012).

A NPP funciona com um indicador importante do status de crescimento da vegetação e da saúde do ecossistema, exercendo uma influência importante sobre o ciclo de carbono da

biosfera global (Liang et al., 2015; Running et al., 2004) e funcionando como um indicador dinâmico da situação de degradação do solo (Zhou et al., 2017). Embora a NPP possa ser medida diretamente quantificando seus compartimentos (Scurlock e Oslen, 2002) esta abordagem torna-se limitada pela considerável carga de trabalho, período de investigação necessário (Fang; Wang e Shao, 2015).

Assim, diversos modelos de simulação de NPP foram amplamente relatados na literatura durante as últimas décadas (Gang et al., 2018), muitos deles foram desenvolvidos para a estimativa de características biofísicas da vegetação através de dados remotos (Peng e Gitelson, 2012). Mesmo assim, um grande número desses modelos em geral captura apenas a agricultura ou apenas certos tipos de culturas (Elliott et al., 2015; Fang; Wang e Shao, 2015). O uso de um único modelo consistente, capaz de fornecer informações sobre a absorção de C por florestas, áreas de cultivo e outros tipos de cobertura da terra, como savanas e matagais, evitaria desvios decorrentes de dados de entrada e diferenças causadas pelos diferentes métodos de amostragem ou modelagem (Neumann e Smith, 2018).

Para obter informações espacialmente representativas sobre a troca de carbono em grande escala pode-se aplicar técnicas e modelos que usam informações geradas por sensoriamento remoto, o que é especialmente útil para análises em grandes áreas por períodos de tempo relativamente longos (Gao et al., 2013). Uma maneira alternativa de estimar a NPP em escalas mais amplas são os modelos baseados na Eficiência de Uso da Luz (LUE), devido aos parâmetros prontamente acessíveis derivados de dados oriundos de satélite (Gang et al., 2018; Kross; Seaquist e Roulet, 2016). Entre os modelos que utilizam o conceito da LUE, está o modelo Carnegie-Ames-Stanford-Approach (CASA), proposto por Potter et al. (1993). O modelo, que é bastante utilizado nas estimativas de NPP usando imagens de satélite vem sofrendo aperfeiçoamentos desde sua elaboração. Segundo Bao et al. (2016), o conceito fundamental de NPP para uma dada localização  $x$  e tempo  $t$  neste modelo é uma variante do modelo LUE originalmente proposto por Monteith (1972), dado pela equação 1, em que a NPP ( $\text{gC m}^{-2} \text{ano}^{-1}$ ) é o produto da radiação fotossinteticamente ativa (PAR) ( $\text{MJ m}^{-2}$ ) pela porção desta absorvida pela vegetação verde (FPAR) e pela eficiência de conversão da radiação em biomassa, a LUE ( $\epsilon$ ) ( $\text{gC MJ}^{-1}$ ):

$$NPP_{(x,t)} = PAR_{(x,t)} \times FPAR_{(x,t)} \times \epsilon_{(x,t)} \quad (1)$$

sendo que PAR x FPAR é relativamente fácil de estimar e resulta na radiação fotossinteticamente ativa absorvida pelas plantas (APAR). APAR (x ,t) e  $\epsilon$  (x ,t) são calculados usando as equações (2) e (3) , respectivamente.

$$APAR_{(x,t)} = RG_{(x,t)} \times FPAR_{(x,t)} \times 0,5 \quad (2)$$

onde RG (x,t) é a radiação solar total ( $MJ m^{-2}$ ) do pixel x no tempo t , 0,5 representa a proporção da radiação solar total disponível para a vegetação (Zhou et al., 2013, Piao et al., 2005).

$$\epsilon_{(x,t)} = \epsilon_{máx} \times T_{\epsilon 1(x,t)} \times T_{\epsilon 2(x,t)} \times W_{\epsilon(x,t)} \quad (3)$$

onde  $T_{\epsilon 1}$  (x,t) e  $T_{\epsilon 2}$  (x,t) denotam os coeficientes de estresse de temperatura na eficiência de uso da luz,  $W_{\epsilon}$ (x,t) é o coeficiente de estresse hídrico que indica a redução na eficiência de uso de luz causada pelo fator umidade, e  $\epsilon_{max}$  denota a máxima eficiência de conversão de biomassa em carbono, sob condições ideais e, variando para cada tipo de vegetação (Zhu et al., 2017).

No modelo CASA original, o coeficiente de estresse hídrico ( $W_{\epsilon(x,t)}$ ) é calculado através da introdução de diversos parâmetros do solo, que muitas vezes são de difícil aquisição para determinadas áreas (Yu et al., 2011). Além disso, não existem muitas informações sobre o uso do sensoriamento remoto nas estimativas deste parâmetro, ao contrário dos demais parâmetros do modelo que podem ser produzidas totalmente de dados remotos (Bao et al., 2016). Uma alternativa a isto, é o uso do Índice de Umidade da Superfície (TVDI). Este índice foi desenvolvido por Sandholt; Rasmussen e Andersen (2002) e está baseado em uma parametrização empírica da relação entre Temperatura Superficial ( $T_s$ ) e o Índice de Vegetação por Diferença Normalizada (NDVI), e que vem sendo bastante utilizado (Chen et al., 2011; Schirmbeck; Fontana e Schirmbeck, 2018) para monitorar as condições de umidade da superfície. Para o Rio Grande do Sul, Schirmbeck; Fontana e Schirmbeck, (2018), ao avaliarem diversos anos, tipos de cobertura e sensores remotos, obtiveram um bom desempenho do índice.

Diante deste contexto, o objetivo do trabalho foi avaliar o desempenho do modelo CASA, a partir da introdução do índice TVDI como coeficiente de estresse hídrico, para quantificar a dinâmica da NPP de ecossistemas agrícolas no noroeste do estado do Rio Grande do Sul.

## 2. MATERIAL E MÉTODOS

### 2.1 Área de estudo

A área de estudo compreendeu a mesorregião agrícola do Noroeste do Estado do Rio Grande do Sul, localizada ao sul do Brasil. No Estado, a soja é a cultura que ocupa a maior área de cultivo, com 4,8 milhões de hectares, totalizando uma produção de cerca de 19,2 milhões de toneladas (safra 2016/2017). Já os dados de referência para avaliação das metodologias propostas, ditos dados de superfície, foram obtidos de uma área experimental, cultivada com a cultura da soja (safra 2017/2018), cultivar de soja DM 5958 RSF IPRO. A área experimental utilizada para o trabalho foi uma lavoura comercial, com aproximadamente 40 ha, cedida a Embrapa Trigo, localizada no município de Carazinho, localizado no norte do Estado do Rio Grande do Sul ( $28^{\circ}13'43.89''$  S e  $52^{\circ}54'15.93''$  O, elevação 560m) (Figura 8).

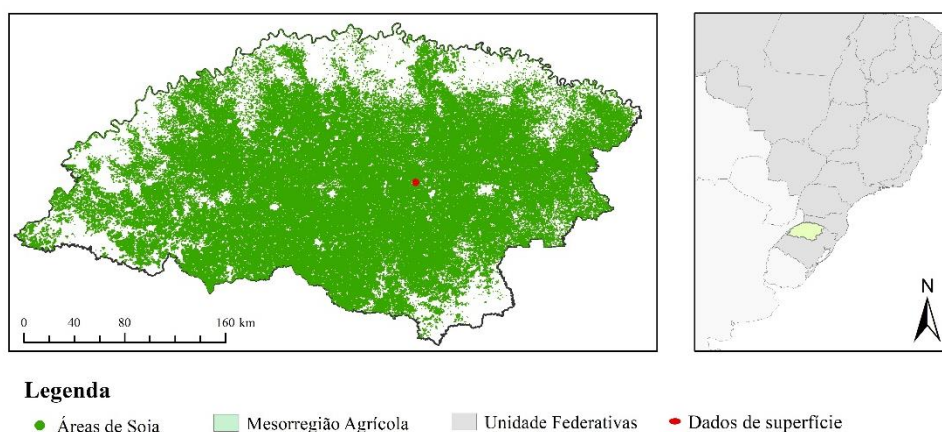


Figura 8 – Área cultivada com soja em 2017 na mesorregião agrícola do Noroeste do Estado do Rio Grande do Sul e localização da área experimental no município de Carazinho.

