

RAPHAEL POUSA DOS SANTOS

**MODELAGEM DA PRODUTIVIDADE DE SOJA EM MODELOS BIOFÍSICO E
AGROECONÔMICO**

Dissertação apresentada à
Universidade Federal de Viçosa,
como parte das exigências do
Programa de Pós-Graduação em
Meteorologia Aplicada, para obtenção
do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2017

**Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa**

T

S237m
2017 Santos, Raphael Pousa dos, 1982-
Modelagem da produtividade de soja em modelos biofísico
e agroeconômico / Raphael Pousa dos Santos. – Viçosa, MG,
2017.
xii, 65f. : il. (algumas color.) ; 29 cm.

Orientador: Marcos Heil Costa.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Referências bibliográficas: f.57-65.

1. Soja - Produtividade. 2. Agricultura. I. Universidade
Federal de Viçosa. Departamento de Engenharia Agrícola.
Programa de Pós-graduação em Meteorologia Aplicada.
II. Título.

CDD 22 ed. 633.34

RAPHAEL POUSA DOS SANTOS

**MODELAGEM DA PRODUTIVIDADE DE SOJA
EM MODELOS BIOFÍSICO E AGROECONÔMICO**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Magister Scientiae*.

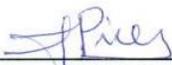
APROVADA: 30 de junho de 2017.



Dênis Antônio da Cunha



Gilvan Sampaio de Oliveira



Gabrielle Ferreira Pires



Marcos Heil Costa
(Orientador)

“ ...

The tools we make to build our lives:
our clothes, our food, our path home...
all these things we base on observation,
on experiment, on measurement, on truth.

And science, you remember, is the study
of the nature and behaviour of the universe,
based on observation, experiment, and measurement,
and the formulation of laws to describe these facts.

The race continues. An early scientist
drew beasts upon the walls of caves
to show her children, now all fat on mushrooms
and on berries, what would be safe to hunt.

The men go running on after beasts.

... ”

The mushroom hunters, Neil Gaiman

AGRADECIMENTOS

À minha mãe, que com toda apreensão foi a pessoa que mais me deu a mão e amor neste novo ciclo.

Ao meu irmão, que junto comigo começou um novo ciclo e estamos seguindo juntos.

À minha avó, por todo amor e bênçãos.

Ao meu avô, que um dia me disse que “quando alguém diz que não gosta de matemática é por que não a entendeu”. Eu o entendi. Muito obrigado, vô.

Ao Yoshio, meu padrasto, que é um grande amigo(-)presente.

Aos meus padrinhos, tia Inês e tio Ennio, gratidão (e)terna.

A todos meus amigos:

Aos (ir)mãos de Cachoeira Paulista, que sempre me apoiaram nesta mudança, mandando-me mensagens para acompanhar a vida deles e com eles continu(ar) constru(indo).

Aos amigos espalhados pelo Vale do Paraíba, que sempre com a mão no cor(ação) estavam dividindo o espaço desta distância tão sentida.

Aos amigos espalhados pelo mundo, eu ajudo a constru(ir) o meu mundo com inspir(ação) nos passos que vocês mostram como trilhar.

Ao grupo de trabalho no INPE, pela troca de experiências, discussão e amizade.

Ao Gilvan Sampaio que no início desta empreitada disse-me: “você terá muitos momentos com vontade de desistir, mas a estrada é gratificante”.

Aos amigos do biosfera-atmosfera:

Ao Fernando, que sem o seu grande auxílio este trabalho não sairia.

À Emily, pelo suporte desde o início da mudança para esta cidade.

Ao Gabriel, pela amizade, pelas discussões esclarecedoras, pela inovação das ideias, cervejas, trocas musicais e literárias.

À Pauline, pela sempre prontidão e organização deste grupo.

À Lívia, pelo apoio e muitos aprendizados.

À Gabrielle, pelas leituras, correções, discussões políticas e apoio como professora.

À Aninha, pela amizade e puxões de orelha.

À Carol, pela amizade e por caminhar em paralelo neste mesmo desafio.

Ao Matheus, pelo apoio operacional e funcional neste grupo.

Ao Vitor, por todos os “helps” com o Optis.

Argemiro, Verônica, Lucas e Livinha por serem os mais novos e mostrarem que há sempre continuação.

Ao Victor e Fabiana pela parceria nesta empreitada.

A todos os professores com quem tive a oportunidade obter novos conhecimentos e por todo o aprendizado.

À Graça Freitas pela competência e amizade que conduziu a secretária da pós-graduação.

Ao CNPQ pelo apoio com a bolsa.

Ao projeto Tanguro pela disponibilização dos dados.

Ao orientador e professor Marcos, pela paciência e maestria desta função.

Por fim, a toda a música que me acompanhou nestes anos. Todo o jazz que me fez aquietar a mente e moldar cada peça deste trabalho, colocando cada uma em seu encaixe, levantando dúvidas de outras e fazendo-me pesquisar.

SUMÁRIO

LISTA DE FIGURAS	vii
LISTA DE TABELAS.....	ix
RESUMO	x
ABSTRACT	xii
1 Introdução	1
2 Metodologia.....	6
2.1 Modelos utilizados.....	7
2.1.1 Modelo biofísico – INLAND	7
2.1.2 Modelo agroeconômico	9
2.1.3 Modelo biofísico-econômico.....	11
2.2 Dados utilizados	12
2.2.1 Biofísicos	12
2.2.1.2 Clima e Solos	13
2.2.1.3 Dados do sítio experimental	13
2.2.1.4 Dados nacionais de produtividade de soja	15
2.2.2 Econômico.....	16
2.2.2.1 Custo mínimo de transporte.....	16
2.2.2.2 Tamanho médio da fazenda	20
2.2.2.3 Preço da soja	20
2.3 Software para calibração do modelo biofísico e biofísico-econômico	21
2.4 Descrição dos experimentos numéricos.....	23
3 Resultados e discussão	27

3.1 Mapas de custo mínimo de transporte	27
3.2 Mapas de tamanho da fazenda	30
3.3 Simulações da produtividade de soja	31
3.4 Discussão.....	41
4 Conclusões.....	53
4.1 Recomendações para trabalhos futuros	55
5 Referências bibliográficas	57

LISTA DE FIGURAS

Figura 1. Esquematização das etapas realizadas neste trabalho: (a) detalhamento de variáveis e modelos utilizados na metodologia; (b) experimentos numéricos realizados. Os índices mostrados nas caixas mostram dados compilados espacialmente (i, j) e temporalmente (k).....	7
Figura 2. Parâmetro do dia e mês expresso em formato de dia juliano para o plantio por pixel baseado no Zoneamento Agrícola.....	12
Figura 3. Localização da Fazenda Tanguro no estado do Mato Grosso (MT). O localizador em vermelho é a posição da estação meteorológica.....	14
Figura 4. Produtividade de soja em anos selecionados conforme o banco de dados de Dias et al. (2016).....	16
Figura 5. Distribuição de portos de exportação de soja e malha de rodovias em função dos coeficientes de custo.....	17
Figura 6. Preço da soja para o período de 1994-1997 (FAO, 2016) e 1998-2012 (CEPEA-Esalq, 2017).....	21
Figura 7. Faixas de temperaturas médias da estação de crescimento para anos selecionados.....	26
Figura 8. Custo para transportar uma tonelada de soja através de cada pixel..	27
Figura 9. Custo mínimo de transporte para anos selecionados.....	28
Figura 10. Custo de transporte a partir de Cuiabá (a) e Sorriso (b) para qualquer ponto do país.....	29
Figura 11. Distribuição dos pixels de custo mínimo de transporte para escoamento da soja para os portos, para anos selecionados.....	30

Figura 12. Tamanho médio das fazendas em cada pixel de 1° x 1°, para anos selecionados. 31

Figura 13. Correlações entre produtividade simulada pelo INLAND e observado. A) Modelo Biofísico com parâmetros originais (B_{Ori}); B) Modelo Biofísico com parâmetros de Tanguro (B_T); C) Modelo econômico (E_1); D) Modelo econômico com 9 grupos (E_9); E) Modelo econômico climático com 9 grupos (E_{C9}); F) Modelo biofísico otimizado com 9 grupos (B_9); G) Modelo Biofísico-Econômico otimizado com 1 grupo (BE_1); H) Modelo Biofísico-Econômico otimizado com 9 grupos (BE_9). 34

Figura 14. Variação da produtividade anual média dos modelos Biofísico (Y_B , representado pelo triângulo) e Biofísico-econômico (Y_{BE} , representado pelo círculo), e do valor médio observado (Y_{Obs} , representado pelo quadrado) para as faixas de temperatura (a) < 24°C, (b) entre 24°C e 26°C e (c) > 26°C. A linha representa a razão entre a produtividade de Y_{BE} e Y_B 48

Figura 15. Em a: cidades campeãs de produtividade Mambarê - PR (2009/2010), Correntina - BA (2010/2011 e 2011/2012); b: cidades campeãs de produtividade de soja safra 2011/2012 (CESB, 2017). 51

LISTA DE TABELAS

Tabela 1. Coeficientes do custo de transporte em diferentes rodovias (Vera-Diaz et al., 2009).....	18
Tabela 2. Período de operação de escoamento da soja nos portos.....	19
Tabela 3. Parâmetros e divisão hierárquica das calibrações.....	23
Tabela 4. Parâmetros utilizados calibração do sítio experimental.....	32
Tabela 5. Síntese dos experimentos. \bar{Y} é a média calculada da produtividade durante todo o período do experimento (n=3877). ε é o erro em relação da média do observado com a média do simulado. O RMSE é o erro médio quadrático. Na equação de regressão, y é o simulado e x representa o observado. E r é a correlação.....	33
Tabela 6. Parâmetros do modelo econômico e sua significância.....	36
Tabela 7. Parâmetros otimizados na segunda calibração e valores de RMSE, separados por faixas de temperatura e períodos para o modelo BE_9	40
Tabela 8. Faixas de variação de $\beta_1 X_1$, $\beta_2 \log X_2$ e $\beta_3 X_3$, para o modelo BE_9	43
Tabela 9. Efeitos na produtividade (ton ha ⁻¹) para cada termo dos modelos BE_9 e E_1 (Equações 1 e 2). Y_B é o resultado do modelo biofísico (INLAND) no contexto da Equação 2. Valores seguidos pela letra (a) são discutidos no texto.....	45

RESUMO

SANTOS, Raphael Pousa dos, M.Sc., Universidade Federal de Viçosa, junho de 2017. **Modelagem da produtividade de soja em modelos biofísicos e agroeconômico**. Orientador: Marcos Heil Costa.

Modelos biofísicos de crescimento de cultura consideram os fatores naturais de crescimento e produtividade das culturas agrícolas, mas negligenciam a influência de fatores econômicos no processo. Por outro lado, modelos estatísticos de natureza agroeconômica são utilizados para simular a produção de culturas sob a influência de variáveis econômicas, porém ignorando eventos biofísicos, como por exemplo a influência de uma seca. Este trabalho acopla um modelo agroeconômico a um modelo biofísico de crescimento da cultura de soja. Este trabalho fez simulações espacialmente distribuídas da produtividade de soja no território nacional para o período de 1994 a 2012, utilizando três tipos de modelos: um modelo puramente biofísico (INLAND – Integrated Land Surface Model); um modelo puramente agroeconômico (modelo de regressão linear) e um híbrido biofísico-econômico (INLAND/linear). Para o modelo agroeconômico e híbrido foram utilizados como parâmetros econômicos o custo de transporte, o tamanho médio da fazenda e o preço da soja. Utilizando um algoritmo genético (NSGA-II/Optis) foi realizada uma calibração da produtividade de soja em dois níveis hierárquicos. Foram realizadas oito simulações com configurações diferentes destes modelos. Os melhores resultados foram obtidos com os modelos que consideraram variáveis econômicas e climáticas. O modelo empírico, contemplando variáveis econômicas e climáticas, apresentou o melhor resultado entre todas as simulações, contemplando variáveis econômicas e climáticas, chegando a uma correlação de 0,72. O modelo biofísico com a inserção das variáveis econômicas, ou seja, com limitantes econômicos na produtividade de soja, teve a produtividade potencial simulada reduzida a uma produtividade real simulada próxima da observada, com viés médio no período 1994-2012 de $-0,01 \text{ ton ha}^{-1}$. A correlação entre os dados simulados e observados aumentou de 0,12 usando o modelo puramente biofísico para 0,55 usando o modelo híbrido. O modelo puramente biofísico, quando testado

nacionalmente no Brasil, apresentou resultados de produtividade potencial próximos aos campeões de concursos de produtividade de soja.

ABSTRACT

SANTOS, Raphael Pousa dos, M.Sc., Universidade Federal de Viçosa, June, 2017. **Modeling soybean yield in biophysical and agroeconomic models.** Adviser: Marcos Heil Costa.

Crop models consider the environmental factors influencing the growth and yield of agricultural crops, but neglect the influence of economic factors on the process. On the other hand, statistical agroeconomic models are used to simulate crop yields under the influence of economic variables, however neglecting biophysical events, such as the influence of a drought. This work couples an agroeconomic model with a soybean crop model. This work simulated spatially distributed soybean yield in Brazil for the period 1994-2012, using three types of models: a purely biophysical model (INLAND – Integrated Land Surface Model); a purely agroeconomic model (linear regression model) and a hybrid biophysical-economic model. For the agroeconomic and hybrid models, the economic parameters used are the cost of transportation, average farm size and the soybean price. Using a genetic algorithm (NSGA-II/Optis) a calibration of the soybean yield was performed at two hierarchical levels. Eight simulations were performed with distinct settings of these models. The best results were obtained with the models that considered purely economic and climate variables. The empirical model, contemplating economic and climate variables, presented the best result among all the simulations reaching a correlation of 0.72. The biophysical model with economic variables introduced economic constraints on the soybean yield, had the simulated potential yield reduced to a simulated real yield close to the observed, with a mean bias of -0.01 ton/ha in the 1994-2012 period. The correlation between simulated and observed data increased from 0.12 using the purely biophysical model to 0.55 using the hybrid model. The purely biophysical model, when tested nationally in Brazil, showed results of potential yield close to the soybean yield contest champions.

1 Introdução

O Brasil tem uma das maiores produções agrícolas do mundo, sendo o segundo maior produtor de soja (Strassburg et al., 2014). A cultura de soja é responsável pela maior parte da área cultivada com grãos no país (Dias et al., 2016), sendo a principal responsável pelo aumento da área de cultivo. A produção de soja alcançou na safra de 2015/2016 um total de 95,6 milhões de toneladas, ou aproximadamente 30% da soja produzida globalmente (EMBRAPA, 2016).

Segundo a *Food and Agriculture Organization of the United States* (FAO), há uma projeção para que a produção mundial de soja tenha um crescimento de 37% nos próximos 10 anos (FAO / OECD, 2015). A produção é o produto da área plantada e da produtividade, sendo que os valores passados, atuais e futuros desta última são influenciados tanto por fatores biofísicos quanto por fatores econômicos. Precipitação, radiação solar, temperatura, concentração de CO₂ e

duração do fotoperíodo são exemplos de fatores biofísicos que influenciam a produtividade de soja. Há também fatores econômicos que interferem nesta, onde se pode incluir o preço de mercado da própria *commodity* e preços de insumos. Ambos podem ser influenciados pelo custo de transporte e pela tecnologia aplicada (variedade de sementes, por exemplo) que está implícito nos insumos e nos custos de produção final do produto (Garrett et al., 2013a).

Atualmente, dois tipos de modelos têm sido utilizados para estimar a produtividade agrícola: modelos agrometeorológicos, que focam em processos biofísicos e simulam o crescimento e senescência das plantas em resposta à forçante meteorológica; e agroeconômicos, que focam em fatores econômicos, como trabalho, preço, insumos aplicados e tecnologias.

Os modelos agrometeorológicos são previsores da produtividade de uma cultura a partir das condições meteorológicas, onde é possível simular a fisiologia da planta a partir de informações sobre clima e solo (Vera-Diaz et al., 2008). Em geral, são modelos baseados em processos fisiológicos e fenológicos das plantas, processos físicos e químicos do solo, bem como a física da atmosfera, dentre outros (Lobell e Burke, 2010). Estes modelos vêm sendo desenvolvidos desde a década de 1970, evoluindo em suas aplicações nas décadas posteriores (Stöckle et al., 2003), como a aplicação de manejo e decisões de campo. Uma característica destes modelos é a sua habilidade em simular cultivos agrícolas de escala bidimensional ou pontual. Exemplos de modelos que trabalham em ambas as escalas são o SOYBEAN (Sinclair, 1986) que simula LAI (*Leaf Area Index* – Índice de Área Foliar) e acúmulo de biomassa; o GLYCIM (Haskett et al., 1995) que simula a produtividade baseada na transpiração, desenvolvimento e

crescimento orgânico, fotossíntese, tanto para nível pontual quanto para nível regional; o CROPGRO (Boote et al., 1998), que considera o balanço de carbono, balanço de nitrogênio e de água no solo para diferentes tipos de cultivos agrícolas; o AgrolBIS (Kucharik, 2003), que simula detalhadamente processos biofísicos. Um modelo bastante utilizado pela comunidade científica, que também apresenta essas características é o DSSAT (*The Decision Support System for Agrotechnology Transfer*) que incorpora 16 tipos de cultivos agrícolas e uma estrutura computacional de fácil acesso (Jones et al., 2003). Alguns modelos como esse são implementados como submodelos em modelos de processos superficiais, os LSMs (*Land Surface Models*). Estes modelos foram inicialmente desenvolvidos para fornecer condições de contorno inferiores para modelos atmosféricos, como fluxos de radiação, de calor sensível e latente, sendo posteriormente modificados para incluir processos fisiológicos (Sellers et al., 1996), crescimento da vegetação natural (Foley et al. 1996) e de culturas agrícolas (Kucharik, 2013). Como modelo agrometeorológico baseado no conceito de LSM temos o AgrolBIS (Kucharik, 2003), o SiBcrop – *Simple Biosphere Model* (Lokupitiya et al., 2009), o CLM-Crop – *Community Land Model* (Drewniak et al., 2013), todos estes com características semelhantes como fisiologia e fenologia de cultivos agrícolas, e simulação de produtividade primária bruta; índice de área foliar e produção de grãos.

Os modelos agroeconômicos simulam as respostas das mudanças na produtividade baseados em relações estatísticas (Nelson et al., 2013). Estes modelos podem estimar a produtividade agrícola através de diversas funções, como por exemplo, preços de fertilizantes, custos de transporte ou em função de

determinantes físicos e econômicos, como preço e demanda (Vera-Díaz et al., 2008). Existem também os modelos de equilíbrio parcial, como o IMPACT (*The International Model for Policy Analysis of Agricultural Commodities and Trade*) que têm em sua essência um modelo de multimercado, em que é possível analisar tendências ambientais, biofísicas e socioeconômicas, permitindo uma análise de uma variedade de questões críticas de interesse em decisões políticas regionais, nacionais e globais (Rosegrant, 2012).

Todos os modelos, sejam eles estatísticos, híbridos ou baseados em processos, possuem suas limitações. Kaufmann e Snell (1997) mostram, por exemplo, que modelos agrometeorológicos necessitam de escolha de cultivares e datas fixas de plantio, tanto no espaço quanto no tempo, o que em geral leva a uma sub-representação da complexa realidade agrícola de regiões mais extensas. Boote et al. (1996) apontam outros fatores limitantes desses modelos, como incertezas em dados de entrada, como quantidade de nitrogênio aplicada na forma de fertilização, ou a negligência de pragas e doenças. Rötter et al. (2011) mostraram que embora desde a década de 1980 os modelos agrometeorológicos tenham ajudado a avaliar os impactos das mudanças climáticas e antropogênicas na produtividade das culturas, estes devem ser revistos para incluir estratégias de adaptação e recalibração de seus parâmetros para seguir as novas tendências de tecnologia, como mudanças na fisiologia da produção (cultivares diferentes).

Os modelos agroeconômicos simulam a produtividade com base em relações empíricas com dados disponíveis, embora algumas vezes não capturem a variação de fatores institucionais no tempo (Angelsen e Kaimowitz, 1999), o

que acaba sendo um limitante. A variação de localidade, o número de produtores e intermediários, organizações financeiras e consumidores, também configuram uma limitação na cadeia de suprimentos que podem ser quantificados neste tipo de modelo (Garrett et al., 2013b). Além disso, os modelos agroeconômicos não tem capacidade para simular o efeito de um evento meteorológico extremo, como uma seca (Nelson et al., 2013).

Os estudos que vêm sendo produzidos nas últimas décadas com o objetivo de avaliar os impactos das mudanças climáticas sobre a produtividade agrícola tem utilizado tanto modelos agrometeorológicos quanto agroeconômicos (Rosenzweig et al., 2013). Este trabalho buscou preencher uma lacuna no desenvolvimento destes modelos híbridos visando abranger de forma inovadora análises tanto temporais quanto espaciais, visto que outros trabalhos realizados contemplavam apenas um ano ou uma área específica, como no trabalho de Garrett et al. (2013a). Portanto, o objetivo desta dissertação é desenvolver um modelo híbrido dos modelos agrometeorológicos e agroeconômicos, de modo a investigar qual a influência das variáveis econômicas e climáticas na produtividade de soja em escala nacional, suprimindo assim a necessidade de resultados de produtividade de soja mais representativos.

2 Metodologia

Para entender o impacto que variáveis econômicas e climáticas causam na produtividade de soja, este trabalho propõe um modelo biofísico-econômico. A Figura 1 sintetiza os trabalhos realizados. Em resumo, foram construídos mapas de custo mínimo de transporte de acordo com a localidade e tamanho da fazenda que serviram como dados de entrada para o modelo. Estes dados deram suporte às simulações do modelo juntamente com dados meteorológicos, de solo e do preço da soja (Figura 1a). Nesse trabalho também foi utilizado um software (Optis) para otimização dos parâmetros dos modelos propostos.

Foram obtidos resultados (Figura 1b) utilizando: modelos biofísicos, com parâmetros originais (B_{Ori}), parâmetros calibrados contra os dados da Fazenda Tanguro (B_T), puramente biofísico (B_9); modelos puramente econômicos (E_1), (E_9), econômicos com a inserção de variáveis climáticas (E_{C9}), e modelos

biofísico-econômico (BE_1) e (BE_9). Os modelos utilizados, a construção dos bancos de dados e os experimentos serão descritos nas seções a seguir.

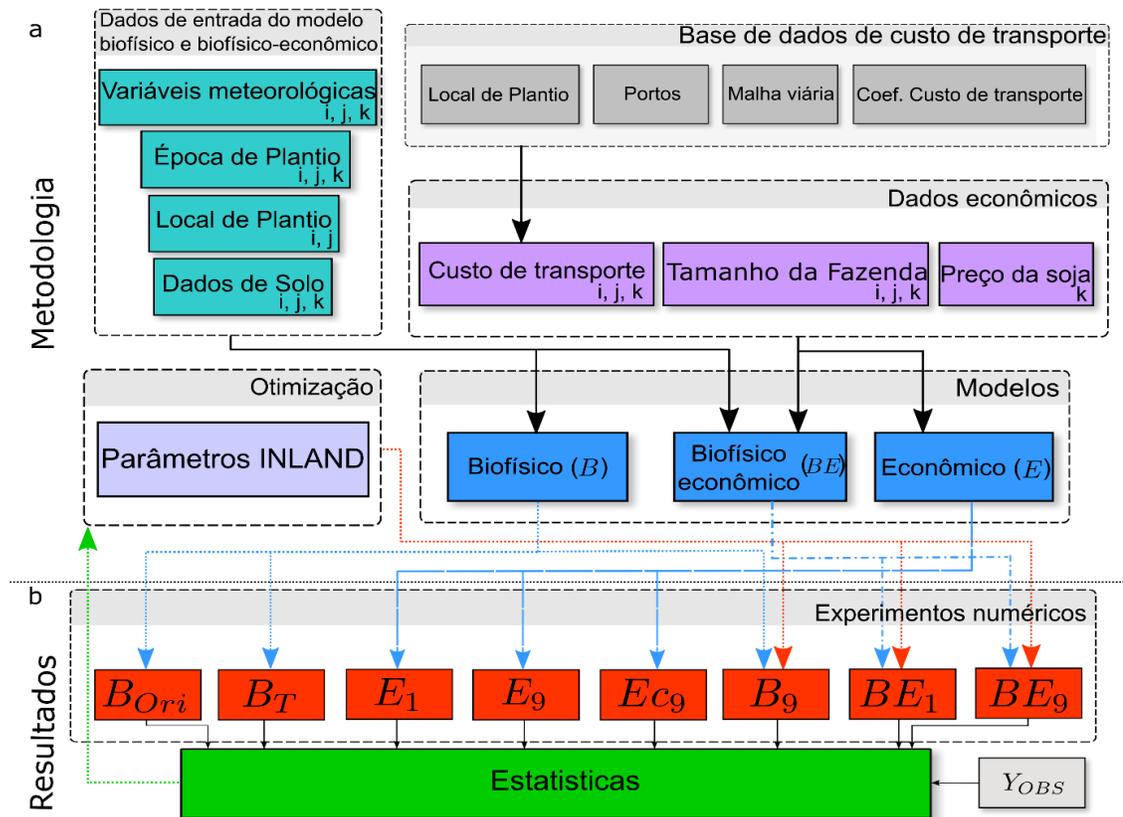


Figura 1. Esquematização das etapas realizadas neste trabalho: (a) detalhamento de variáveis e modelos utilizados na metodologia; (b) experimentos numéricos realizados. Os índices mostrados nas caixas mostram dados compilados espacialmente (i, j) e temporalmente (k).

2.1 Modelos utilizados

2.1.1 Modelo biofísico – INLAND

O modelo INLAND (*Integrated Land Surface Model*), utilizado neste trabalho para simular a produtividade de soja, é um modelo desenvolvido por pesquisadores brasileiros e irá integrar o módulo de superfície do BESM (*Brazilian Earth System Model – Modelo Brasileiro do Sistema Terrestre*).

Baseado nos modelos IBIS (*Integrated Biosphere Simulator*, Foley et al., 1996) e AgroIBIS (Kucharik, 2003), o INLAND é um modelo de quinta geração (dentro os LSMs), onde são representados os processos de superfície, fisiologia vegetal com fotossíntese e respiração, fenologia e dinâmica da vegetação, o ciclo completo do carbono terrestre e a ocorrência e efeitos de distúrbios de fogo (Tourigny, 2014), condutância do dossel e interações com o solo; processos hidrológicos superficiais, incluindo áreas inundadas (Foley et al., 1996; Kucharik et al., 2000). O foco principal do modelo é uma melhor representação de processos relevantes da interação atmosfera-biosfera na América do Sul, em especial a dinâmica de vegetação transiente na Amazônia e Cerrado brasileiro. A vegetação é representada por 12 PFTs (*Plant Functional Types* – Tipos Funcionais de Plantas) que descrevem diferentes ecossistemas como floresta tropical, florestas decíduas, savana e gramíneas.

Em 2014 foi lançada uma segunda versão do modelo, totalmente escrita e compilada em FORTRAN 90, em que foi incluída a fenologia de cultivos agrícolas, baseada no modelo AgroIBIS (Cuadra et al., 2012). Nesta versão, o modelo passou a ter 16 PFTs, incluindo 4 cultivos agrícolas (soja, milho, trigo e cana-de-açúcar). Destas culturas, soja, milho e trigo são cultivos anuais; enquanto cana-de-açúcar é perene.

As equações do modelo são resolvidas em um intervalo de integração de 60 minutos, onde são simulados os balanços de energia, água, carbono e momentum. O sistema solo-planta-atmosfera inclui 11 camadas de solo com espessuras diferentes até a profundidade de 2,5 metros, que são parametrizados em 11 categorias de textura de solo, correspondentes a seus atributos físicos

(Kucharik e Twine, 2007).

O funcionamento biofísico do módulo de cultivos agrícolas do INLAND parte dos parâmetros fornecidos. As datas de plantio podem ser prescritas ou prognosticadas. A produtividade primária líquida é alocada em quatro diferentes reservatórios (raízes, hastes, folhas e grãos), onde os parâmetros desta alocação são dinâmicos no tempo, ou seja, variam de acordo com os estádios fenológicos da cultura. Estes estádios de emergência, enchimento de grãos e maturidade fisiológica são controlados pela acumulação de graus-dia (GDD), até que o GDD de maturidade fisiológica (GDDm) seja alcançado. Deste modo, o ciclo fisiológico é dividido em três fases, ou estádios:

(1) Estádio de emergência: do plantio até o GDD acumulado atingir 1% do GDDm;

(2) Estádio vegetativo: ao atingir o 1% de GDDm, inicia-se o desenvolvimento da planta e das folhas, até que GDD acumulado atinja 60-70% de GDDm;

(3) Estádio reprodutivo (enchimento de grãos): entre o fim do estágio vegetativo e o dia em que o GDD acumulado atinge o GDDm. Atingida a maturidade, a colheita pode ser inicializada imediatamente.

2.1.2 Modelo agroeconômico

O modelo puramente agroeconômico utilizado neste trabalho, baseado no modelo de Garrett et al. (2013a), estima a produtividade de soja em função das variáveis econômicas, sem influência de variáveis biofísicas. Dentre as diversas variáveis econômicas que explicam a variabilidade na produtividade da

soja, foram utilizadas três variáveis que estavam disponíveis para o período em estudo, conforme a Equação 1:

$$Y_E(i, j, k) = \alpha_0 + \alpha_1 X_1(i, j, k) + \alpha_2 \log(X_2(i, j, k)) + \alpha_3 X_3(k) + \varepsilon(i, j, k) \quad (1)$$

em que:

Y_E é a produtividade de soja (ton ha^{-1}) estimada pelo modelo econômico.

X_1 é o custo de transporte ($\text{US\$ ton}^{-1}$), que tem um papel fundamental na produção de soja, pois dependendo da região, pode representar até 30% dos custos da produção. Esta é uma variável que pode acarretar outros impactos na produção. O alto custo do transporte reduz o preço líquido da soja que é recebida pelos fazendeiros, e ainda reduz o nível ideal de insumos aplicados, tais como fertilizantes e agroquímicos. Este efeito é reforçado por preços elevados de insumos adquiridos em áreas com alto custo de transporte (Vera-Diaz et al., 2008) A obtenção da variável X_1 está descrita na seção 2.2.2.1.

X_2 é o tamanho da fazenda (ha). Garrett et al. (2013a) mostraram que existe pequena relação positiva entre o tamanho da fazenda e a produtividade de soja, sendo que para 1% de crescimento no tamanho médio da fazenda, houve aumento de 0,02% de crescimento na produtividade. O raciocínio por trás dessa relação é que, em fazendas maiores, utilizam-se máquinas maiores e mais eficientes que reduzem o custo por tonelada produzida. A obtenção da variável X_2 está descrita na seção 2.2.2.2.

X_3 é o preço da soja ($\text{US\$ ton}^{-1}$), fator que configura como um elemento da cadeia de suprimentos e tem forte efeito na área plantada e pequeno, mas significativo, efeito na produtividade. O preço da soja tem influência na

produtividade de soja, visto que, com uma expectativa de receita mais elevada, o produtor tende a investir mais em insumos. A obtenção da variável X_3 está descrita na seção 2.2.2.3.

ε é o erro, onde são contabilizadas variáveis econômicas não consideradas neste modelo, como por exemplo, crédito rural, cadeia de suprimentos, mão-de-obra e preço de fertilizante. α_0 , α_1 , α_2 e α_3 são coeficientes definidos por uma regressão linear.

2.1.3 Modelo biofísico-econômico

O modelo biofísico-econômico é um híbrido dos modelos apresentados anteriormente buscando explicar a fração da produtividade potencial biofísica atingida na realidade através de limitantes econômicos. Deste modo, o modelo biofísico econômico deste trabalho é mostrado na Equação 2:

$$Y_{BE}(i, j, k) = Y_B(i, j, k) [\beta_0 + \beta_1 X_1(i, j, k) + \beta_2 \log(X_2(i, j, k)) + \beta_3 X_3(k)] + \varepsilon(i, j, k) \quad (2)$$

em que Y_{BE} é a produtividade simulada pelo modelo biofísico econômico, Y_B representa a produtividade resultante do modelo biofísico (INLAND) e o termo entre colchetes é o componente econômico, conforme descrito anteriormente. Essa configuração assume implicitamente que o INLAND irá simular a produtividade potencial, limitada apenas pelo clima e pelos solos, enquanto o termo entre colchetes irá quantificar as limitações introduzidas pelas condições econômicas.