### 2.2 Conjunto de Dados e Pré-processamento

#### 2.2.1 Dados meteorológicos

A base de dados incluiu uma das mais recentes reanálises atmosféricas globais, o ERA-Interim, obtido através de uma API (*Application Programming Interface*), disponibilizada pelo ECMWF (*European Centre for Medium-Range Weather Forecasts*). Os dados foram extraídos através de scripts usando IDL (*Interactive Data Language*) e incluíram dados meteorológicos mensais de precipitação pluvial (mm), temperatura do ar ( $^{\circ}$ C), umidade relativa do ar (%),

velocidade do vento ( $\text{m s}^{-1}$ ) e radiação solar global ( $\text{MJ m}^{-2}$ ). A partir destes dados foi realizado o cálculo do balanço hídrico meteorológico, através da metodologia proposta por Thornthwaite e Matter (1995) e Evapotranspiração Potencial (ETP) calculada pelo método de Pennam e Monteith (1972). A Capacidade de Armazenamento de Água disponível (CAD) foi definida como sendo 75 mm para Latossolos Vermelhos, característicos da região, com teor de argila superior a 35%, conforme observado por Cunha et al. (2001).

Foram também obtidos os mesmos dados meteorológicos das Estações Meteorológicas de superfície localizadas em Cruz Alta, Santo Ângelo e Passo Fundo, pertencentes ao Instituto Nacional de Meteorologia (INMET), e presentes na mesorregião de estudo de forma a derivar a ETP para toda a região.

### 2.2.2 Dados de Sensores Remoto

Para executar o modelo CASA, foram utilizados dois conjuntos de dados oriundos de satélites cobrindo a área experimental e a mesorregião em estudo (Fig 8). Abrangendo a área experimental, foram obtidas 5 imagens (20/11 em 2017 e 07/01, 08/02, 24/02 e 12/03 em 2018) do satélite Landsat 8 – sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*), de Reflectância de Superfície (bandas 4 e 5) e Temperatura Superficial (banda 10 e 11) com resolução espacial de 30m e 100m, respectivamente. Já para as análises da mesorregião, foram obtidos dados de produtos oriundos do sensor MODIS (*Moderate-Resolution Imaging Spectroradiometer*) a bordo do satélite Terra, incluindo o índice NDVI do produto MOD13Q1 e dados de Temperatura de Superfície do produto MOD11A2, com resolução espacial de 250 e 1.000m. Neste caso, foram usadas 10 imagens espaçadas em 16 dias de novembro a março.

As imagens Landsat para compor o TVDI foram baixadas da URL [earthexplorer.usgs.gov](http://earthexplorer.usgs.gov), enquanto que os produtos do MODIS foram baixados da URL [search.earthdata.nasa.gov](http://search.earthdata.nasa.gov). As bases de dados do Era-Interim e do TVDI foram importadas para o ambiente de trabalho da plataforma Google Earth Engine (GEE) e, posteriormente, interpolados para servirem como dados de entrada para o cálculo do coeficiente de estresse hídrico. Os dados originalmente com resolução espacial diferentes, (ERA-Interim, dados de Ts e TVDI) foram reamostrados utilizando-se o método Kriging para uma resolução de 30 e 250m, para corresponder com os dados de NDVI da área experimental e mesorregião, respectivamente,

tanto temporal quanto espacialmente. Além disso, foram obtidos dados de NDVI diretamente da plataforma do GEE para compor o modelo.

### 2.2.3 Dados de superfície

A Matéria Seca (MS) acumulada pela soja foi determinada semanalmente, da emergência das plantas ao final do ciclo. Para isso foram coletadas quatro repetições de um metro linear de plantas, em secções de linhas no transecto central da área reservada para avaliações. A biomassa verde foi colocada em embalagens de papel e levada para estufa para secagem de material vegetal na temperatura de 70°C até massa constante. A MS foi pesada e massa a foi expressa em g m<sup>-2</sup>. Após a maturação fisiológica foram feitas quatro amostragens de biomassa de 9 m<sup>2</sup> para determinação da produtividade de grãos. Os grãos de cada parcela foram separados das impurezas e pesados. A produtividade de grãos foi corrigida a 13% de umidade e calculada para uma área de um hectare.

O incremento de biomassa acima do solo foi convertido em conteúdo de carbono usando um fator de conversão de 0,40 (baseado em Pillon; Mielniczuk e Martin Neto, 2004), obtendo-se, assim, a NPP observada das medições baseadas em dados de superfície (NPP<sub>real</sub>%CMS).

Também dos dados de superfície foi obtido a LUE<sub>máx</sub> através do ajuste de uma regressão linear dos dados de MS e APAR medidos e determinação do coeficiente angular da reta ajustada. Este coeficiente também foi multiplicado por 0,4 para se obter a eficiência de uso da luz de 0,926 gC MJ<sup>-1</sup>.

## 2.3 Método

### 2.3.1 Obtenção do coeficiente de estresse hídrico

Foram comparadas duas formas alternativas de obter o coeficiente de estresse hídrico no modelo CASA. Inicialmente o  $W_{\varepsilon(x,t)}$  foi definido como originalmente foi definido:

$$W_{\varepsilon 0}(x, t) = 0,5 + 0,5 \times \frac{EET(x,t)}{PET(x,t)} \quad (4)$$

em que EET e PET representam a evapotranspiração real e potencial (mm), respectivamente. Neste modelo, o valor de  $W_{\varepsilon}(x,t)$  varia, geralmente, de 0,5 para ecossistemas muito áridos a 1 para ecossistemas muito úmidos (Bao et al., 2016).

Neste trabalho, num segundo enfoque, o  $W_{\varepsilon}(x,t)$  foi calculado usando o índice TVDI, o qual permite normalizar a condição de água da vegetação entre valores que variam de 0 para ecossistemas muito úmidos a 1 para ecossistemas muito secos, obtido através da Equação 5:

$$TVDI = \frac{T_s - T_s^{mín}}{a + b \times NDVI - T_s^{mín}} \quad (5)$$

onde  $T_s^{mín}$  é a temperatura de superfície mínima no triângulo, que define a borda úmida,  $T_s$  é a temperatura de superfície observada num dado pixel e  $a$  e  $b$  são os parâmetros que definem a borda seca, a qual é definida a partir do ajuste da regressão linear entre os dados de  $T_{mín}$  e NDVI (Schirmbeck; Fontana e Schirmbeck, 2018).

De forma a compatibilizar os enfoques do coeficiente de estresse hídrico, os valores do TVDI foram recalculados, invertendo-o para corresponder à faixa de valores do  $W_{\varepsilon}$ , da seguinte forma:

$$W_{\varepsilon TVDI} = 1 - \left( \frac{T_s - T_s^{mín}}{a + b \times NDVI - T_s^{mín}} * 0,5 \right) \quad (6)$$

em que a constante 1 garante que os valores variem de 0 para ecossistemas secos e 1 para ecossistemas muito úmidos, semelhante ao termo original do modelo CASA (Potter et al., 1993).

### 2.3.2 Processamento e avaliação dos modelos de NPP

Inicialmente, os valores de NPP modelados pelo modelo CASA, com  $W_{\varepsilon}$  original ( $NPP_{real\_W_{\varepsilon 0}}$ ) e com uso do TVDI ( $NPP_{real\_W_{\varepsilon TVDI}}$ ), foram comparados com os dados de superfície da área experimental, a fim de avaliar a precisão das estimativas e o desempenho do modelo CASA. Foram avaliados o coeficiente de determinação ( $R^2$ ) e o erro quadrático médio (RMSE) entre os dois grupos de dados.

Posteriormente, o modelo CASA (Equação 1) foi aplicado a área cultivada com soja na Mesorregião Agrícola do noroeste do estado do RS utilizando os dados obtidos dos produtos

MODIS. Então, os coeficientes  $W_{\epsilon 0}$  e  $W_{\epsilon TVDI}$  foram espacializados para verificar as principais diferenças existentes entre estes nas estimativas finais de NPP.

Para obter as áreas de soja cultivadas na região foi utilizado o método de extração de máscaras de cultivo. O método, já testado no RS (Santos et al., 2014), consiste na geração de imagens de mínimo e máximo NDVI referentes ao estádios iniciais e desenvolvimento pleno da cultura da soja, respectivamente, e, através destas, a geração de uma imagem diferença, a qual é utilizada no cálculo das áreas. Com a imagem diferença foram definidas as máscaras de cultivo da soja, utilizando o limiar de corte na imagem diferença de 0,39, que gerou uma área de cultivo de 3.103.093 ha. A área obtida foi similar aos dados de área semeada com soja, de 3.094.664 ha, disponibilizada pelo Sistema Recuperação Automática (SIDRA) do Instituto Brasileiro de Geografia e Estatística (IBGE - <https://ibge.gov.br>), de, para Censo Agropecuário de 2017.