2.2 Dados utilizados

2.2.1 Biofísicos

2.2.1.1 Data de plantio

Dois parâmetros são bastante importantes para a simulação da produtividade de soja no modelo INLAND: o dia e o mês para o início do plantio (Figura 2). Utilizou-se a mesma data de plantio para todo o período de simulação do modelo. Estes dados foram baseados no Zoneamento Agrícola de Risco Climático produzido pela EMBRAPA, onde “períodos favoráveis para a semeadura da soja foram definidos com base no índice de satisfação da necessidade de água, definido como sendo a relação entre a evapotranspiração real (E_{tr}) e evapotranspiração máxima da cultura (ET_m) para a frequência de ocorrência de 80%, calculada para a fase fenológica de floração e enchimento de grãos da cultura” (Agritempo, 2016).

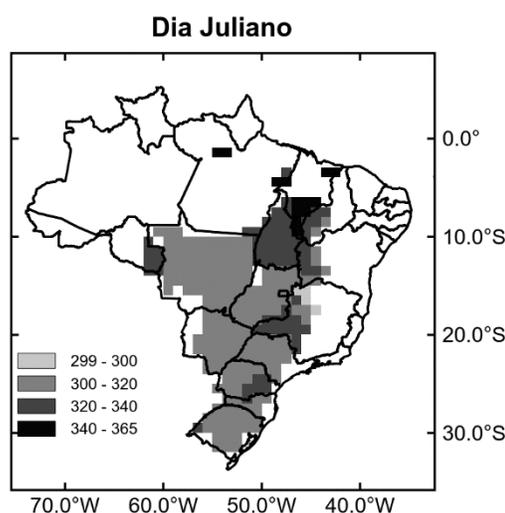


Figura 2. Parâmetro do dia e mês expresso em formato de dia juliano para o plantio por pixel baseado no Zoneamento Agrícola.

2.2.1.2 Clima e Solos

O modelo INLAND foi inicializado com forçantes atmosféricas diárias de clima histórico advindas do banco de dados *Terrestrial Hydrology Research Group da Universidade de Princeton - PTHRG* (Sheffield et al., 2006), para o período de 1994-2012. Espacializado em uma grade de 1° x 1° (~111 km x 111 km) o modelo teve como forçantes as seguintes variáveis: cobertura de nuvem (%); precipitação (mm/dia); umidade relativa (%); temperatura máxima (°C); temperatura mínima (°C) velocidade do vento (m/s) e temperatura (°C).

Os dados de solo utilizados como dados de entrada para o modelo INLAND são baseados no banco de dados *Global Soil Data Products* do ORNL DAAC (*Distributed Active Archive Center for Biogeochemical Dynamics* – disponível em <http://www.daac.ornl.gov>). Os dados possuem as propriedades da pedosfera em escala global, apresentados em porcentagem de areia, argila e silte. O modelo interpreta esta porcentagem, define o tipo do solo presente no pixel e lê os parâmetros do solo de uma tabela de consulta.

2.2.1.3 Dados do sítio experimental

A calibração da produtividade de soja pelas variáveis biofísicas do modelo INLAND, foi realizada utilizando os dados da estação de coleta micrometeorológica localizada na beira do Rio Xingu (Figura 3) em uma plantação de soja na Fazenda Tanguro – MT (Latitude: 13°3'37,16"S; Longitude: 52°22'55,68"W; Altitude: 358 m). O período disponível dos dados é de 2,5 anos (2014-2016), contemplando um ciclo total da cultura de soja. Foram utilizados dados com medidas horárias de umidade relativa do ar (%), precipitação (mm),

velocidade do vento (m/s), temperatura (°C) e fluxos de radiação de onda longa e curta (W/m²), como forçantes atmosféricas para o modelo INLAND, disponíveis para o período de 01 de janeiro de 2014 a 01 de julho de 2016 (disponíveis em: <http://dadostanguro.com.br/>).

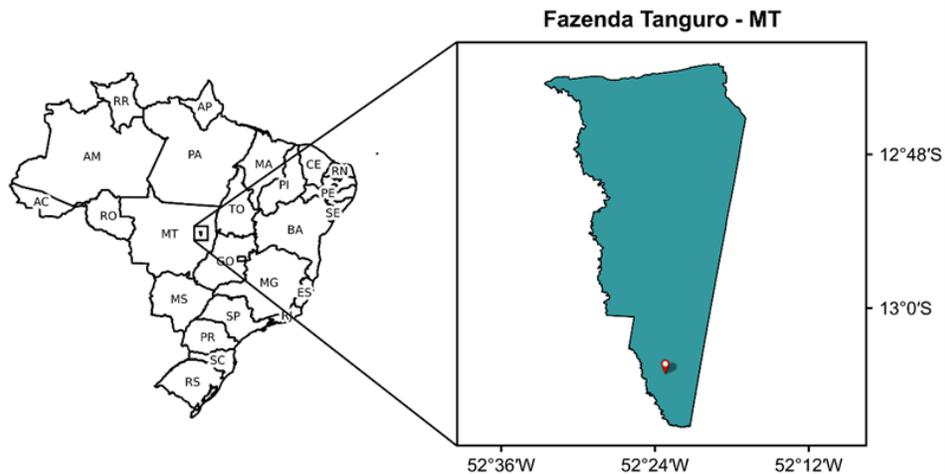


Figura 3. Localização da Fazenda Tanguro no estado do Mato Grosso (MT). O localizador em vermelho é a posição da estação meteorológica.

Estações meteorológicas podem apresentar problemas ocasionais de funcionamento prejudicando a coleta de dados e, desse modo, resultando em falhas nas medições. Para o período disponível (2014-2016) as falhas foram preenchidas de acordo com Senna (2004):

- Falha (f) menor ou igual a 3 horas:

$$X_i = X_p + \frac{(X_{p+f+1} - X_p)}{f + 1} * (i - p) \quad (3)$$

onde, X_i é o valor da falha a ser preenchida, X_p é o valor antecessor à falha, X_{p+f+1} é o valor sucessor à falha, i é a hora da falha e p a hora anterior à falha.

- Para a falha (f) maior que 3 horas e menor que 24 horas:

$$X_i = X_{i-24} + \frac{(p + f + 1 - i)}{f + 1} * (X_p - X_{p-24}) + \frac{(i - p)}{f + 1} * (X_{p+f+1} - X_{(p+f+1)-24}) \quad (4)$$

onde, X_{i-24} é o valor de 24 horas antes do horário da falha, X_{p-24} é o valor de 24 horas antes do antecessor à falha, X_{p+f+1} é o valor sucessor da falha e $X_{(p+f+1)-24}$ é o valor de 24 horas antes do sucessor da falha.

Desta forma, utilizando as equações propostas por Senna (2004) foi possível manter o comportamento dos dados observados em seus períodos de falha. Para o período de estudo, as medições analisadas possuem um número pequeno de falhas, que eram sempre inferiores que 24 horas.

2.2.1.4 Dados nacionais de produtividade de soja

Os mapas de produtividade de soja neste trabalho fazem parte do banco de dados BHALU (*Brazilian Historical Agricultural Land Use*) construídos por Dias et al. (2016) (Figura 4). Consiste em uma reconstrução histórica da distribuição espacial dos cultivos (totais, soja, milho e cana-de-açúcar) e das pastagens (naturais e plantadas) através da combinação espacializada de dados de censo agrícola e de dados de sensoriamento remoto para todo o território brasileiro.

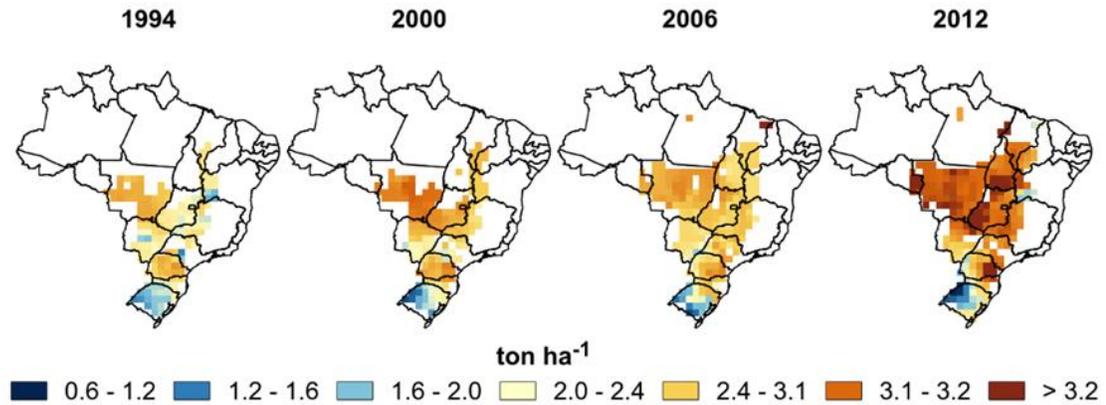


Figura 4. Produtividade de soja em anos selecionados conforme o banco de dados de Dias et al. (2016).

Neste banco de dados podem ser encontrados mapas de produtividade de soja para período de 1990 a 2012 (pode ser acessado em: <http://www.biosfera.dea.ufv.br/pt-BR/banco/uso-do-solo-agricola-no-brasil-1940-2012---dias-et-al-2016>). Neste trabalho utilizou-se apenas os dados de produtividade de soja para o período de 1994-2012.

2.2.2 Econômico

2.2.2.1 Custo mínimo de transporte

Para gerar os mapas de custo de transporte foi assumido que: (1) o valor do diesel para o transporte da soja foi constante durante todo o período, (2) toda a soja produzida era escoada pelos principais portos exportadores de soja, sem passar pelas fábricas de processamento de grãos, (3) todo o transporte de soja foi feito apenas pelas rodovias federais.

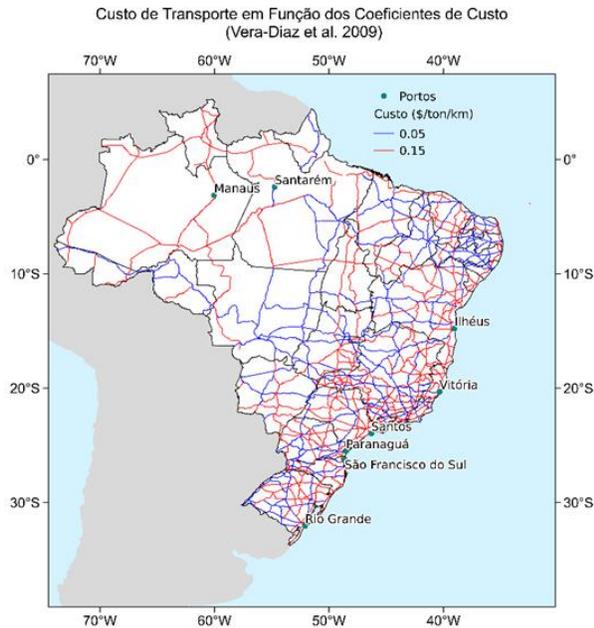


Figura 5. Distribuição de portos de exportação de soja e malha de rodovias em função dos coeficientes de custo.

Foi necessário em primeiro lugar classificar as rodovias em pavimentadas e não pavimentadas para, em seguida, aplicar os coeficientes de custo baseados em estimativas para o custo de transporte de produtos sobre superfícies (pavimentadas, não pavimentadas e estradas de terra vicinais; Figura 5). Algumas estradas são caracterizadas como “em pavimentação” pelo DNIT (Departamento Nacional de Infraestrutura de Transportes) e seus trechos foram divididos entre pavimentados e não pavimentados, conforme análise feita pelo Google Earth. Não foi considerada variação na pavimentação no tempo.

Os custos (Tabela 1) utilizados na classificação das rodovias são estimativas baseadas na indústria madeireira e podem ser aplicados ao escoamento de soja, pois ambos os produtos utilizam caminhões com mesmos comprimento, peso e volume (Vera-Diaz et al., 2009). O modal aquaviário interno

não foi considerado pela falta de informação sobre a porcentagem de escoamento de soja transportada por este modal e das vias fluviais utilizadas para este transporte.

Tabela 1. Coeficientes do custo de transporte em diferentes rodovias (Vera-Diaz et al., 2009)

Classificação	US\$/ton/km
Rodovias pavimentadas	0,05
Rodovias não pavimentadas	0,15
Rodovias vicinais	0,20

Os valores de custo por tipo de pavimentação foram alocados nas rodovias e posteriormente convertidos para um mapa de custo no formato *raster*, para servir como dado de entrada para o cálculo do custo mínimo. Para as regiões onde não existem rodovias foi considerado a menor distância entre o local de produção e a estrada mais próxima e o valor de US\$ 0,20 ton/km (Tabela 1) para o cálculo do custo.

Para calcular o custo mínimo de transporte foram utilizadas as funções *r.cost* e *r.drain* do Sistema de Informações Geográficas GRASS GIS (*Geographic Resources Analysis Support System*). O *r.cost* calcula o custo acumulado de percurso de um ponto inicial até um ponto final e o *r.drain* traça o caminho mínimo de menor custo sobre uma superfície (GRASS GIS Team, 2017). Como dado de entrada para estas funções foram utilizados o mapa com a superfície de custo de transporte, os mapas de produtividade de soja (1994-2012) e a lista dos principais portos exportadores de soja do Brasil, advindos da ANTAQ (Agência Nacional de

Transportes Aquaviários). Para determinar o período em que cada porto operou seu escoamento de soja (Tabela 2), utilizou-se o Sistema de Análise das Informações de Comércio Exterior, chamado AliceWeb, uma ferramenta da Secretaria do Comércio Exterior, do Ministério da Indústria e Comércio Exterior e Serviços (MDIC; AliceWeb, 2016). Verificou-se em todos os portos se havia operação de recebimento de soja para a exportação naquele ano. Os portos de Manaus e Santarém entraram na lista de operação do escoamento de soja apenas a partir do ano de 1997, enquanto os demais operam pelo menos desde 1994.

Tabela 2. Período de operação de escoamento da soja nos portos

Período	1994-1996	1997-2012
Manaus	-	✓
Santarém	-	✓
Ilhéus	✓	✓
Vitória	✓	✓
Santos	✓	✓
Paranaguá	✓	✓
São Francisco do Sul	✓	✓
Rio Grande	✓	✓

Para determinar o custo anual de transporte para cada pixel do mapa foi feito um filtro utilizando os mapas de área plantada de soja (Dias et al., 2016; mostrados na seção 2.2.1.4). Com este filtro foram mantidos no mapa de ocorrência de soja apenas pixels com área plantada de soja maiores que 5% da área do pixel (> 60,000 ha). Os pixels com menos de 5% não foram utilizados neste estudo. Por fim, os mapas anuais de menor custo de transporte foram

gerados. Deste modo, cada pixel do mapa contém o menor custo de transporte em relação a um dos portos.

2.2.2.2 Tamanho médio da fazenda

Nos mapas de tamanho da fazenda foi assumido que: (1) a área das propriedades rurais não varia com tempo, (2) o valor da área do pixel é a soma das médias das áreas rurais dentro deste pixel. Estes mapas foram produzidos a partir dos dados de tamanho da propriedade rural disponibilizados pelo censo do IBGE (Instituto Brasileiro de Geografia e Estatística) de 2006, onde estão contidos a área e o número de estabelecimentos agropecuários para cada município. O tamanho médio de estabelecimentos agropecuários foi calculado pela razão entre a área e o número de estabelecimentos rurais. A espacialização destes dados foi feita através do cruzamento da malha municipal de 2006 do IBGE. Em seguida, os mapas foram filtrados em função dos mapas de área plantada de soja (Dias et al., 2016; mostrados na seção 2.2.1.4) e reamostrados ano a ano para a resolução espacial de $1^{\circ} \times 1^{\circ}$ para comportarem apenas os pixels onde houve efetivo plantio de soja.

2.2.2.3 Preço da soja

Os dados de preço (Figura 6) utilizados neste trabalho são valores no momento do plantio. A base de dados principal utilizada foi a disponibilizada pelo Centro de Estudos Avançados em Economia Aplicada (CEPEA-Esalq), porém há disponibilidade somente a partir do ano 1998. Para os primeiros anos 1994-1997

foi utilizada a base de dados da série histórica anual disponibilizada pela FAOSTAT (*Food and Agriculture Organization of the United Nations – Statistics Division*). O produtor necessitará planejar ações futuras para obter melhor produtividade, para isto será necessário observar componentes de custos que auxiliarão na sua produção. Desta forma se faz necessária uma análise da viabilidade econômica da safra em questão, onde se adotam preços de produtos e fatores na época do plantio (Richetti, 2014). Seguindo esta premissa, este trabalho adotou o uso do preço da soja na época de seu plantio.

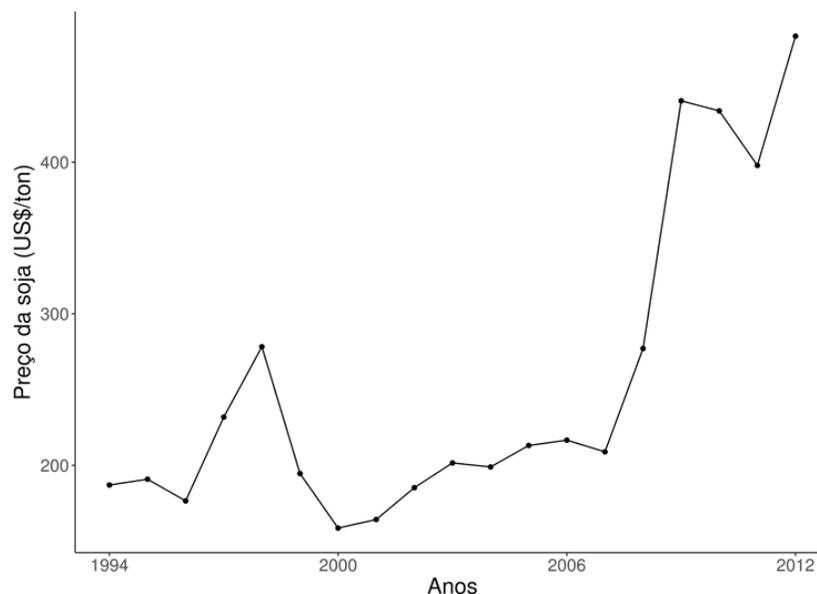


Figura 6. Preço da soja para o período de 1994-1997 (FAO, 2016) e 1998-2012 (CEPEA-Esalq, 2017).

2.3 Software para calibração do modelo biofísico e biofísico-econômico

A calibração dos modelos é uma importante ferramenta na realização das simulações já que os modelos mecanísticos possuem grande número de parâmetros, os quais necessitam de uma calibração eficaz para obter resultados

mais realísticos.

O procedimento de calibração deste trabalho teve como base o software Optis (Varejão et al., 2013), baseado no algoritmo genético NSGA-II (*Non-dominated Sorted Genetic Algorithm-II*). O Optis foi acoplado ao modelo INLAND por Fontes (2015), que tem como base uma calibração automática dos parâmetros de maneira multi ou mono-objetiva e hierárquica. Nesse trabalho foi utilizada apenas uma função objetiva, ou seja, uma calibração mono-objetiva, e dois níveis hierárquicos de calibração. Calibrar o modelo significa identificar os valores dos parâmetros que irão minimizar uma medida de erro (MAE, erro absoluto médio, ou RMSE, raiz do erro quadrático médio), entre os dados simulados e observados.

A calibração dos parâmetros (Tabela 3) foi dividida em duas etapas hierárquicas:

- Na etapa 1 foi feita uma calibração do modelo biofísico em modo pontual contra a produtividade obtida no sítio de soja em Tanguro apenas para o ciclo da soja para o período da safra 2015/2016, e esta versão foi designada como B_T . Os parâmetros resultantes e ajustados foram utilizados para a segunda etapa hierárquica.
- Na etapa 2 foi feita a calibração espacializada da produtividade do modelo biofísico contra os dados de Dias et al. (2016) em três experimentos, designados como B_9 , BE_1 e BE_9 , e abrangem a área com a produção de soja em todo o Brasil para o período de estudo.

Tabela 3. Parâmetros e divisão hierárquica das calibrações

Parâmetros	Nível hierárquico de calibração		Unidade	Descrição
	1	2		
LOTEMP	X		°C	Temperatura limite mínima
HITEMP	X		°C	Temperatura limite máxima
F1	X		adimensional	Constante utilizada na equação de temperatura
F2	X		adimensional	Constante utilizada na equação de temperatura
LAICONS	X		adimensional	Fator constante de diminuição do índice de área foliar
ALLCONSL	X		adimensional	Fator de diminuição da alocação de folha
ALLCONSS	X		adimensional	Fator de diminuição da alocação de tronco
DECLFACT	X		adimensional	Taxa de diminuição de índice de área foliar após enchimento de grãos
FLEAFI	X		fração	Fração inicial de alocação de carbono para as folhas
GRNFILL	X		fração	Fração de GDD necessária para a início de enchimento de grãos
ALPHA_C3	X		adimensional	Eficiência quântica de plantas do tipo C3
GAMMA	X		adimensional	Coefficiente de respiração das folhas
COEFM	X	X	mol m ⁻² s ⁻¹	Coefficiente de relação de condutância estomática (m)
COEFB	X		adimensional	Coefficiente de relação de condutância estomática (b)
VMAX_PFT	X	X	μmol[CO ₂] m ⁻² s ⁻¹	Atividade da Rubisco no PFT
SPECLA	X		m ² kg ⁻¹	Área específica da folha
Q10	X		adimensional	Parâmetro de ajuste da equação de fotossíntese
TEMPT	X		°C	Temperatura de ajuste da equação de fotossíntese
GDD _M		X	°C	GDD requerido para atingir a maturidade
β ₀		X	adimensional	Coefficiente econômico: interseção
β ₁		X	ton US\$ ⁻¹	Coefficiente econômico: custo mínimo de transporte
β ₂		X	ha ⁻¹	Coefficiente econômico: Tamanho médio da fazenda
β ₃		X	US\$ ⁻¹	Coefficiente econômico: Preço da soja

2.4 Descrição dos experimentos numéricos

Oito simulações foram conduzidas para avaliar a capacidade dos modelos em reproduzir a variabilidade espacial e temporal da produtividade de soja no Brasil durante o período 1994-2012, em um total de n=3877 pontos (número de pontos com soja x anos). Foram testados um modelo puramente biofísico (INLAND), um modelo puramente agroeconômico (modelo de regressão linear),

e um modelo híbrido biofísico-econômico (híbrido INLAND/linear). O modelo biofísico foi testado em três experimentos diferentes (B_{Ori} , B_T , B_9), assim como o modelo agroeconômico, que também foi testado em três experimentos (E_1 , E_9 , E_{C9}). Já o modelo biofísico-econômico foi testado em dois experimentos (BE_1 , BE_9), que são descritos a seguir.

O experimento B_{Ori} é uma simulação para o período de 1994-2012 do modelo biofísico com os parâmetros originais do modelo AgriBIS validados para um cultivar de soja norte-americana (Kucharik e Twine, 2007). A produtividade simulada neste experimento tem como finalidade dar um ponto de partida para mostrar as possíveis melhorias do procedimento introduzidas pelos avanços nos modelos e no procedimento de calibração dos experimentos seguintes.

O próximo experimento realizado foi a calibração da produtividade de soja utilizando os dados do sítio experimental de Tanguro com a otimização do Optis. O modelo INLAND foi parametrizado para simular exatamente o ciclo da produtividade de soja no sítio. As variáveis de máximo GDD requerido para atingir a maturidade fisiológica e a temperatura base para acumulação de GDD (*baset*) foram fixadas em 2018°C.dia e 10°C, respectivamente. Nessa simulação o modelo foi configurado com a mesma data do plantio observada, respeitando o ciclo observado da soja em Tanguro, que teve seu plantio em 2 de dezembro de 2015 e colheita em 7 de abril de 2016 (safra 2015-2016). O experimento B_T é uma simulação regional para o período de 1994-2012 do modelo biofísico com os parâmetros resultantes da calibração do experimento pontual de Tanguro.

O experimento E_1 compreende uma estimativa da produtividade de soja

utilizando o método dos mínimos quadrados, para o período de 1994-2012, pelo modelo econômico mostrado na Equação 1, onde não há influência de variáveis biofísicas.

No experimento E_9 , foi feita uma estimativa da produtividade de soja utilizando a metodologia do modelo E_1 com a divisão em nove grupos, sendo três faixas de temperatura e três períodos, analogamente ao especificado na descrição do modelo B_9 .

O experimento E_{C9} compreende a mesma estrutura do modelo anterior, porém com a inclusão de duas variáveis climáticas: precipitação e temperatura. Para este experimento os dados de precipitação são o acumulado da precipitação por pixel considerando um ciclo de soja de 120 dias. Para os dados de temperatura, foi utilizada a média da temperatura no pixel para o mesmo período do ciclo de soja.

No experimento B_9 foi feita a calibração utilizando apenas as variáveis biofísicas considerando três faixas de temperatura (t) ($t < 24^\circ\text{C}$; $24^\circ\text{C} \leq t \leq 26^\circ\text{C}$ e $t > 26^\circ\text{C}$) e três períodos (1994-2000, 2001-2006 e 2007-2012) totalizando 9 simulações. As faixas de temperatura (Figura 7) foram definidas fazendo-se uma média da estação de crescimento com os dados diários de forçantes atmosféricas do PTHRG (Sheffield et al., 2006), em três faixas: amenas, quentes e muito quentes. Esse desenho experimental visa simular a variação espacial e temporal das cultivares de soja. As três faixas de temperatura usam cultivares com valores crescentes de GDD_m , enquanto os três intervalos de tempo representam a evolução temporal dos cultivares em direção a variedades mais

produtivas. A duração de cada período (6-7 anos) foi escolhida por ser o tempo médio de lançamento de novos cultivares (Albuquerque e Silva, 2008).

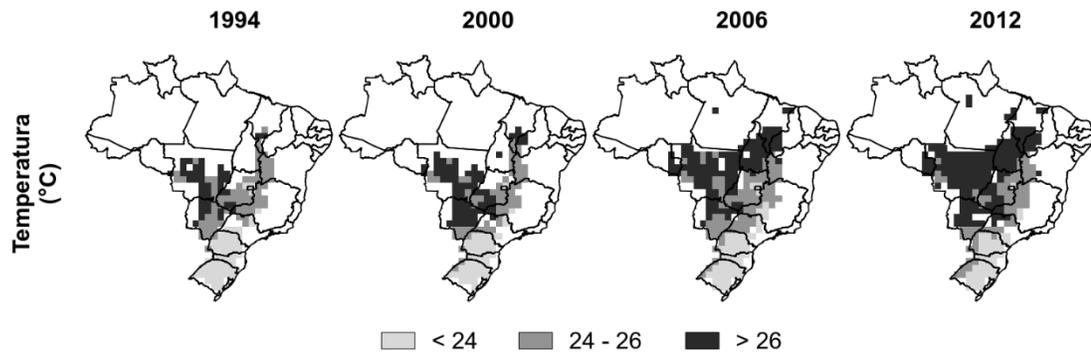


Figura 7. Faixas de temperaturas médias da estação de crescimento para anos selecionados.

No experimento BE_1 foi realizada uma calibração utilizando as variáveis biofísicas e econômicas descritas na Equação 2 do modelo biofísico-econômico. A calibração deste modelo foi feita com todos os pontos com soja nos dezenove anos corridos ($n=3877$). Os parâmetros biofísicos utilizados nesta calibração foram: $hb added$, máximo de acúmulo de graus dia para iniciar a fase de maturidade (Kucharik, 2003); $vmax$, que é a taxa máxima de carboxilação da enzima Rubisco ($\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$); e $coefm$, que é um coeficiente de condutância estomática utilizado na equação que descreve a taxa de captação líquida de CO_2 na superfície foliar (Collatz et al., 1991). Os parâmetros econômicos utilizados nesta calibração foram os parâmetros do modelo descrito na Equação 2.

Para o experimento BE_9 foi realizada a calibração com a mesma estrutura que o experimento B_9 , porém com a inclusão dos parâmetros econômicos.

3 Resultados e discussão

3.1 Mapas de custo mínimo de transporte

O mapa de custo de transporte (Figura 8) é resultado do cruzamento do mapa de rodovias federais classificadas pelo tipo de pavimentação (pavimentadas, não-pavimentadas e vicinais) com os coeficientes de custo por tonelada (US\$ ton⁻¹) mostrados por Vera-Dias et al. (2009).

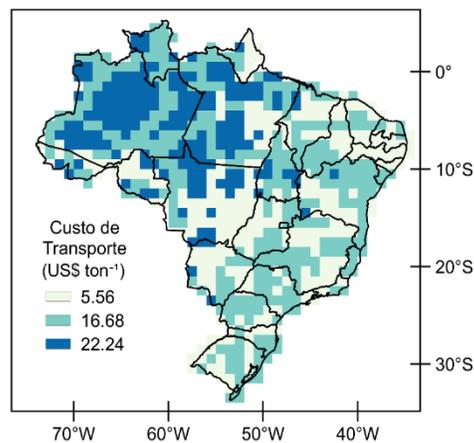


Figura 8. Custo para transportar uma tonelada de soja através de cada pixel.

Observa-se que no mapa a classificação tem maior valor onde se encontram grande parte das estradas vicinais, por exemplo, no norte do Mato Grosso, centro e norte do Pará e Amazonas central. Nos pixels contemplados por rodovias pavimentadas e não-pavimentadas, os valores do custo são menores.

O mapa de custo mínimo de transporte (Figura 9) acompanhou anualmente a evolução da produção de soja e sua expansão do Centro-Oeste para a região do MATOPIBA (Mato Grosso, Tocantins, Piauí e Bahia) e, principalmente, do escoamento de soja nos portos. Nos anos 1994-1997, seis portos operavam a exportação de soja. Já a partir de 1997 até o ano de 2012, este número passou para oito. A soja produzida no estado do Mato Grosso possui um maior custo devido à distância dos portos e a precariedade das estradas não-pavimentadas para o escoamento da soja. As variações nos custos ocorreram apenas em regiões que foram influenciadas pelo início da operação de soja em novos portos.

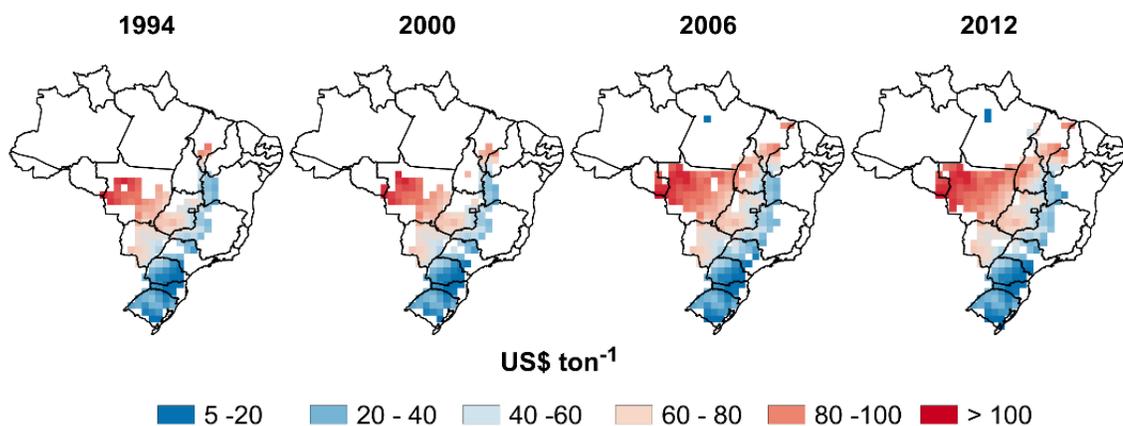


Figura 9. Custo mínimo de transporte para anos selecionados.