### **3. RESULTADOS**

#### **3.1 Avaliação da precisão dos modelos frente aos dados de superfície**

Ambos métodos testados apresentaram resultados bastante consistentes quando comparados aos dados de superfície (Figura 9). Observa-se uma tendência do modelo  $NPP_{real\_W_{\epsilon TVDI}}$  em subestimar a NPP, enquanto que no modelo original  $NPP_{real\_W_{\epsilon 0}}$  mostrou tendência em superestima-los, mas ambos com desempenho similares ( $NPP_{real\_W_{\epsilon TVDI}}$  com  $r = 0,99$  e  $NPP_{real\_W_{\epsilon 0}}$  com  $r = 0,99$ ) (Figura 9). Os RMSEs também foram similares 29,58 e 22,89  $gC\ m^{-2}$ , respectivamente para  $NPP_{real\_W_{\epsilon TVDI}}$  e  $NPP_{real\_W_{\epsilon 0}}$ .



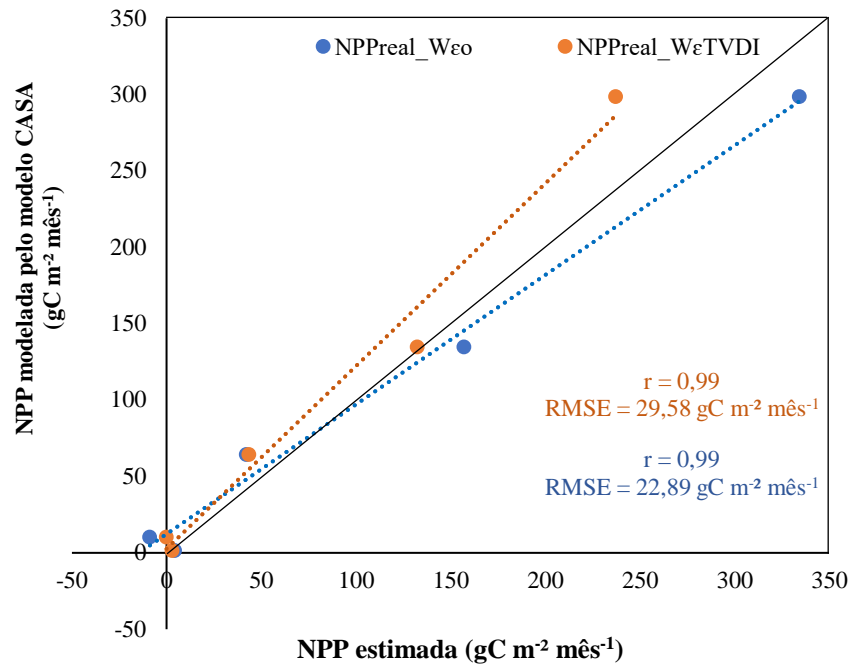


Figura 9 – Dispersão entre a NPP modelada NPPreal\_WeTVDI e NPPreal\_Weo observada NPPreal\_campo. Obtidas através de imagens e estimadas a partir de dados de superfície, respectivamente. Valores de coeficiente de correlação (R) e do erro quadrático médio (RMSE)

Quando analisado o transcurso ao longo do ciclo da NPP para os dois modelos testados em relação aos dados de superfície, é possível observar que houve correspondência (Figura 10). Observa-se que no mês de fevereiro houve a diferença maior entre os modelos testados e a NNP observada, particularmente, para o modelo NPPreal\_WeTVDI. Mesmo assim, a semelhança entre os dados na maioria dos meses, indica que ambos os modelos testados foram semelhantes para representar as variações mensais de NPP. A maior diferença observada entre este modelo e os dados obtidos de superfície, foi de aproximadamente  $75 \text{ gC m}^{-2}$ .

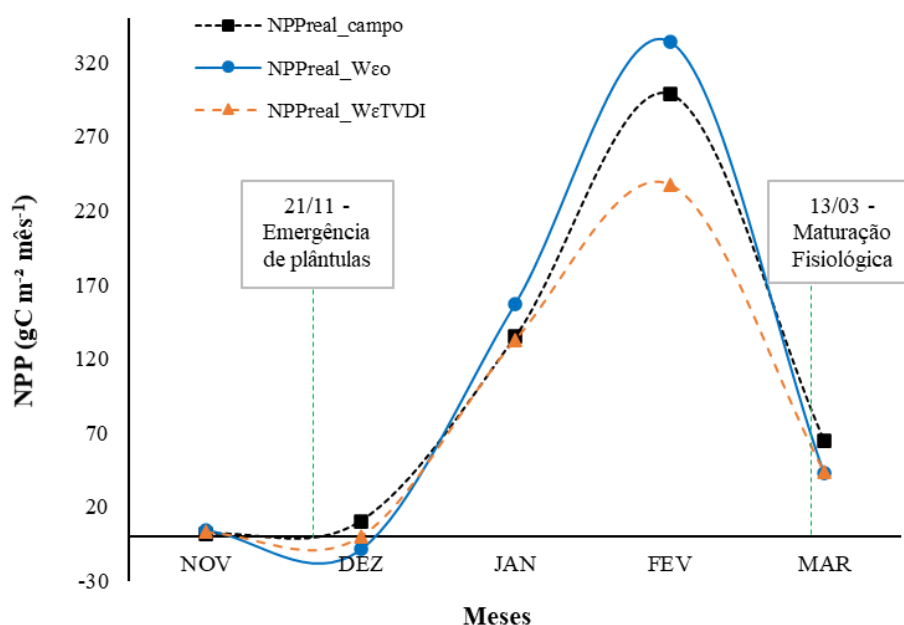


Figura 10 - Comparação do perfil temporal entre a NPP observada a campo e modelada pelo modelo CASA utilizando o TVDI  $NPP_{real\_WeTVDI}$  e utilizando  $We$  original  $NPP_{real\_Weo}$ .

### 3.2 Padrão espacial na área experimental

Os mapas de estimativa da NPP estão apresentados na Figura 11 e forneceram informações relevantes para avaliar o padrão de distribuição da NPP na área experimental, o qual na maioria dos meses foi similar para os dois modelos.

Observa-se que os meses de novembro, janeiro e março, possuem uma distribuição bastante similar, indicando que as estimativas feitas pelos modelos testados são consistentes e comparáveis entre si. As maiores diferenças foram encontradas no mês de fevereiro, o que coincide com o mês em que o cultivo da soja atingiu o desenvolvimento máximo e, conseqüentemente, uma maior produção de biomassa e incremento de carbono. As diferenças estão associadas ao uso do TVDI como coeficiente de estresse hídrico, o qual permite representar mais detalhadamente o padrão espacial, possibilitando valores de saída de NPP com maior representação da variabilidade espacial.

Mesmo sendo próximas as estimativas mensais de NPP, o total acumulado ao longo do ciclo apresentou valores distintos entre os modelos. Foram obtidos valores de NPP total para o ciclo da cultura da soja de 441,34 e 566,33  $gC\ m^{-2}$  somando os valores de novembro a março, para o modelo  $NPP_{real\_WeTVDI}$  e  $NPP_{real\_Weo}$ , respectivamente, chegando a uma diferença entre eles superior a 100  $gC$ .

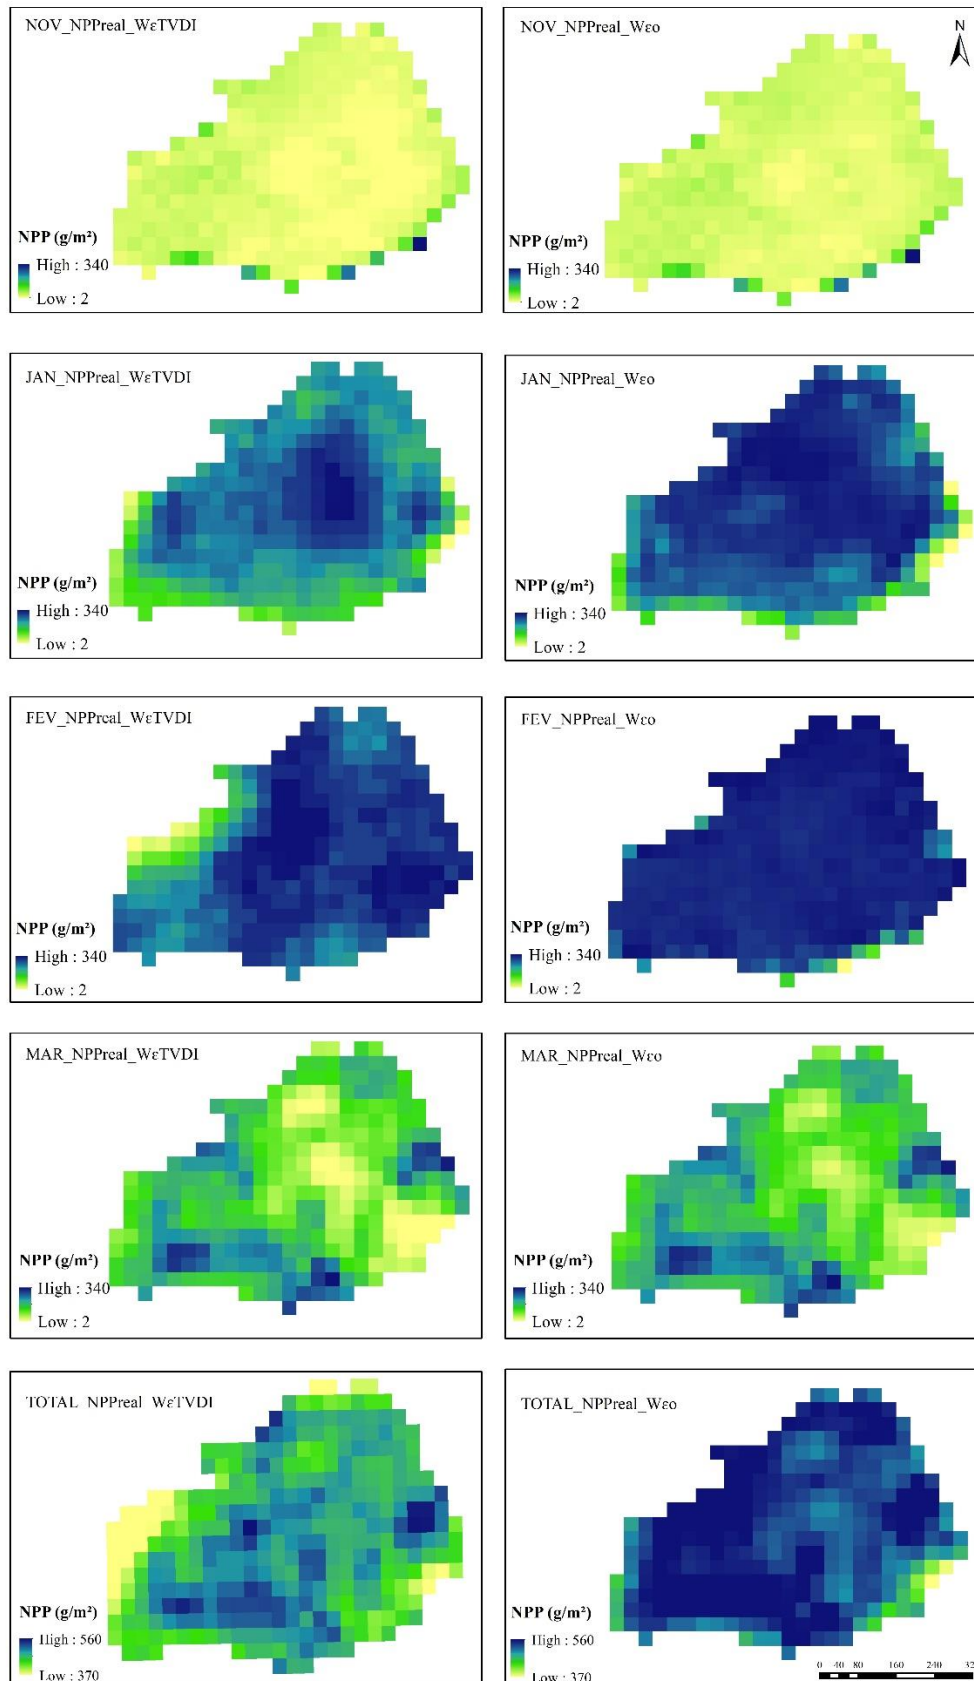


Figura 11 – Distribuição espacial das estimativas de Produtividade Primária Líquida (NPP) mensais e acumulado ao longo do ciclo para o modelo NPPreal\_WeTVDI (esquerda) e NPPreal\_Weo (direita)

Em função da cobertura de nuvens e da limitada resolução temporal do satélite Landsat, somente quatro imagens estavam disponíveis nesta etapa do trabalho. Mesmo assim, foi possível observar as variações de NPP no ciclo da cultura. Verifica-se que houve um pequeno incremento de carbono no desenvolvimento inicial, o qual aumentou conforme a cultura cresceu e se desenvolveu e no final do ciclo voltou a reduzir os valores estimados de NPP em função da maturação dos grãos e senescência das plantas (Figura 11).

### **3.3 Padrão espacial na mesorregião agrícola**

Ao espacializar os modelos para as áreas ocupadas com soja na mesorregião agrícola do Noroeste do Estado do Rio Grande do Sul, observa-se, conforme esperado, que os valores de NPP obtidos para o modelo  $NPP_{real\_W_{\epsilon_0}}$  foram em geral superiores quando comparados aos valores do modelo  $NPP_{real\_W_{\epsilon_{TVDI}}}$  (Figuras 12 e 13).

Embora os mapas gerados sejam bastante similares, existem algumas pequenas diferenças no padrão espacial quando estes são comparados. Observa-se, por exemplo, que nos mapas de novembro, o modelo de  $NPP_{real\_W_{\epsilon_0}}$  apresentou algumas regiões com valores mais baixos quando comparados ao modelo de  $NPP_{real\_W_{\epsilon_{TVDI}}}$ . Enquanto que no restante do período de estudo, os valores de  $NPP_{real\_W_{\epsilon_0}}$  sempre foram maiores que os de  $NPP_{real\_W_{\epsilon_{TVDI}}}$ . É possível observar alguns problemas nas imagens, como manchas no mês de dezembro 2 em ambos os modelos, e algumas falhas no mês março 2 para o modelo de  $NPP_{real\_W_{\epsilon_0}}$ .