A Figura 10 mostra um resultado intermediário do processo de cálculo para soja a ser escoada de Cuiabá – MT (Figura 10a) e Sorriso – MT (Figura 10b). Os mapas mostram o custo de transporte do ponto de origem para qualquer ponto do país. Valores em tons azuis possuem menores custos e tons amarelo e vermelho representam custos maiores. Nestes mapas o custo mínimo é o menor custo partindo daquele ponto dentre todos os portos. O custo de transporte de Cuiabá a Santarém e de Sorriso a Santos foram comparados com os valores apresentados por Vera-Diaz et al. (2009) e IMEA (2016). O custo de transporte partindo de Cuiabá para Santarém é de aproximadamente US\$ 132 por tonelada, valor 30% superior ao mostrado por Vera-Diaz et al. (2009), US\$ 101 por tonelada; para o custo de transporte partindo de Sorriso para Santos, o valor é de US\$ 119 por tonelada, 32% maior que o valor apresentado pelo IMEA (2016), US\$ 90 por tonelada.

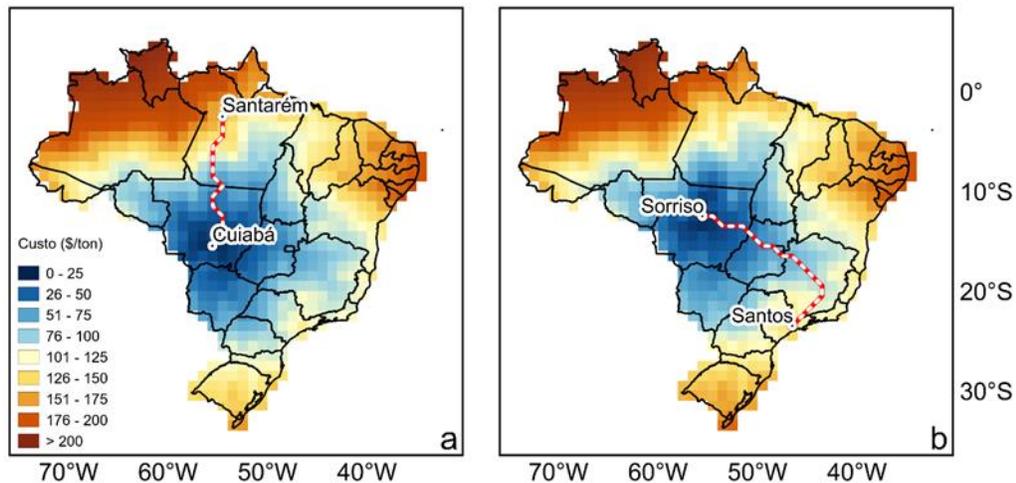


Figura 10. Custo de transporte a partir de Cuiabá (a) e Sorriso (b) para qualquer ponto do país.

Na Figura 11 é possível ver a evolução temporal dos pontos de menor custo de transporte para cada pixel. Nos primeiros anos (1994-1997) os pontos de produção de soja do estado do Mato Grosso eram escoados totalmente pelos portos de Ilhéus – BA e Paranaguá/São Francisco do Sul – PR. A partir da abertura do escoamento da soja para os portos de Manaus e Santarém, os pontos do norte do Mato Grosso e da região do MATOPIBA passaram a escoar por estes portos.

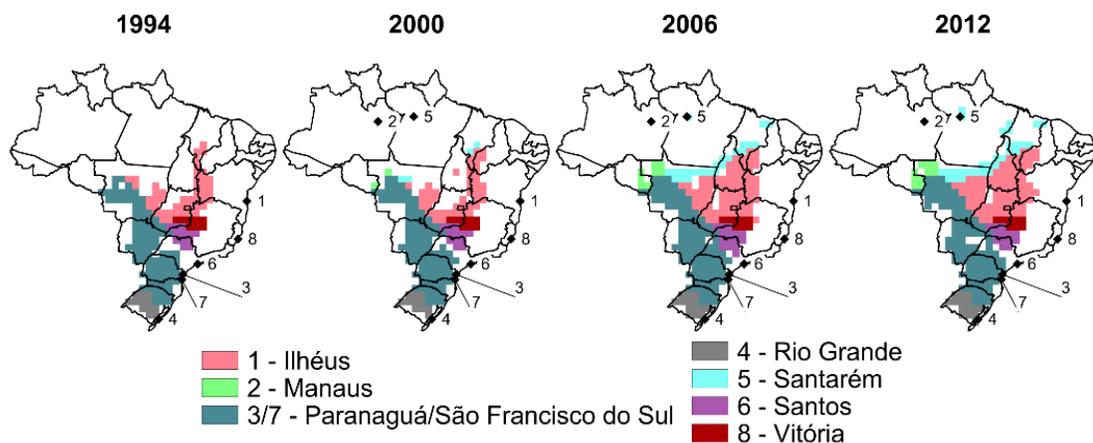


Figura 11. Distribuição dos pixels de custo mínimo de transporte para escoamento da soja para os portos, para anos selecionados.

3.2 Mapas de tamanho da fazenda

Os mapas de tamanho da fazenda são mostrados na Figura 12. Um mesmo pixel possui o mesmo valor para todos os anos. A diferença entre os mapas, de um ano para o outro, ocorre devido às novas áreas de expansão da soja para o interior do Brasil. As maiores fazendas, em média, estão localizadas em municípios do Estado do Mato Grosso (MT), onde também os maiores produtores de soja estão localizados nesta região. Entre os cinco municípios com

maiores fazendas, quatro estão no MT, sendo Sapezal o município com o maior tamanho médio (6079 ha). Já os municípios de Corumbá, Santo Antônio de Leverger e Itiquira, no Estado do Mato Grosso do Sul (MS) têm as fazendas com menores médias (0,59 ha).

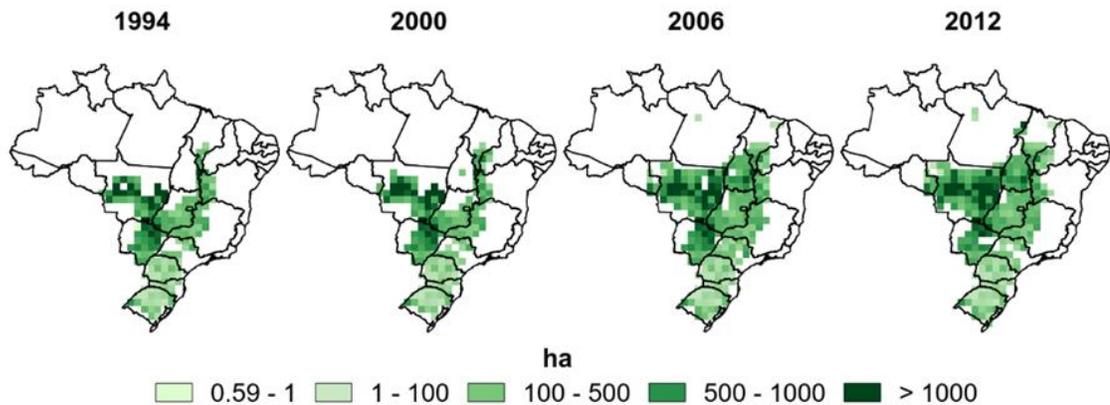


Figura 12. Tamanho médio das fazendas em cada pixel de $1^{\circ} \times 1^{\circ}$, para anos selecionados.

3.3 Simulações da produtividade de soja

No experimento pontual, a produtividade simulada, utilizando a otimização do Optis, foi idêntica à produtividade de $3,1 \text{ ton ha}^{-1}$ observada em Tanguro (Canarana – MT) em um ciclo de 126 dias (Divino Silvério, comunicação pessoal). Antes da calibração, usando os parâmetros originais, a produtividade simulada para este sítio era de $0,11 \text{ ton ha}^{-1}$, representando apenas 3,54% do total observado em Tanguro. Este resultado reforça a importância e a necessidade de uma calibração dos parâmetros biofísicos do modelo para uma estimativa realista da produtividade de soja no país. Os parâmetros biofísicos calibrados (Tabela 4) neste experimento foram utilizados como parâmetros fixos nas simulações dos experimentos seguintes.

Tabela 4. Parâmetros utilizados calibração do sítio experimental

Parâmetro	Original (Kucharik e Twine, 2007)	Faixa permitida		Otimizado
		Mínimo	Máximo	
LOTEMP	4,0	2,4	5,6	3,6
HITEMP	38,0	22,8	40,0	39,71
F1	0,40	0,24	0,56	0,24
F2	0,40	0,24	0,56	0,49
LAICONS	1,0	0,6	1,4	1,23
ALLCONSL	2,0	1,2	2,8	1,83
ALLCONSS	3,0	1,8	4,2	3,78
DECLFACT	1,0	0,6	1,4	0,60
FLEAFI	0,95	0,57	1,0	0,97
GRNFILL	0,625	0,375	0,875	0,63
ALPHA_C3	0,080	0,048	0,112	0,11
GAMMA	0,015	0,009	0,021	0,009
COEFM	9,0	5,4	12,6	6,58
COEFB	0,01	0,006	0,014	0,006
VMAX_PFT	45,0	27,5	63,5	53,5
SPECLA	27,4	16,44	38,36	37,59
Q10	2,6	2,0	3,0	2,9
TEMPT	15	11,0	16,0	13,7

Uma síntese dos experimentos em escala nacional é apresentada na Tabela 5 e na Figura 13.

Tabela 5. Síntese dos experimentos. \bar{Y} é a média calculada da produtividade durante todo o período do experimento (n=3877). $\bar{\mathcal{E}}$ é o erro em relação da média do observado com a média do simulado. O RMSE é o erro médio quadrático. Na equação de regressão, y é o simulado e x representa o observado. E r é a correlação

Experimentos	\bar{Y} (ton ha ⁻¹)	$\bar{\mathcal{E}}$ (ton ha ⁻¹)	RMSE (ton ha ⁻¹)	Equação de regressão	r
<i>B_{Ori}</i>	2,59	0,01	1,02	$y = -0,059x + 2,7$	-0,032
<i>B_T</i>	8,78	6,20	6,35	$y = 0,33x + 7,9$	0,12
<i>E₁</i>	2,57	-0,01	0,408	$y = 0,28x + 1,9$	0,53
<i>E₉</i>	2,51	0,06	0,400	$y = 0,29x + 1,8$	0,57
<i>E_{C9}</i>	2,57	-0,01	0,334	$y = 0,51x + 1,3$	0,72
<i>B₉</i>	1,96	-0,62	0,955	$y = 0,38x + 0,98$	0,24
<i>BE₁</i>	2,36	-0,22	0,662	$y = 0,33x + 1,5$	0,28
<i>BE₉</i>	2,57	-0,01	0,421	$y = 0,43x + 1,5$	0,55
<i>Y_{OBS}</i>	2,58	--	--	--	--

O resultado do experimento *B_{Ori}* reflete a configuração do modelo que utiliza os parâmetros originais herdados do modelo AgrolBIS advindos de parâmetros para uma soja de variedade norte-americana. Em geral, as variedades de soja diferem com relação à resposta ao clima, afetando assim o ajuste entre simulado e observado, mesmo que na média de uma simulação estes valores sejam semelhantes. Na Figura 13A é possível observar como estas diferenças afetam a dispersão dos valores de produtividade simulada e observada. O coeficiente angular da reta desta dispersão foi negativo (-0,059), o que mostra que parâmetros norte-americanos não reproduzem corretamente uma simulação da produtividade de soja no Brasil. Porém por um acaso, o erro médio ($\bar{\mathcal{E}}$) ficou próximo de zero.

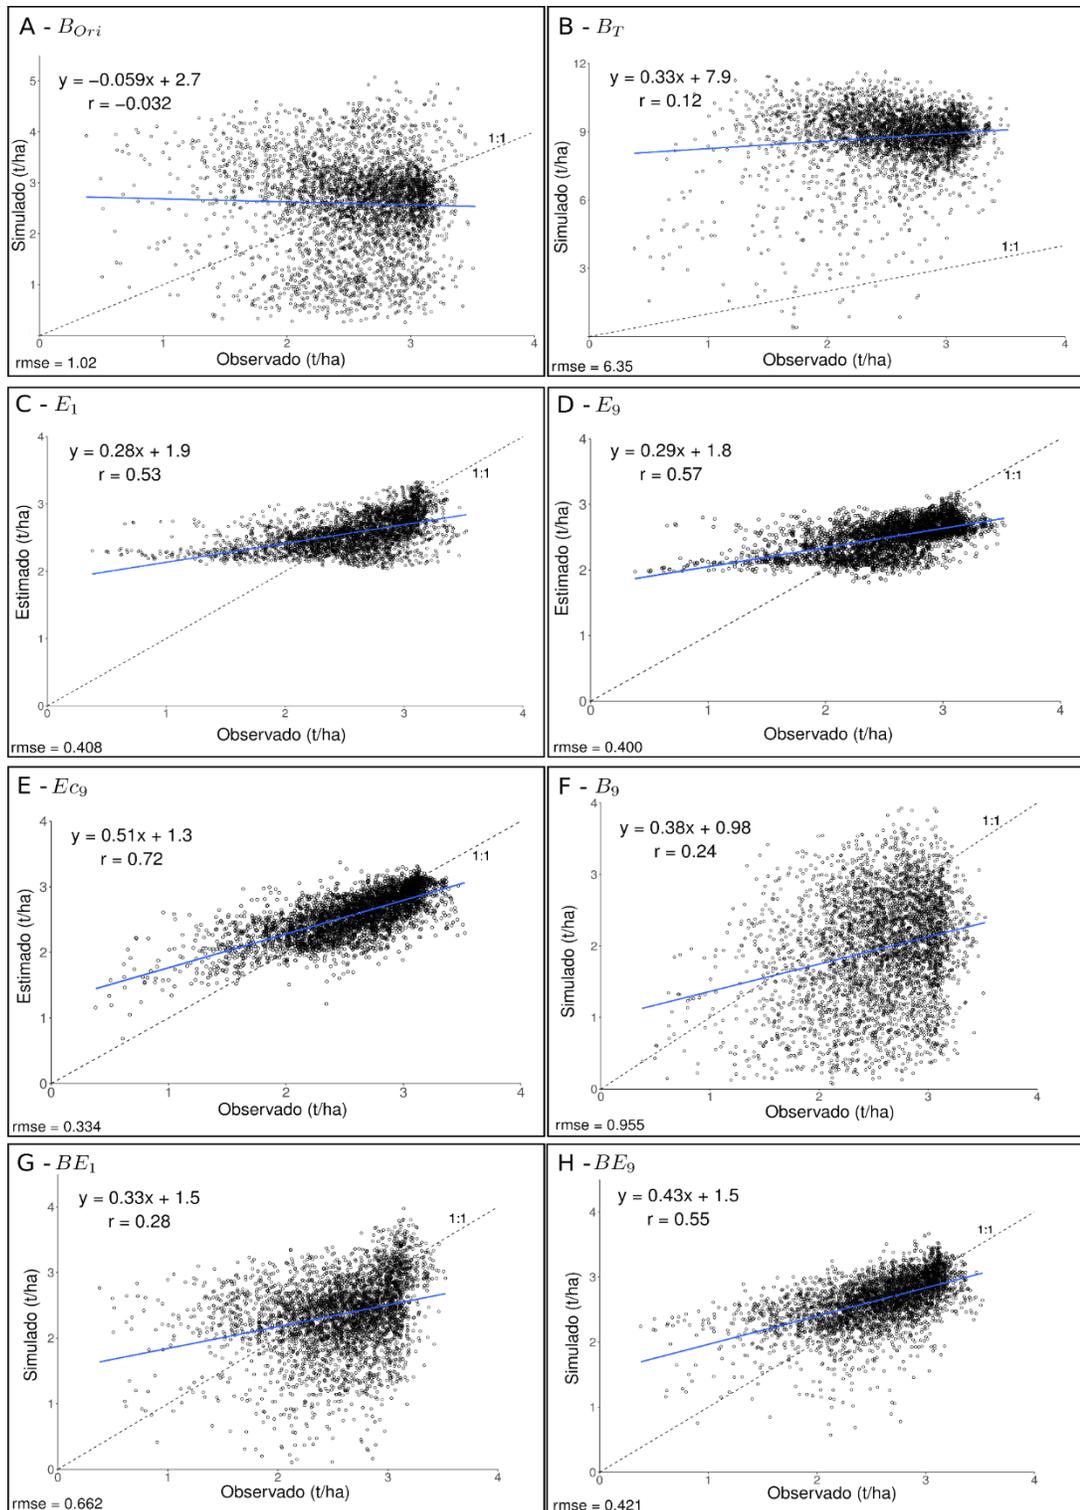


Figura 13. Correlações entre produtividade simulada pelo INLAND e observado. A) Modelo Biofísico com parâmetros originais (B_{Ori}); B) Modelo Biofísico com parâmetros de Tanguro (B_T); C) Modelo econômico (E_1); D) Modelo econômico com 9 grupos (E_9); E) Modelo econômico climático com 9 grupos (EC_9); F) Modelo biofísico otimizado com 9 grupos (B_9); G) Modelo Biofísico-Econômico otimizado com 1 grupo (BE_1); H) Modelo Biofísico-Econômico otimizado com 9 grupos (BE_9).