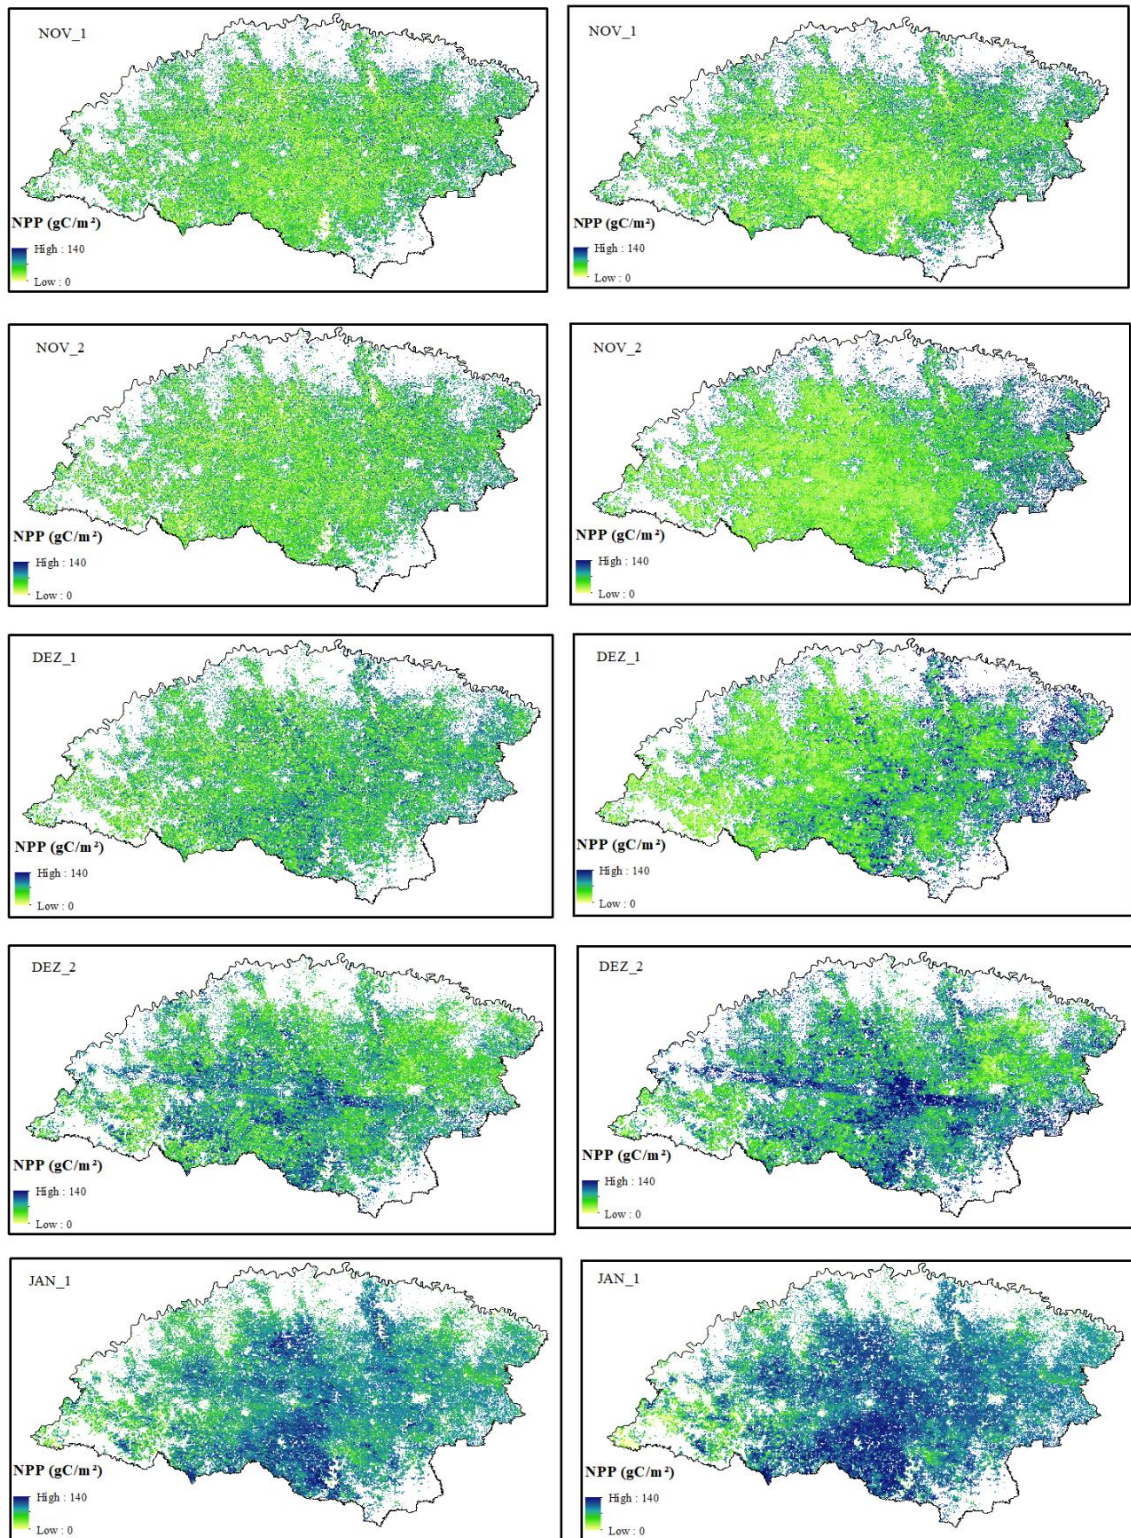


Figura 12 – Espacialização do modelo NPPreal\_We<sub>TVDI</sub> (esquerda) e NPPreal\_We<sub>o</sub> (direita) para a mesorregião agrícola do noroeste do estado do Rio Grande do Sul, utilizando dados MODIS.



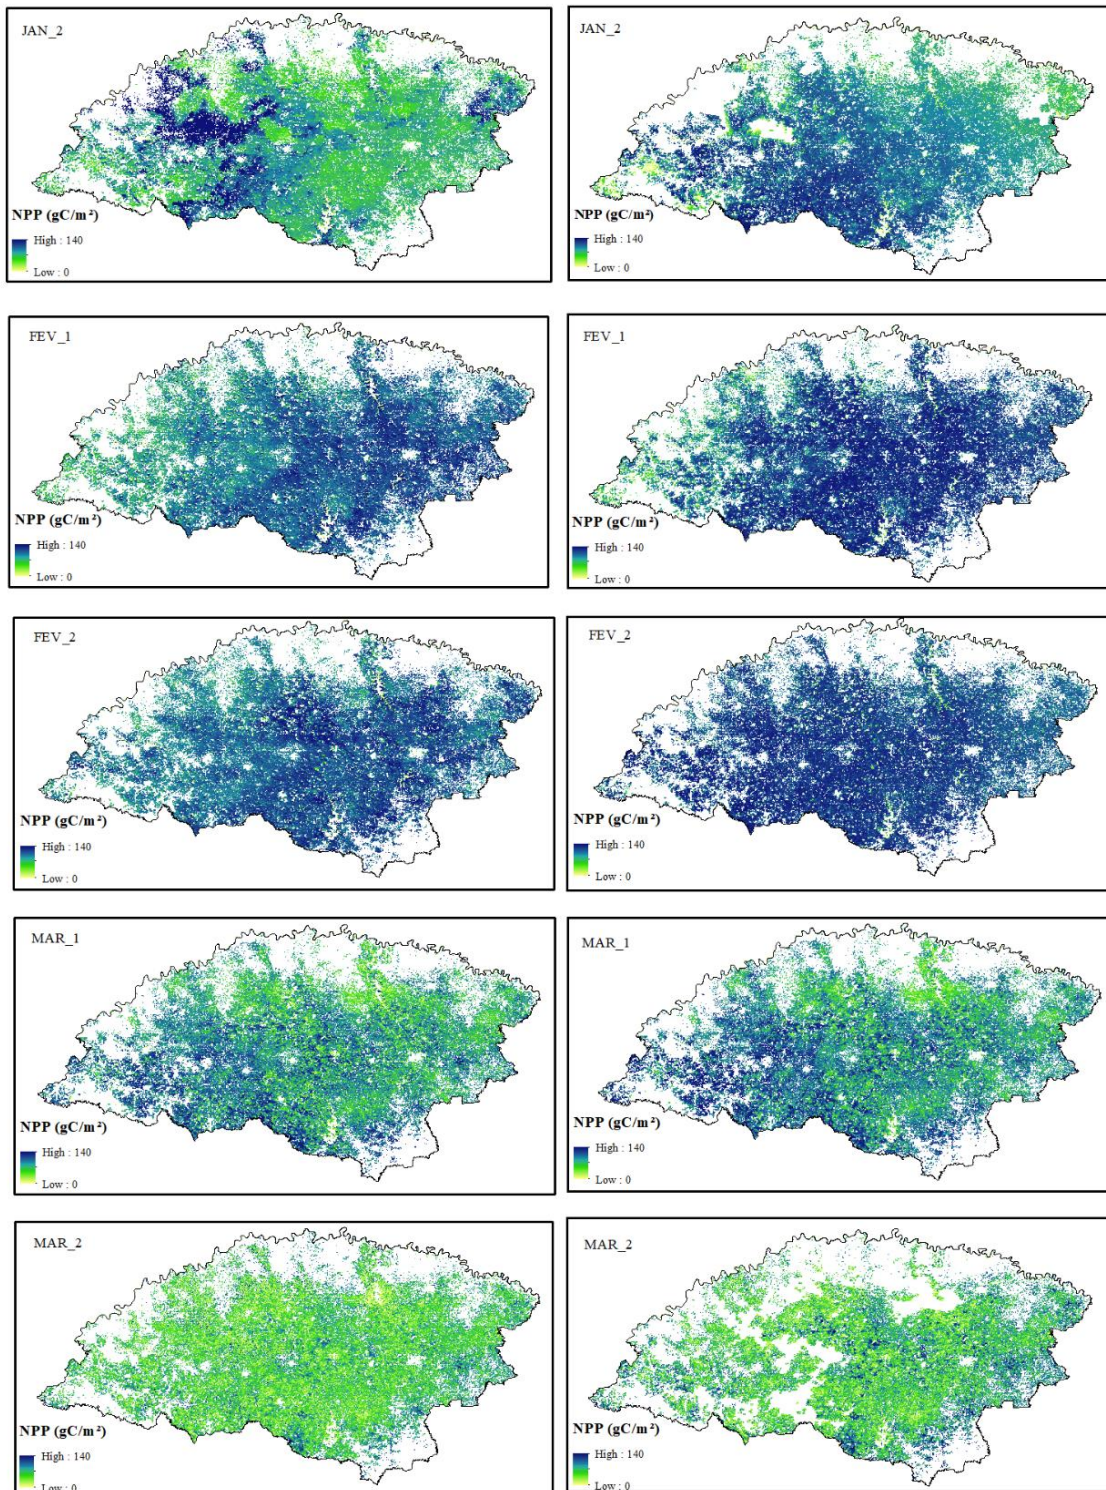


Figura 13 – Espacialização do modelo  $NPP_{real\_WeTVDI}$  (esquerda) e  $NPP_{real\_Weo}$  (direita) para a mesorregião agrícola do noroeste do estado do Rio Grande do Sul, utilizando dados MODIS.