O experimento B_T é o primeiro a receber os parâmetros herdados da calibração de Tanguro. A inserção destes parâmetros no modelo do experimento biofísico B_T elevaram a produtividade em 240% em relação à simulação do modelo biofísico B_{Ori} . A produtividade simulada tem um valor médio de 8,78 ton ha⁻¹, enquanto o observado é de 2,59 ton ha⁻¹ (Tabela 5; Figura 13B). Neste experimento, a produtividade simulada é considerada potencial, uma vez que não há limitantes implícitos como pragas e manejo.

Os parâmetros biofísicos que foram calibrados no modelo pontual têm melhor aproveitamento na área onde está a Fazenda Tanguro, porém não é aconselhável estendê-los para uma região maior como o Brasil todo, visto que, estes parâmetros variam de uma região para a outra. O coeficiente angular da reta (0,33) deste modelo (Figura 13B) mostra que há melhora em relação ao modelo anterior, porém com resultado ainda com baixa correlação. Nesse caso, mostra-se a necessidade de uma segunda calibração, utilizando apenas alguns parâmetros biofísicos que são mais sensíveis para uma região maior, e parâmetros econômicos, como custo mínimo de transporte, tamanho médio da fazenda e preço da soja.

Os resultados do experimento do modelo econômico E_1 mostraram um erro médio de -0,01 ton ha⁻¹ em relação à produtividade observada e correlação de 0,53 (Tabela 5). Este resultado agregou fatores limitantes, como os dados de custo de transporte, tamanho da fazenda (log) e preço da soja. O modelo estimado desta regressão é descrito na Equação 1, e pode ser equiparado ao resultado encontrado por Garrett et al. (2013a). Estes autores verificaram relação

negativa da produtividade com o custo mínimo de transporte e positiva com o tamanho médio da fazenda (log), alcançando correlação de 0,64. Os resultados da regressão linear múltipla (Tabela 6) mostram que a relação da produtividade com o custo mínimo de transporte, tamanho médio da fazenda (log) e preço da soja com a produtividade observada é positiva. O RMSE entre a produtividade estimada e observada é de 0,4 ton ha⁻¹. A diferença do sinal no coeficiente do custo mínimo de transporte é devida ao número maior de variáveis utilizado por Garrett et al. (2013a). Em seu trabalho, há variáveis como declividade; valores institucionais de investimento e valores de créditos governamentais, como os aplicados no estado do Mato Grosso, onde ocorre a maior produtividade de soja. Estas variáveis não foram consideradas neste trabalho pois não há informações com a variação temporal, e provavelmente teriam influenciado no sinal do coeficiente do custo mínimo de transporte.

Tabela 6. Parâmetros do modelo econômico e sua significância

Coefficientes econômicos	Valor	P
α_0 (ton ha ⁻¹)	1,705192163	0
α_1 (US\$ ton ⁻¹)	0,005787327	4,76e-111
α_2 (adimensional)	0,027110807	0,03904
α_3 (US\$ ton ⁻¹)	0,001565816	1,48e-128
r = 0,529		
RMSE = 0,408 ton ha⁻¹		

A dispersão entre a produtividade estimada pelo modelo econômico e a observada é mostrada na Figura 13C. Nota-se que o modelo simula melhor valores mais altos de produtividade, mas não estima valores menores que 2 ton ha⁻¹, por exemplo. Para pontos com produtividades baixas, a produtividade

estimada foi mais alta porque este modelo não sofre influência biofísica. Por exemplo, o modelo não é capaz de representar um evento de seca, dessa forma, regiões (pixels) que têm sua produtividade reduzida quando há influência de um evento climático extremo, acabam atingindo produtividade muito maior que a observada.

Neste ponto, mais dois experimentos com o modelo econômico foram realizados como forma de comparação com os modelos biofísico-econômico. O modelo E_9 (Figura 13D) mostra em sua dispersão que, mesmo com a divisão por faixas de temperatura e períodos, continua não havendo uma simulação dos pontos com produtividade mais baixa. Isso demonstra que ainda há falta da influência de variáveis climáticas, no entanto este modelo tem uma correlação um pouco melhor que o experimento E_1 , de $r=0,57$. Partindo desta análise, foi realizado o experimento E_{C9} , e a dispersão deste (Figura 13E) mostra que com a inclusão de duas variáveis climáticas, precipitação e temperatura, levou à melhor correlação entre os experimentos, $r=0,72$ e um coeficiente de reta de 0,51. Com isso é possível demonstrar que as variáveis climáticas diminuem os pontos onde valores mais altos de produtividade eram estimados erroneamente.

Para o modelo B_9 foram feitas duas simulações otimizadas. Na primeira todos os valores das três variáveis biofísicas otimizadas tenderam para o mínimo em todas as faixas de temperatura e períodos. Resultou em um RMSE de $2,94 \text{ ton ha}^{-1}$ bastante acima da média. Portanto, foram feitas novas simulações configurando os mínimos de $coefm$ e $Vmax$ para a metade de seus valores. Nessa segunda simulação (Figura 13F) a correlação foi de 0,24 com um

coeficiente da reta de 0,38 e um alto RMSE (0,955). No entanto, as variáveis tenderam ainda mais para os valores mínimos permitidos, incompatíveis com os observados. Neste caso, há uma indicação que variáveis biofísicas apenas não são suficientes para simular a produtividade da soja em escala nacional e ao longo de um período tão longo.

A partir desse ponto, os mapas de custo de transporte, tamanho da fazenda e preço da soja foram incorporados como dados de entrada ao modelo INLAND, tornando-o assim um modelo biofísico-econômico.

O modelo BE_1 teve como resultados um erro na produtividade média de $-0,22 \text{ ton ha}^{-1}$ com uma correlação baixa de 0,28 (Tabela 5; Figura 13G), e o coeficiente angular da reta é igual a 0,33, melhor que o apresentado pelo modelo econômico, E_1 . O que resultou essa baixa correlação foi a utilização de apenas um cultivar de soja não considerando a divisão dos pontos em faixas de temperatura e, também, à falta de tendência no aumento da produtividade de soja com a divisão em três períodos, o que foi feito no próximo experimento.

Partindo do experimento BE_1 foram utilizadas as divisões de faixas de temperatura e períodos. O modelo BE_9 chegou ao melhor resultado entre os experimentos com modelos biofísicos, com um erro de médio de $0,01 \text{ ton ha}^{-1}$, uma melhor correlação, 0,55 (Figura 13H), e também o melhor do coeficiente angular da reta que foi de 0,43. Assim, a calibração feita por períodos de tempo e regiões representou melhor a produtividade simulada. A Tabela 7 mostra os valores de RMSE para cada período de simulação em suas três faixas de temperaturas e, também, os valores otimizados para as variáveis biofísicas e

econômicas.

Neste experimento é possível encontrar pequenas variações aceitáveis nas variáveis biofísicas. Os valores de assimilação fotossintética ficaram entre valores aceitáveis, estando dentro da faixa 25 e 42 $\mu\text{mol}[\text{CO}_2] \text{ m}^{-2} \text{ s}^{-1}$ encontrada experimentalmente por Vu et al. (1997). Os valores de GDD acompanham o deslocamento das faixas de temperatura. Para temperaturas amenas ($t < 24^\circ\text{C}$), foi estabelecida uma variação de 1200 a 1500 $^\circ\text{C.dia}$, para temperaturas quentes ($24^\circ\text{C} \leq t \leq 26^\circ\text{C}$) de 1500 a 1800 $^\circ\text{C.dia}$, e para a faixa com temperaturas muito quentes ($t > 26^\circ\text{C}$), um GDD entre 1800 e 2100 $^\circ\text{C.dia}$, similares aos parâmetros testados por Alliprandini et al. (2009).

Tabela 7. Parâmetros otimizados na segunda calibração e valores de RMSE, separados por faixas de temperatura e períodos para o modelo BE_9

t < 24°C						
		Faixa de parâmetros otimizados		1994-2000	2001-2006	2007-2012
		Min	Max	Otimizado	Otimizado	Otimizado
GDD_m	°C	1200	1500	1497,12	1495,14	1250,42
m	mol m ⁻² s ⁻¹	5,40	12,60	6,17	5,65	12,35
Vmax	μmol[CO ₂] m ⁻² s ⁻¹	26,0	50,0	28,5	26,06	27,46
β₀	adimensional	-0,3	3,00	0,29618	0,36236	0,38907
β₁	ton US\$ ⁻¹	-0,2	0,02	-0,00061	-0,00036	0,00032
β₂	adimensional	-0,2	1,00	0,00936	0,00394	-0,00393
β₃	US\$ ⁻¹	0	0,12	7,62 x 10 ⁻⁸	4,9 x 10 ⁻⁶	5,58 x 10 ⁻⁵
			RMSE	0,526	0,658	0,466
24°C ≤ t ≤ 26°C						
		Faixa de parâmetros otimizados		1994-2000	2001-2006	2007-2012
		Min	Max	Otimizado	Otimizado	Otimizado
GDD_m	°C	1500	1800	1799,12	1523,08	1695,32
m	mol m ⁻² s ⁻¹	5,40	12,60	5,91	5,52	5,90
Vmax	μmol[CO ₂] m ⁻² s ⁻¹	26,0	50,0	27,29	43,8	27,11
β₀	adimensional	-0,3	3,00	0,28636	0,28962	0,38996
β₁	ton US\$ ⁻¹	-0,2	0,02	0,00120	0,00183	0,00026
β₂	adimensional	-0,2	1,00	-0,00489	-0,01116	0,00406
β₃	US\$ ⁻¹	0	0,12	1,36 x 10 ⁻⁹	6,84 x 10 ⁻⁵	7,99 x 10 ⁻⁸
			RMSE	0,431	0,455	0,434
t > 26°C						
		Faixa de parâmetros otimizados		1994-2000	2001-2006	2007-2012
		Min	Max	Otimizado	Otimizado	Otimizado
GDD_m	°C	1800	2100	1917,70	2097,52	1842,89
m	mol m ⁻² s ⁻¹	5,40	12,60	6,64	9,79	10,44
Vmax	μmol[CO ₂] m ⁻² s ⁻¹	26,0	50,0	26,50	34,57	26,83
β₀	adimensional	-0,3	3,00	0,35986	0,26629	0,39293
β₁	ton US\$ ⁻¹	-0,2	0,02	0,00046	0,00075	0,00011
β₂	adimensional	-0,2	1,00	-0,00368	-0,00756	-0,00453
β₃	US\$ ⁻¹	0	0,12	3,71 x 10 ⁻⁶	1,28 x 10 ⁻¹¹	2,36 x 10 ⁻⁹
			RMSE	0,401	0,338	0,248

3.4 Discussão

De acordo com a seção anterior, os resultados do modelo BE_9 , que incorporou as variáveis econômicas e as divisões por faixas de temperatura e períodos, apresentou melhor simulação da produtividade de soja entre os modelos biofísicos. O modelo econômico E_1 apresentou uma correlação próxima ao do modelo BE_9 , porém não explica os pontos com produtividade baixa. Assim, para confrontar este resultado do modelo puramente econômico foram incluídas duas variáveis climáticas – precipitação e temperatura – que fizeram com que o modelo econômico E_{C9} alcançasse uma melhor correlação. O modelo BE_9 incorpora em seu resultado melhor heterogeneidade espacial na representação da produção de soja, considerando três tipos de cultivares e três períodos, onde pode-se ter variação melhor da produção nacional.

Os coeficientes econômicos (β_1 , β_2 e β_3) apresentados na Tabela 7 devem ser analisados conjuntamente com as variáveis X_1 , X_2 e X_3 e com a variação espacial e temporal da produtividade de soja do modelo biofísico INLAND (Y_B). Desta forma, na Tabela 8 é mostrada a variação dos termos da Equação 2 ($\beta_1 X_1$, $\beta_2 X_2$ e $\beta_3 X_3$), enquanto a Tabela 9 mostra os valores em ton ha^{-1} para o produto de cada termo da Equação 2 com o valor de Y_B , no caso do modelo BE_9 , e da Equação 1 para o modelo E_1 . Com isso é possível observar o quanto as variáveis econômicas têm de influência no resultado da produtividade do modelo biofísico (Y_B) da Equação 2.

Para a variável de custo de transporte (X_1) o coeficiente β_1 mostra-se negativo apenas nos primeiros dois períodos da faixa mais amena. Para as outras

faixas e períodos este coeficiente é positivo. No entanto analisar somente o coeficiente não é suficiente, sendo necessário analisar o produto desse coeficiente com os valores de X_1 e Y_B (Tabelas 8 e 9). Com este produto é possível notar que na faixa amena, mesmo os valores do coeficiente sendo negativos nos dois primeiros períodos, o impacto significativo é pequeno no resultado de Y_B ($<0,347 \text{ ton ha}^{-1}$). Na faixa quente há influência de até 25,3% (Tabela 8) o que se pode traduzir em até $1,832 \text{ ton ha}^{-1}$ (Tabela 9) sobre Y_B , para o período 2001-2006. No mesmo período, para a faixa muito quente há, influência de até 10,4% (Tabela 8), o que se pode traduzir em até $1,162 \text{ ton ha}^{-1}$ na produtividade do de soja do modelo biofísico (Y_B).

Para a variável de tamanho médio da fazenda (X_2) é onde pode-se observar mais ocorrências de valores negativos no coeficiente. Para o último período da faixa amena, o valor do produto tem influência de até 5,8% (Tabela 8), o que pode ser traduzido em até $0,451 \text{ ton ha}^{-1}$ sobre Y_B . Os maiores impactos são mostrados nas faixas quentes e muito quentes, onde também ficam as maiores fazendas. Na primeira, influência de -9,7% (Tabela 8), o que traduz em $-0,665 \text{ ton ha}^{-1}$, no segundo período (2001-2006). Na faixa muito quente há influência de -6,6% no segundo período e de -3,9% no último período, o que traduz em $-0,715 \text{ ton ha}^{-1}$ e $-0,365 \text{ ton ha}^{-1}$ sobre Y_B , respectivamente.

Para a variável do preço da soja (X_3), o coeficiente β_3 , em todas as faixas de temperatura, mostra influencia não significativa sobre Y_B não sendo maior que $0,187 \text{ ton ha}^{-1}$.