Além da espacialização, foi possível quantificar a NPP média e sua variabilidade para toda mesorregião noroeste do RS, de forma contínua a cada 16 dias, ao longo da safra de soja (Figura 14).

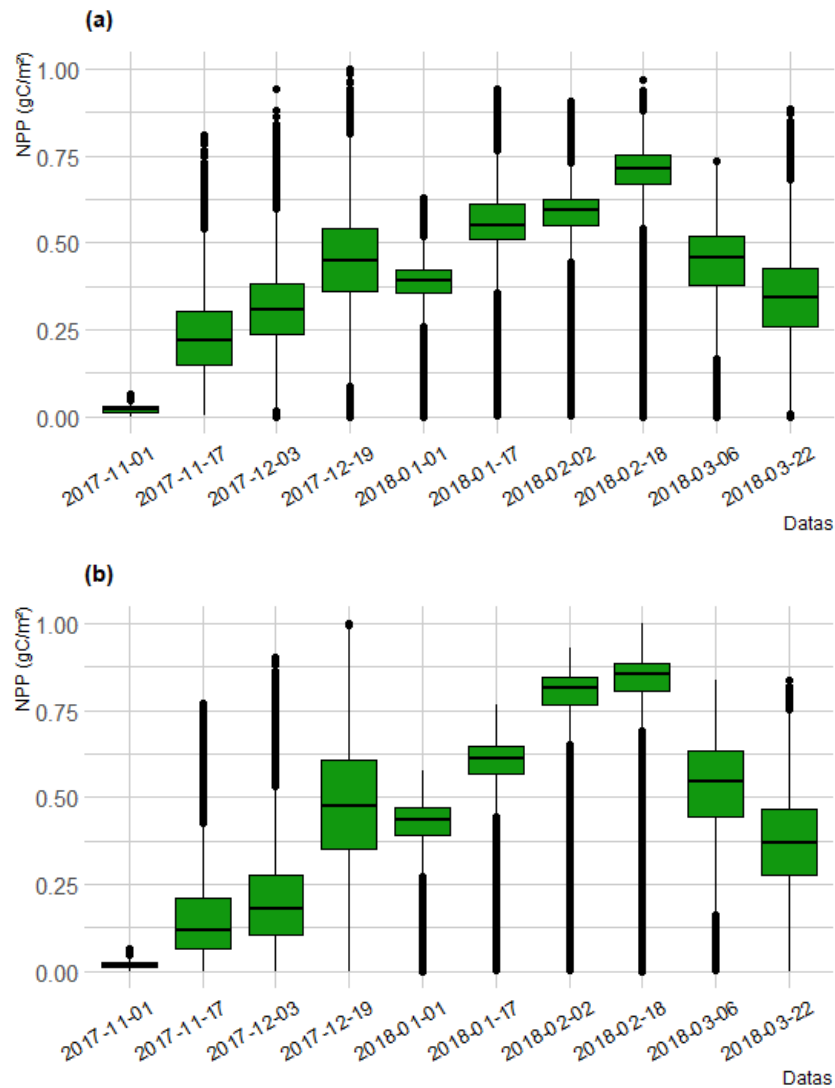


Figura 14 – Diagrama de caixas do perfil de NPP ao longo do ciclo de cultivo da soja para os modelos  $NPP_{real\_W_{\epsilon T V D I}}$  (a) e  $NPP_{real\_W_{\epsilon o}}$  (b). As caixas delimitam o primeiro e o terceiro percentil do conjunto de dados, e a linha centralizada sobre elas indica a mediana referente a estes. As linhas contínuas indicam os demais dados dentro do conjunto e os círculos indicam os outliers ou pontos que estão afastados demais do conjunto ou inconsistentes. Dados normalizados.

## 4. DISCUSSÃO

### 4.1 Avaliação da precisão do modelo CASA modificado

Os valores de NPP para os modelos testados,  $NPP_{real\_W_{\epsilon o}}$  e  $NPP_{real\_W_{\epsilon T V D I}}$ , foram bastante similares. Foram obtidos  $R^2$  e RMSE semelhantes evidenciando que ambos os modelos podem ser utilizados em estimativas de NPP, principalmente, por estarem altamente

correlacionados com os dados obtidos na área experimental (Figura 9). Importante salientar ainda que não foram obtidas melhorias significativas nas estimativas com a introdução do coeficiente  $W_{\epsilon}$  obtido com os dados do TVDI. Trabalhos que abordaram propostas similares para obtenção do  $W_{\epsilon}$ , baseado somente em dados de sensoriamento remoto, como o de Bao et al. (2016), também não obtiveram grandes melhorias. Mesmo assim, os autores consideram o fato de a estimativa do  $W_{\epsilon}$  usando imagens se torna bastante simplificada, possibilitando a estimativa de NPP mais facilmente aplicada em diversas regiões de estudo, mesmo com carência de estações meteorológicas.

#### **4.2 Distribuição da NPP ao longo do ciclo da soja**

O padrão de variação ao longo dos meses do ciclo da soja, de ambos modelos testados, foi coerente com os dados observados de superfície, mostrando os menores valores de NPP no início do ciclo da cultura, aumentando conforme a cultura vai se desenvolvendo e reduzindo novamente ao final do ciclo (Figuras 11, 12 e 13). Dado o bom desempenho dos modelos em simular a NPP frente aos valores de superfície, pode-se recomendar o uso dos mesmos para estimar a NPP da soja no sul do Brasil, já que há uma grande similaridade dos cultivos e condições ambientais nesta região.

Observando os mapas gerados ao longo da safra estudada (Figura 11), é possível observar que houve uma melhoria no detalhamento da variabilidade espacial do modelo  $NPP_{real\_W_{\epsilon TVDI}}$  em relação ao  $W_{\epsilon}$  original, principalmente nos meses de janeiro e fevereiro, meses de máximo desenvolvimento da cultura. O uso de imagens Landsat possibilitou um detalhamento da NPP dentro da área experimental em estudo, dada a compatibilidade com a resolução espacial das imagens. Isto é importante na medida em que áreas de soja cultivadas no sul do Brasil muito seguidamente são superiores aos 40ha da área experimental. No entanto, houve certa dificuldade no acompanhamento sistemático destas variações, em função da baixa resolução temporal e cobertura de nuvens presentes em boa parte das cenas.

Quando especializadas para áreas maiores (Figuras 12 e 13), o uso de sensores orbitais de menor resolução espacial e maior resolução temporal, se constitui uma alternativa. É neste sentido que foi testado o uso do sensor MODIS, o qual possibilita um monitoramento periódico dos cultivos. A principal vantagem do uso deste sensor é a disponibilidade de produtos com qualidade e frequência temporal adequada para o acompanhamento de safras, minimizando as dificuldades na obtenção de perfis espaço-temporais de áreas agrícolas devido a cobertura de



nuvens (Santos et al., 2014). Assim, uma melhor caracterização do perfil de NPP ao longo do ciclo pode ser produzido corroborando com os dados espacializados (Figura 14). Na safra em estudo obteve-se 10 cenas MODIS disponíveis, bem superior as quatro utilizadas quando da análises com as imagens Landsat.

Foi observada, portanto, alta correspondência espacial entre os mapas gerados pelos modelos, em ambas abrangências espaciais da área experimental e da mesorregião (Figuras 11, 12 e 13), indicando que o método CASA modificado tem um grande potencial para ser utilizado como método alternativo nas estimativas de NPP. As principais diferenças observadas ocorreram em fevereiro, mês de máximo desenvolvimento da cultura da soja, em que os valores obtidos pelo modelo CASA baseado em  $W_e$  excedem os valores do modelo CASA baseado no TVDI. Tamaña diferença, também foi observada nos perfis de NPP mensais. Neste mês, as estimativas do modelo CASA baseado em  $W_e$  superestimam os valores observados de superfície, enquanto as estimativas do modelo CASA baseado no TVDI subestimam os dados observados (Figura 10). Essa diferença, provavelmente esteja associada ao fato do NDVI apresentar saturação no máximo desenvolvimento da cultura, podendo interferir nas estimativas de NPP quando do uso do TVDI.

### **4.3 Análise do coeficiente de estresse hídrico**

$W_e$  leva em consideração o impacto complexo do estresse hídrico na fotossíntese (isto é, mudanças na condutância estomática, potencial da água nas folhas, etc.) causadas pela umidade do solo e/ou déficits de água na atmosfera (Robertson; Suyker e Xiao, 2015). No modelo original, o coeficiente de estresse hídrico foi calculado em função da Evapotranspiração real (ET). Mesmo existindo estreita relação de acoplamento entre a transpiração da planta e a fotossíntese (Chapin III; Matson e Vitousek, 2012) existem incertezas relativamente grandes nos modelos de estimativa da ET (Chen et al., 2014). Em seu trabalho, Chen et al. (2014) explicaram que parte dos modelos, além de apresentarem suposições simplificadoras, foram projetados, na maioria dos casos, para diferentes aplicações e com diferentes formulações dos processos. Assim, mesmo utilizando um modelo mais complexo de estimativa de ET, este pode conter incertezas nas estimativas devido a inserção de parâmetros inerentes a formulação do modelo. Quaisquer ruídos ou erros nas simulações de ET, portanto, seriam transferidos para as previsões de GPP, ou NPP, e reduziriam ainda mais o desempenho do modelo baseado na LUE (Yuan et al., 2014). Assim, mesmo sendo de fácil implementação, todas as variáveis

relacionadas à água usadas no modelo LUE possuem algumas incertezas em termos de restrição de disponibilidade de água (Yuan et al., 2015).

O presente estudo foi conduzido em um ano em que ocorreu pequena restrição hídrica, o que pode ter acarretado em um  $W_e$  que não tenha representado precisamente os estresses causados pelas variações de água para a planta ao longo do cultivo. Já o TVDI, ao considerar as variações de verdor e de temperatura da planta, pode ter conseguido representar de forma mais apropriada estas pequenas variações. Son et al. (2012) explicam que como o NDVI fornece pouca informação sobre o teor de água no solo e a TS está relativamente relacionada ao estresse hídrico, a combinação entre eles pode fornecer melhores informações sobre as condições de vegetação e umidade na superfície. Assim, o TDVI, que foi testado no presente estudo, mostrou potencial de ser usado como um indicador da umidade da superfície, já que as informações contidas nos comprimentos de onda do termal e do V/NIR (através do NDVI) provaram ser adequadas e complementares para monitorar o estado da vegetação e o estresse hídrico (Sandholt; Rasmussen e Andersen, 2002).

Além disso, o uso do sensoriamento remoto pode ajudar a capturar estas pequenas mudanças hídricas e seus efeitos sobre a vegetação de forma mais preciso e detalhada do que estimativas de ET através de modelos baseados em processos. Isso ainda se agrava quando do uso de dados meteorológicos medidos em superfície, já que existe uma pequena densidade de Estações Meteorológicas para cobrir grandes áreas, o que acaba não representando precisamente o efeito climático em locais onde há carência destas informações. Além disso, outras incertezas podem ser produzidas no processo de interpolação espacial dos dados meteorológicos para regiões em que não existem dados medidos, podendo trazer prejuízos nos resultados finais de NPP.

Outra vantagem do uso do TVDI, está no uso do índice de vegetação que consegue capturar a variação do verdor e, segundo Yuan et al. (2015), a maturidade do dossel, monitorando as mudanças fenológicas. Isso se torna importante para avaliar o efeito da fenologia foliar (ou idade da folha) na fotossíntese no nível do dossel, pois as folhas jovens não têm a mesma capacidade fotossintética que as folhas maduras (Reich; Walters e Ellsworth, 1991). As estimativas de sensoriamento remoto podem, portanto, agregar ainda mais informações às estimativas de NPP e torna-las mais precisas e semelhantes aos dados de superfície.

Por fim, sabe-se que definir uma função de sensoriamento remoto para capturar as restrições de disponibilidade de umidade na fotossíntese das plantas é um desafio avaliado há

muitos anos (Yuan et al., 2014). Este estudo evidenciou que o TVDI pode oferecer um melhor detalhamento do estresse hídrico e melhorar as estimativas de NPP utilizando o modelo CASA. Ainda são, entretanto, necessárias melhorias e ajustes no método para que as estimativas representem precisamente os dados observados de superfície.

#### **4.4 Considerações para trabalhos futuros**

Os resultados apresentados neste trabalho mostram a possibilidade e consistência dos dados de NPP quando introduzido o Índice de Umidade da Superfície (TDVI) para estimar o Coeficiente de Estresse Hídrico ( $W_e$ ), comparado a proposta original de obtenção deste coeficiente baseado na razão entre a evapotranspiração real e potencial. De qualquer forma, a metodologia proposta deve ainda ser testada em outras regiões de estudo e diferentes ecossistemas, para avaliar ainda mais a precisão do modelo em estimar a NPP da vegetação.

Outros índices de umidade podem ser testados nessa análise e, melhor explorados, para aplicações em escalas locais a globais. Além disso, a coleta e obtenção de dados observados de diversas regiões e maiores períodos de estudo podem tornar os modelos de estimativa de NPP mais próximos dos valores reais.

### **5. CONCLUSÕES**

O Modelo CASA, tanto com  $W_e$  original ou  $W_e$  baseado no TVDI, é acurado na estimativa da NPP da soja e expressa as diferenças relacionadas à dinâmica da cultura e do clima ao longo da safra.

Existe vantagem no uso da abordagem que introduz o TDVI, a qual está relacionada a maior capacidade de representar a variabilidade espacial da NPP.

O uso de diferentes sensores agrega informações importantes para analisar a variabilidade da NPP. O Landsat apresenta uma melhor resolução espacial e detalhamento para estudar a região experimental, enquanto o MODIS apresenta uma melhor resolução temporal para avaliar grandes extensões de áreas com produtos sem interferência de nuvens.

### **REFERÊNCIAS**

ALLEN, R. G. *et al.* Crop evapotranspiration: guidelines for computing crop water requirements. Rome: FAO, 1998. 300 p. (FAO – Irrigation and Drainage Paper, 56).

- BAO, G. *et al.* Modeling net primary productivity of terrestrial ecosystems in the semi-arid climate of the Mongolian Plateau using LSWI-based CASA ecosystem model. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 46, p. 84-93, 2016.
- CHAPIN III, F. S.; MATSON, P. A.; VITOUSEK, P. **Principles of terrestrial ecosystem ecology**. New York: Springer Science & Business Media, 2012.
- CHEN, C. *et al.* Monitoring of soil moisture variability in relation to rice cropping systems in the Vietnamese Mekong Delta using MODIS data. **Applied Geography**, Sevenoaks, v. 31, n. 2, p. 463-475, 2011.
- CHEN, Y. *et al.* Comparison of satellite-based evapotranspiration models over terrestrial ecosystems in China. **Remote Sensing of Environment**, New York, v. 140, p. 279-293, 2014.
- CUNHA, G. R. *et al.* Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 9, n. 3, p. 446-459, 2001.
- ELLIOTT, J. *et al.* The global gridded crop model intercomparison: data and modeling protocols for phase 1 (v1. 0). **Geoscientific Model Development (Online)**, Katlenburg-Lindau, v. 8, n. 2, p. 261-277, 2015.
- FANG, O.; WANG, Y.; SHAO, X. The effect of climate on the net primary productivity (NPP) of *Pinus koraiensis* in the Changbai Mountains over the past 50 years. **Trees**, Berlin, v. 30, n. 1, p. 281-294, 2015.
- GANG, C. *et al.* The impacts of land conversion and management measures on the grassland net primary productivity over the Loess Plateau, Northern China. **The Science of the Total Environment**, Amsterdam, v. 645, p. 827-836, 2018.
- GAO, Y. *et al.* Vegetation net primary productivity and its response to climate change during 2001–2008 in the Tibetan Plateau. **The Science of the Total Environment**, Amsterdam, v. 444, p. 356-362, 2013.
- KROSS, A.; SEAQUIST, J. W.; ROULET, N. T. Light use efficiency of peatlands: variability and suitability for modeling ecosystem production. **Remote Sensing of Environment**, New York, v. 183, p. 239-249, 2016.
- LI, Q. *et al.* Quantitative assessment of the relative roles of climate change and human activities in desertification processes on the Qinghai-Tibet Plateau based on net primary productivity. **Catena**, Cremlingen, v. 147, p. 789-796, dez. 2016.
- LIANG, W. *et al.* Analysis of spatial and temporal patterns of net primary production and their climate controls in China from 1982 to 2010. **Agricultural and Forest Meteorology**, Amsterdam, v. 204, p. 22-36, 2015.
- LOREL, C. *et al.* Linking the human appropriation of net primary productivity-based indicators, input cost and high nature value to the dimensions of land-use intensity across