Tabela 8. Faixas de variação de β_1X_1 , $\beta_2\log X_2$ e β_3X_3 , para o modelo BE_9

Y_{BE9}						
$t < 24^\circ\text{C}$						
	1994-2000		2001-2006		2007-2012	
	Min	Max	Min	Max	Min	Max
β_1X_1 (adimensional)	-0,048	-0,003	-0,024	-0,002	0,002	0,021
$\beta_2\log X_2$ (adimensional)	0,020	0,058	0,008	0,024	-0,024	-0,008
β_3X_3 (adimensional)	$1,21 \times 10^{-5}$	$2,12 \times 10^{-5}$	0,0008	0,001	0,012	0,027
$24^\circ\text{C} \leq t \leq 26^\circ\text{C}$						
	1994-2000		2001-2006		2007-2012	
	Min	Max	Min	Max	Min	Max
β_1X_1 (adimensional)	0,040	0,177	0,045	0,253	0,008	0,036
$\beta_2\log X_2$ (adimensional)	-0,043	-0,011	-0,097	-0,024	0,009	0,035
β_3X_3 (adimensional)	$2,40 \times 10^{-7}$	$3,78 \times 10^{-7}$	0,011	0,015	$1,67 \times 10^{-5}$	$3,86 \times 10^{-5}$
$t > 26^\circ\text{C}$						
	1994-2000		2001-2006		2007-2012	
	Min	Max	Min	Max	Min	Max
β_1X_1 (adimensional)	0,015	0,068	0,025	0,104	0,004	0,015
$\beta_2\log X_2$ (adimensional)	-0,032	0,002	-0,066	0,004	-0,039	0,002
β_3X_3 (adimensional)	0,0006	0,001	$2,11 \times 10^{-9}$	$2,59 \times 10^{-9}$	$4,94 \times 10^{-7}$	$1,04 \times 10^{-6}$

A influência de β_1 e β_2 é pequena, quando comparada a β_0 , que faz a maior diferença nessa equação. O produto desse coeficiente com Y_B faz a correção da produtividade Y_B sem ter que forçar o modelo a utilizar valores das variáveis biofísicas fora das faixas consideradas aceitáveis, como ocorreu com o modelo B_9 . Para o β_0 pode-se supor que ao considerar um pixel grande ($1^\circ \times 1^\circ$), arrume-se que os tamanhos da fazenda serão menores que o tamanho deste pixel e os dados de clima e solo são homogêneamente distribuídos neste pixel. No entanto, ao se considerar um pixel grande (12 mil km^2), a real distribuição da precipitação, por exemplo, pode não ser homogênea, causando um estresse hídrico em uma parcela deste pixel, assim ocasionando uma diminuição na

produtividade. Desta forma, o efeito dessas variações dentro de cada pixel são estimadas pelo β_0 , deduzindo-se, assim, uma representação da variabilidade biofísica de subgrade. Porém, somente β_0 não é suficiente para melhorar o ajuste de Y_B , é necessário contabilizar o custo de transporte e o tamanho da fazenda, por mais que hajam limitações nestas variáveis.

Por outro lado, é possível notar nas Tabelas 6 e 7 que no modelo puramente econômico E_1 , o preço da soja é uma variável significativa sobre a produtividade, sendo que os máximos, tanto do termo custo de transporte ($\alpha_1 X_1$) quanto preço da soja ($\alpha_3 X_3$), ficaram acima do RMSE desse modelo (0,408). Como esse modelo não foi dividido por períodos e faixas de temperatura, essas variáveis podem estar representando a influência de outros processos. O coeficiente do custo de transporte positivo ($\alpha_1 > 0$) mostra que quanto mais caro o custo, mais há produção de soja, o que não é intuitivo. Isto pode ser explicado também pela abrangência espacial do modelo, pois os maiores custos de transporte ocorrem onde estão as maiores produções de soja, o que pode ter ocasionado o alto valor para esse coeficiente. Já a variável preço da soja, significativa nesse modelo, pode ter assimilado a variação da tendência tecnológica no período, enquanto que no modelo BE_9 , esta tendência está presente nos diferentes valores das variáveis biofísicas no tempo e na divisão de faixas de temperatura.

Tabela 9. Efeitos na produtividade (ton ha⁻¹) para cada termo dos modelos BE_9 e E_1 (Equações 1 e 2). Y_B é o resultado do modelo biofísico (INLAND) no contexto da Equação 2. Valores seguidos pela letra (^a) são discutidos no texto

Y_{BE}						
t < 24°C						
	1994-2000		2001-2006		2007-2012	
	Min	Max	Min	Max	Min	Max
$\beta_0 Y_B$	0,668	2,557	0,736	2,840	1,203	3,051
$\beta_1 X_1 Y_B$	-0,347	-0,026	-0,157	-0,012	0,012	0,145
$\beta_2 \log X_2 Y_B$	0,058	0,451	0,027	0,157	-0,158	-0,043
$\beta_3 X_3 Y_B$	$3,22 \times 10^{-5}$	0,0002	0,002	0,008	0,036	0,187
24°C ≤ t ≤ 26°C						
	1994-2000		2001-2006		2007-2012	
	Min	Max	Min	Max	Min	Max
$\beta_0 Y_B$	0,462	2,414	0,781	2,577	1,588	2,911
$\beta_1 X_1 Y_B$	0,159	1,258 ^a	0,245	1,832 ^a	0,043	0,254
$\beta_2 \log X_2 Y_B$	-0,312	-0,050	-0,665 ^a	-0,142	0,045	0,247
$\beta_3 X_3 Y_B$	$4,11 \times 10^{-7}$	$3,03 \times 10^{-6}$	0,038	0,125	$7,78 \times 10^{-5}$	0,0003
t > 26°C						
	1994-2000		2001-2006		2007-2012	
	Min	Max	Min	Max	Min	Max
$\beta_0 Y_B$	1,659	2,996	0,768	3,050	2,215	3,638
$\beta_1 X_1 Y_B$	0,107	0,513 ^a	0,138	1,162 ^a	0,014	0,130
$\beta_2 \log X_2 Y_B$	-0,261	0,013	-0,715 ^a	0,036	-0,365 ^a	0,018
$\beta_3 X_3 Y_B$	0,003	0,008	$6,87 \times 10^{-9}$	$2,72 \times 10^{-8}$	$2,81 \times 10^{-6}$	$1,04 \times 10^{-5}$
Y_E						
1994-2012						
	Min	Max				
α_0		1,70				
$\alpha_1 X_1$	0.032	0.853 ^a				
$\alpha_2 \log X_2$	-0.006	0.102				
$\alpha_3 X_3$	0.256	0.756 ^a				

No modelo BE_9 , em sete situações (Tabela 9) os valores dos termos ($\beta_i X_i Y_B$) podem assumir valor maior (em módulo) que o RMSE daquele período. Na região de temperatura amena, o modelo econômico influenciou sempre

abaixo do RMSE, significando que o erro está maior do que todos os termos econômicos podem afetar. Para a faixa de temperatura quente, apenas no primeiro e segundo períodos para os termos ^(a) com custo de transporte e tamanho da fazenda ficaram acima do erro. Por fim, na faixa mais quente, os três períodos apresentaram valores ^(a) acima do erro, tanto nos termos com custo de transporte quanto nos com tamanho da fazenda. Podemos observar que no modelo BE_9 a variável de preço da soja têm influência inferior a $0,2 \text{ ton ha}^{-1}$ em todas as casas.

Para os termos com custo de transporte que apresentaram valores acima do erro é possível questionar se este custo está estimado corretamente, visto que há alguns casos que não foram considerados, como nos casos em que a soja é processada dentro dos portos. Nos casos onde os termos com tamanho da fazenda apresentam valores acima do erro é possível também questionar sobre o quão correto está esse dado, visto que, na faixa de temperatura muito quente, onde estão as maiores fazendas, quanto maior a fazenda maior a perda de produtividade. Considerar uma relação linear entre o logaritmo do tamanho médio da fazenda e a produtividade também pode introduzir erros, pois pode não haver uma distribuição normal do log destes dados, visto que é possível ter muitas fazendas com tamanho pequeno e poucas com tamanho grande. Outro limitante que pode ser considerado em ambos os casos é que os dados estão em uma resolução de $1^\circ \times 1^\circ$, o que acarreta erro considerável na representação dos mesmos. Para a não influência do termo com o preço da soja no modelo biofísico-econômico em todas as faixas de temperaturas e períodos, é possível interpretar que provavelmente o aumento que o preço da soja tem no longo prazo está

embutido nas mudanças de cultivares (períodos). É possível interpretar que o preço da soja tem efeito de longo prazo na produtividade, e o efeito ano a ano é principalmente na área plantada.

Na Figura 14 é possível notar que os valores anuais médios simulados pelo modelo biofísico-econômico (BE_9) estão muito próximos do valor médio observado, enquanto o valor médio da produtividade simulada apenas pelo modelo biofísico mostra-se acima da observada, caracterizando uma produtividade potencial, sem influência de variáveis econômicas. Nesse caso, é possível afirmar que as variáveis econômicas afetam como um limitador na produtividade da soja, em função das condições econômicas.

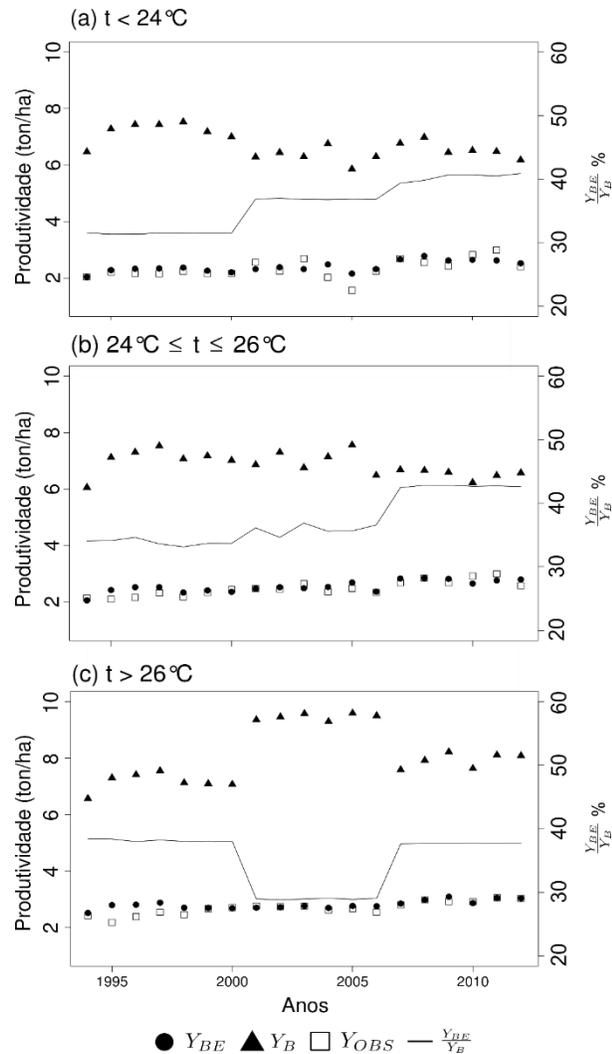


Figura 14. Variação da produtividade anual média dos modelos Biofísico (Y_B , representado pelo triângulo) e Biofísico-econômico (Y_{BE} , representado pelo círculo), e do valor médio observado (Y_{OBS} , representado pelo quadrado) para as faixas de temperatura (a) $< 24^{\circ}\text{C}$, (b) entre 24°C e 26°C e (c) $> 26^{\circ}\text{C}$. A linha representa a razão entre a produtividade de Y_{BE} e Y_B .

Embora o experimento BE_9 tenha representado melhora significativa nos resultados simulados em relação ao modelo puramente econômico, não foi o suficiente para atingir os valores de correlação encontrado por Garrett et al. (2013a), que foi de 0,64. No entanto, mesmo que os resultados mostrem valores de correlação menores, o modelo desenvolvido neste trabalho é capaz de

capturar as variações temporais, que não foram consideradas por Garrett et al. (2013a). Além disso, é importante ressaltar que desenvolver um sistema que englobe os estudos de um cultivo agrícola de grande importância mundial, tanto de forma temporal, quanto espacial, acarreta a necessidade de grande interação entre estes sistemas, de maneira que há grande dificuldade na modelagem dos processos. Portanto, consideramos que a calibração realizada teve desempenho satisfatório, quando analisado o resultado da produtividade do modelo biofísico-econômico.

O melhor resultado apresentado entre os experimentos realizados foi o do modelo E_{C9} , que chegou a uma correlação de 0,72, incorporando duas variáveis climáticas: precipitação e temperatura. O aumento em 0,15 na correlação (produtividade x precipitação) em relação ao modelo E_1 foi devido ao grande impacto causado pela precipitação, enquanto a temperatura não demonstrou influência, $r=0,04$ (produtividade x temperatura). Esta relação mostra a dependência da cultura de soja com a precipitação. Este modelo também mostrou uma melhora em relação ao modelo de Garrett et al. (2013a) por ter considerado uma maior variabilidade temporal e espacial do que considerada por estes autores.

Comparando os dois melhores resultados simulados, E_{C9} e BE_9 , é possível notar que há uma necessidade da utilização tanto de variáveis climáticas quanto econômicas para chegar a uma melhor representação real da produtividade de soja. Porém, considerar apenas o modelo econômico E_{C9} , onde há a contabilização de duas variáveis climáticas, não é totalmente ideal, mesmo

este tendo apresentado o melhor resultado. Por outro lado, este ideal seria trabalhar sobre uma melhoria do modelo biofísico-econômico BE_9 , visto que neste há uma modelagem de variáveis puramente biofísicas. No entanto, este modelo apresenta uma maior incerteza devido a uma quantidade maior de variáveis biofísicas, ou seja, um erro maior.

Outra forma de analisar esses resultados é através do Desafio Nacional de Produtividade Máxima de Soja, que tem sido organizado pelo Comitê Estratégico de Soja do Brasil (CESB), o qual inspira produtores de soja no Brasil a produzir mais utilizando o mesmo espaço, com o auxílio de tecnologias sendo possível alcançar um máximo de produtividade. O desafio foi criado a partir da safra 2008/2009, porém nesta safra nenhum dos produtores participantes passaram de $5,4 \text{ ton ha}^{-1}$. A partir da safra 2009/2010 a produtividade dos produtores participantes começou a crescer. O campeão de produtividade para esta safra chegou a $6,5 \text{ ton ha}^{-1}$. Na safra 2015/2016 o campeão chegou à produtividade de $7,2 \text{ ton ha}^{-1}$. O recorde ficou para a safra 2014/2015 com $8,5 \text{ ton ha}^{-1}$ (CESB, 2017).

Na Figura 15a tem-se as cidades campeãs de produtividade nas safras 2010, 2011, 2012 desde que o campeonato começou. É possível ver os valores da produtividade potencial de soja para quatro cidades campeãs de produtividade na safra 2011/2012 na Figura 15b, última safra presente nas simulações deste trabalho. A cidade de Correntina (BA) foi a campeã nacional de produtividade de soja nesta safra com $6,5 \text{ ton ha}^{-1}$ e o modelo biofísico simulou $6,7 \text{ ton ha}^{-1}$. A cidade de Arapoti foi a campeã do estado do Paraná e apresentou a menor diferença com o simulado, uma diferença de $0,043 \text{ ton ha}^{-1}$. As cidades de Itararé

(SP) e Uruaçu (GO) foram as que apresentaram maior diferença em relação ao simulado. A produção de soja nestas cidades é de soja não irrigada, assim como a que foi simulada.

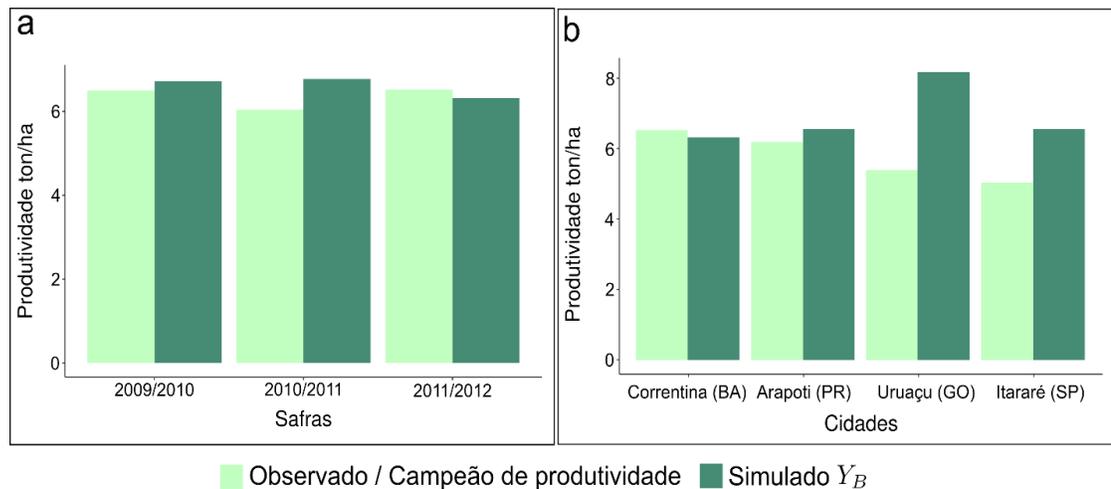


Figura 15. Em a: cidades campeãs de produtividade Mambarê - PR (2009/2010), Correntina - BA (2010/2011 e 2011/2012); b: cidades campeãs de produtividade de soja safra 2011/2012 (CESB, 2017).