French agricultural landscapes. **Agriculture, Ecosystems & Environment**, Amsterdam, v. 283, p.106565-106565, 2019.

MONTEITH, J. Solar radiation and productivity in tropical ecosystems. **Journal of Applied Ecology**, Oxford, v. 9, n. 3, p. 747–766, 1972.

NEUMANN, M.; SMITH, P. Carbon uptake by European agricultural land is variable, and in many regions could be increased: evidence from remote sensing, yield statistics and models of potential productivity. **Science of the Total Environment**, Amsterdam, v. 643, p. 902-911, 2018.

PEI, F. *et al.* Assessing the impacts of droughts on net primary productivity in China. **Journal of Environmental Management**, London, v. 114, p. 362-371, 2013.

PENG, Y.; GITELSON, A. A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. **Remote Sensing of Environment**, New York, v. 117, p. 440-448, 2012.

PIAO, S. *et al.* Changes in vegetation net primary productivity from 1982 to 1999 in China. **Global Biogeochemical Cycles**, Washington, DC, v. 19, n. 2, [art.] GB2027, [p. 1-16], 2005.

PILLON, C. N.; MIELNICZUK J.; MARTIN NETO, L. **Ciclagem da matéria orgânica em sistemas agrícolas**. Pelotas: Embrapa Clima Temperado, 2004. (Documentos, 125).

POTTER, C. S. *et al.* Terrestrial ecosystem production: a process model based on global satellite and surface data. **Global Biogeochemical Cycles**, Washington, DC, v. 7, n. 4, p. 811-841, 1993.

POTTER, C.; KLOOSTER, S.; GENOVESE, V. Net primary production of terrestrial ecosystems from 2000 to 2009. **Climatic Change**, Dordrecht, v. 115, n. 2, p. 365-378, 2012.

REICH, P. B.; WALTERS, M. B.; ELLSWORTH, D. S. Leaf age and season influence the relationships between leaf nitrogen, leaf mass per area and photosynthesis in maple and oak trees. **Plant, Cell and Environment**, Oxford, v. 14, n. 3, p. 251-259, 1991.

ROBERTSON, A.; SUYKER, A.; XIAO, X. Modeling gross primary production of maize and soybean croplands using light quality, temperature, water stress, and phenology. **Agricultural and Forest Meteorology**, Amsterdam, v. 213, p. 160-172, 2015.

RUNNING, S. W. *et al.* A continuous satellite-derived measure of global terrestrial primary production. **Bioscience**, Washington, DC, v. 54, n. 6, p. 547-560, 2004.

SANDHOLT, I.; RASMUSSEN, K.; ANDERSEN, J. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. **Remote Sensing of Environment**, New York, v. 79, n. 2/3, p. 213-224, 2002.

SANTOS, J. S. *et al.* Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campinas, v. 18, n. 1, p. 54-63, 2014.

SCHIRMBECK, L. W.; FONTANA, D. C.; SCHIRMBECK, J. Two approaches to calculate TVDI in humid subtropical climate of southern Brazil. **Scientia Agricola**, Piracicaba, v. 75, n. 2, p. 111-120, 2018.

SCURLOCK, J. M. O.; OLSON, R. J. Terrestrial net primary productivity-A brief history and a new worldwide database. **Environmental Reviews**, Ottawa, v. 10, n. 2, p. 91-109, 2002.

SON, N.T. *et al.* Monitoring agricultural drought in the Lower Mekong Basin using MODIS NDVI and land surface temperature data. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 18, p. 417-427, ago. 2012.

THORNTHWAITE, C. W.; MATHER, J. R. **The water balance**. Centerton, NJ: Drexel Institute of Technology - Laboratory of Climatology, 1955. 104 p. (Publications in Climatology, v. 8, n.1).

YU, D.Y. *et al.* Forest ecosystem restoration due to a national conservation plan in China. **Ecological Engineering**, Amsterdam, v. 37, n. 9, p. 1387-1397, 2011.

YUAN, W. *et al.* Global comparison of light use efficiency models for simulating terrestrial vegetation gross primary production based on the LaThuile database. **Agricultural and Forest Meteorology**, Amsterdam, v. 192/193, p. 108-120, 2014.

YUAN, W. *et al.* Uncertainty in simulating gross primary production of cropland ecosystem from satellite-based models. **Agricultural and Forest Meteorology**, Amsterdam, v. 207, p. 48-57, 2015.

ZHOU, W. *et al.* Grassland degradation remote sensing monitoring and driving factors quantitative assessment in China from 1982 to 2010. **Ecological Indicators**, New York, v. 83, p. 303-313, 2017.

ZHU, Q. *et al.* Remotely sensed estimation of Net Primary Productivity (NPP) and its spatial and temporal variations in the Greater Khingan Mountain Region, China. **Sustainability**, Basel, v. 9, n. 7, p. 1213-1229, 2017.

## 6. CONSIDERAÇÕES FINAIS

A Produtividade Primária Líquida é um parâmetro importante para avaliar a situação dos diversos ecossistemas agrícolas existentes. Através das estimativas do potencial de NPP foi possível avaliar o padrão da produtividade anual e as variações causadas pelas condições meteorológicas da região. Com estas estimativas pode se melhorar as técnicas de manejo das culturas, em função das oscilações dos regimes hídricos e térmicos, para que não se tenha grandes perdas de produtividade.

Já o modelo CASA testado no trabalho apresenta bom desempenho na simulação da NPP dos cultivos de soja existentes na região, conseguindo representar adequadamente a variação temporal do incremento de carbono pelas plantas. O uso dos dados meteorológicos de reanálise do ERA-Interim mostrou-se com uma boa alternativa para compor o modelo de NPP, evidenciando seu potencial em representar eficientemente os dados medidos de estações meteorológicas.

A quantificação da Apropriação Humana da NPP mostrou-se um bom indicador dos efeitos causados em função das atividades humanas na produtividade potencial do ambiente. Através deste, há a possibilidade de separar os efeitos causados pelas diferentes atividades, como mudança de uso e cobertura do solo e colheita de biomassa e, assim, adotar técnicas que visem a minimizar os impactos e perdas desta região de produção.

Além disso, ao incorporar o Índice de Umidade da Vegetação (TVDI) para determinar o coeficiente de estresse hídrico foram obtidas algumas vantagens em relação aos dados obtidos do coeficiente original  $W_e$ , principalmente pelo uso de variáveis que conseguem monitorar o estado da planta frente as condições hídricas. Também, pelo uso do sensoriamento remoto, que tem sido bastante eficiente nos estudos da dinâmica da vegetação, podendo auxiliar ainda mais no monitoramento dos cultivos e definição das zonas de manejo para que se tenham ganhos na produção agrícola.

De qualquer forma, a metodologia proposta deve ainda ser testada em outras regiões de estudo, de diferentes ecossistemas e condições ambientais, para determinar ainda mais a precisão do modelo em estimar a NPP da vegetação.

Outros índices de umidade podem ser testados nessa análise e, melhor explorados, para aplicações em escalas locais a globais. Além disso, a coleta e obtenção de dados observados de diversas regiões e maiores períodos de estudo podem tornar os modelos de estimativa de NPP mais próximos dos valores dos valores reais.