Neste trabalho, algumas das condições assumidas na construção dos mapas de custo mínimo de transporte e tamanho médio da fazenda podem ter introduzido erros importantes no processo de modelagem: (1) Considerar o valor do diesel no custo de transporte foi constante ao longo do tempo; (2) considerar que toda a soja produzida é escoada nos portos, não passando por processamento de grãos no país; (3) Não considerar a variação temporal da pavimentação das estradas. Todas essas condições assumidas podem ter ocasionado viés na análise temporal dos mapas, o que provavelmente gerou alguns dos questionamentos nos resultados do modelo BE_9 e mesmo do modelo E_1 . Por sua vez, os mapas de tamanho médio da fazenda são baseados apenas nos dados do censo de um ano, e assim, cada pixel possui o mesmo tamanho

todos os anos. Esta limitação pode ser solucionada com a utilização de dados de tamanho das fazendas advindos do Cadastro Ambiental Rural (CAR), porém esta é uma base de dados ainda incompleta. Outra solução, é a utilização da malha fundiária nacional recentemente desenvolvida pelo Instituto de Manejo e Certificação Florestal Agrícola (IMAFLOA, 2017), onde mapas com áreas públicas e privadas estão disponibilizadas. Esses dados ainda não estavam disponíveis no período de desenvolvimento deste trabalho.

Por fim, o modelo agroeconômico desenvolvido neste trabalho abre a possibilidade para o acoplamento de outros tipos de modelos econômicos, que podem auxiliar na simulação de soja para cenários climáticos futuros.

4 Conclusões

Nas últimas duas décadas, a produtividade de soja teve crescimento progressivo com o auxílio de tecnologias, sofrendo influências climáticas e econômicas. Este trabalho buscou esforços para inovar sobre um paradigma da modelagem propondo um híbrido entre dois tipos de modelos. Buscou-se, portanto, a interdisciplinaridade entre sistemas naturais e econômicos.

Os experimentos mostraram evolução e melhoria nos resultados com o auxílio da calibração e escolha do modelo. Partindo do modelo B_{Ori} que não teve nenhuma otimização de parâmetros e apresentou baixa correlação ($r=-0,0032$) para um modelo biofísico-econômico (BE_9) com melhor correlação ($r=0,55$) entre os experimentos com modelos biofísicos. Outros modelos foram simulados e discutidos com algumas diferenças em suas configurações, gerando resultados que levassem ao melhor experimento. O modelo econômico (E_1) apresentou

correlação ($r=0,53$), próxima ao modelo BE_9 , porém com coeficiente de inclinação da reta menor ($0,28$). No entanto, o modelo puramente econômico superestima a produtividade em pontos com baixa produtividade observada, visto que não há influência de variáveis biofísicas. A inserção de variáveis econômicas tornou-se um limitante real fazendo com que a produtividade potencial se aproximasse da produtividade real e ficasse próxima da produtividade observada. Três experimentos receberam a otimização espacializada do Optis, primeiro o B_9 que visava uma comparação com o comportamento da produtividade dos outros modelos biofísico-econômico. Segundo, o modelo BE_1 que teve uma baixa correlação ($r=0,28$), e por fim o modelo BE_9 com a melhor correlação ($0,55$), resultante de nove simulações divididas em períodos para obter uma tendência no crescimento da produtividade e com uma divisão em três faixas de temperatura para salientar a variabilidade da dependência da temperatura do cultivar.

Com melhor resultado, o modelo E_{C9} , conclui-se que há a necessidade de utilizar variáveis tanto econômicas quanto climáticas. A divisão por faixas de temperatura e períodos contabiliza a evolução tecnológica do período de estudo. No caso do melhor resultado entre os modelos biofísico-econômico, o modelo BE_9 precisa de algumas melhorias para alcançar uma melhor correlação, como melhorar a incerteza dos dados climáticos de entrada do modelo; uma forma mais dinâmica do manejo da cultura e considerar outras variáveis mais sensíveis na otimização.

4.1 Recomendações para trabalhos futuros

A partir das limitações discutidas neste trabalho, são recomendadas ações futuras para a melhoria do modelo biofísico-econômico, as quais são apresentadas por elemento do modelo.

(a) Para o modelo biofísico:

- Estender este estudo para os outros cultivos agrícolas presentes no modelo INLAND.
- Considerar uma melhor forma de manejo da cultura.
- Fazer uma análise de sensibilidade nas variáveis do modelo para verificar quais são necessárias para uma otimização melhor.
- Utilizar outro banco de dados climáticos e de solo para testar a sensibilidade do modelo em relação aos dados de entrada.

(b) Para as variáveis econômicas:

- Considerar o preço do óleo diesel com variação temporal para calcular um custo de transporte que proporcione variabilidade maior no espaço e no tempo.
- Ter o conhecimento da quantidade de soja escoada em cada porto onde a soja é processada interiormente.
- Realização de trabalho de campo para melhorar as estimativas dos custos de transporte.
- Incorporar outras variáveis econômicas nesta modelagem. Já existe uma quantidade importante de dados, com variação temporal, relacionados a despesas de custeio da lavoura (mão de

obra, sementes, fertilizantes, defensivos) e despesas pós-colheita (transporte externo, armazenagem; manutenção, encargos sociais) (CONAB, 2016), que podem auxiliar em um importante ganho para este modelo.

- Buscar uma solução para analisar a porcentagem de escoamento de soja em uma rede multimodal ou intermodal.
- Quantificar a soja que chega aos portos, visto que uma porcentagem desta acaba sendo minimizada no caminho em fábricas de processamento de grãos.

(c) Para a otimização do Optis:

- Desenvolver uma forma mais otimizada para a simulação do modelo para que não seja dividida tantas vezes, como foi o caso deste trabalho, em faixas de temperatura e períodos.
- Implementar outras formas de métricas de erro como o BATEA (*Bayesian total error analyses*) proposto por Thyer et al. (2009), onde os componentes de um modelo como dados de entrada, estruturas de erros (como parâmetros estocásticos) e dados de saída também são calibrados.

5 Referências bibliográficas

Agritempo. **Sistema de Monitoramento Agrometeorológico**. Disponível em:

<www.agritempo.gov.br>. Acessado em 15 de outubro de 2016.

Albuquerque, A.C.S., Silva, A.G. da, 2008. **Agricultura Tropical - Quatro**

décadas de inovações tecnológicas, institucionais e políticas. Embrapa Informação Tecnológica, 375-382.

AliceWeb. **Sistema de Análise das Informações de Comércio Exterior via**

Internet do Ministério do Desenvolvimento, Indústria e Comércio

Exterior. Disponível em: <alicesweb.desenvolvimento.gov.br>. Acessado

em 12 de agosto de 2016.

- Alliprandini, L.F., Abatti, C., Bertagnolli, P.F., Cavassim, J.E., Gabe, H.L., Kurek, A., Matsumoto, M.N., De Oliveira, M.A.R., Pitol, C., Prado, L.C., Steckling, C., 2009. **Understanding soybean maturity groups in brazil: Environment, cultivar classification, and stability.** *Crop Science*, 49, 801–808. doi:10.2135/cropsci2008.07.0390
- Angelsen, A., Kaimowitz, D., 1999. **Rethinking the Causes of Deforestation: Lessons from Economic Models.** *The World Bank Research Observer*, 14, 73–98. doi:10.1093/wbro/14.1.73
- Boote, K.J., Jones, J.W., Pickering, N.B., 1996. **Potential Uses and Limitations of Crop Models I. Model Use as a Research Tool.** *Agronomy Journal* 716, 704–716. doi:10.2134/agronj1996.00021962008800050005x
- Boote, K.J., Jones, J.W., Hoogenboom, G., Pickering, N.B., 1998. **The CROPGRO model for grain legumes.** *Understanding Options for Agricultural Production*, 7, 99–128. doi:10.1007/978-94-017-3624-4_6
- CEPEA-Esalq. **Centro de Estudos Avançados em Economia Aplicada.** Disponível em: <<http://www.cepea.esalq.usp.br/br/indicador/soja.aspx>>. Acessado em 10 de maio de 2017.
- CESB. **Comitê Estratégico Soja Brasil.** Disponível em: <www.cesbrasil.org.br>. Acessado em 15 de janeiro de 2017.
- Collatz, G.J., Ball, J.T., Grivet, C., Berry, J.A., 1991. **Physiological and environmental regulation of stomatal conductance, photosynthesis and transpiration: a model that includes a laminar boundary layer.** *Agricultural and Forest Meteorology*, 54, 107–136. doi:10.1016/0168-1923(91)90002-8

CONAB. **Companhia Nacional de Abastecimento**. Disponível em:
<<http://www.conab.gov.br/conteudos.php?a=1555&t=>>. Acessado em: 13 de agosto de 2016.

Cuadra, S. V., Costa, M.H., Kucharik, C.J., Da Rocha, H.R., Tatsch, J.D., Inman-Bamber, G., Da Rocha, R.P., Leite, C.C., Cabral, O.M.R., 2012. **A biophysical model of Sugarcane growth**. *Global Change Biology Bioenergy*, 4, 36–48. doi:10.1111/j.1757-1707.2011.01105.x

Dias, L.C.P., Pimenta, F.M., Santos, A.B., Costa, M.H., Ladle, R.J., 2016. **Patterns of land use, extensification, and intensification of Brazilian agriculture**. *Global Change Biology*, 22, 2887–2903. doi:10.1111/gcb.13314

Drewniak, B., Song, J., Prell, J., Kotamarthi, V.R., Jacob, R., 2013. **Modeling agriculture in the Community Land Model**. *Geoscientific Model Development*, 6, 495–515. doi:10.5194/gmd-6-495-2013

EMBRAPA. **Empresa Brasileira de Pesquisa Agropecuária**. Disponível em
<<https://www.embrapa.br/soja>>. Acessado em 10 de novembro de 2016.

FAO. **Food and Agriculture Organization of the United Nations/OECD (2015)**,
OECD-FAO Agricultural Outlook 2015, OECD Publishing, Paris.
doi:10.1787/agr_outlook-2015-en

Foley, J.A., Prentice, I.C., Ramankutty, N., Levis, S., Pollard, D., Sitch, S., Haxeltine, A., 1996. **An integrated biosphere model of land surface processes, terrestrial carbon balance, and vegetation dynamics**. *Global Biogeochemical Cycles*, 10, 603–628. doi:10.1029/96GB02692

- Fontes, V.C., 2015. **Calibração automática multi-sítio e multi-objetiva de um modelo de superfície terrestre.** 45 f. Dissertação (Mestrado em Meteorologia Aplicada) - Universidade Federal de Viçosa, Viçosa - MG.
- Garrett, R.D., Lambin, E.F., Naylor, R.L., 2013a. **Land institutions and supply chain configurations as determinants of soybean planted area and yields in Brazil.** Land use policy, 31, 385–396. doi:10.1016/j.landusepol.2012.08.002
- Garrett, R.D., Lambin, E.F., Naylor, R.L., 2013b. **The new economic geography of land use change: Supply chain configurations and land use in the Brazilian Amazon.** Land use policy, 34, 265–275. doi:10.1016/j.landusepol.2013.03.011
- GRASS Development Team, 2017. **Geographic Resources Analysis Support System (GRASS) Software**, Version 7.2. Open Source Geospatial Foundation. Electronic document: <http://grass.osgeo.org>
- Haskett, J.D., Pachepsky, Y.A., Acock, B., 1995. **Estimation of soybean yields at county and state levels using GLYCIM: A case study for Iowa.** Agronomy Journal, 87, 926–931. doi:10.2134/agronj1995.00021962008700050025x
- Imaflora. **Instituto de Manejo e Certificação Florestal e Agrícola.** Disponível em: <<http://imaflora.blogspot.com.br/>>. Acessado em 10 de Abril de 2017.
- IMEA. **Instituto Mato-grossense de economia agrária.** Disponível em: <www.imea.com.br>. Acessado em 20 de novembro de 2016.

- Jones, J.W., Hoogenboom, G., Porter, C.H., Boote, K.J., Batchelor, W.D., Hunt, L.A., Wilkens, P.W., Singh, U., Gijsman, A.J., Ritchie, J.T., 2003. **The DSSAT cropping system model**. *European Journal of Agronomy*, 18, 235-265. doi:10.1016/S1161-0301(02)00107-7
- Kaufmann, R.K., Snell, S.E., 1997. **A Biophysical Model of Corn Yield: Integrating Climatic and Social Determinants**. *American Journal of Agricultural Economics*, 79, 178–190. doi:10.2307/1243952
- Kucharik, C.J., 2003. **Evaluation of a Process-Based Agro-Ecosystem Model (Agro-IBIS) across the U.S. Corn Belt: Simulations of the Interannual Variability in Maize Yield**. *Earth Interactions*, 7, 1–33. doi:10.1175/1087-3562(2003)007<0001:EOAPAM>2.0.CO;2
- Kucharik, C.J., Foley, J.A., Delire, C., Fisher, V.A., Coe, M.T., Lenters, J.D., Young-Molling, C., Ramankutty, N., Norman, J.M., Gower, S.T., 2000. **Testing the performance of a dynamic global ecosystem model: Water balance, carbon balance, and vegetation structure**. *Global Biogeochemical Cycles*, 14, 795–825. doi:10.1029/1999GB001138
- Kucharik, C.J., Twine, T.E., 2007. **Residue, respiration, and residuals: Evaluation of a dynamic agroecosystem model using eddy flux measurements and biometric data**. *Agricultural and Forest Meteorology* 146, 134–158. doi:10.1016/j.agrformet.2007.05.011
- Lobell, D.B., Burke, M.B., 2010. **On the use of statistical models to predict crop yield responses to climate change**. *Agricultural and Forest Meteorology*, 150, 1443–1452. doi:10.1016/j.agrformet.2010.07.008

- Lokupitiya, E., Denning, S., Paustian, K., Baker, I., Schaefer, K., Verma, S., Meyers, T., Bernacchi, C., Suyker, A., Fischer, M., 2009. **Incorporation of crop phenology in Simple Biosphere Model (SiBcrop) to improve land-atmosphere carbon exchanges from croplands.** *Biogeosciences*, 6, 969–986. doi:10.5194/bgd-6-1903-2009
- Nelson, G.C., Valin, H., Sands, R.D., Havlík, P., Ahammad, H., Deryng, D., Elliott, J., Fujimori, S., Hasegawa, T., Heyhoe, E., Kyle, P., Von Lampe, M., Lotze-Campen, H., Mason, D., van Meijl, H., van der Mensbrugge, D., Müller, C., Popp, A., Robertson, R., Robinson, S., Schmid, E., Schmitz, C., Tabeau, A., Willenbockel, D., 2013. **Climate change effects on agriculture: Economic responses to biophysical shocks.** *Proceedings of the National Academy of Science*, 111, 3274-3279. doi:10.1073/pnas.1222465110
- Richetti, A., 2014. **Viabilidade econômica da cultura da soja na safra 2014/2015, em Mato Grosso do Sul.** 13p. Comunicado técnico 194.
- Rosegrant, M.W. and the IMPACT Development Team. 2012. **International Model for Policy Analysis of Agricultural Commodities and Trade (IMPACT): Model Description.** 55p. International Food Policy Research Institute (IFPRI), Washington, D.C.
- Rosenzweig, C., Jones, J.W., Hatfield, J.L., Ruane, A.C., Boote, K.J., Thorburn, P., Antle, J.M., Nelson, G.C., Porter, C., Janssen, S., Asseng, S., Basso, B., Ewert, F., Wallach, D., Baigorria, G., Winter, J.M., 2013. **The Agricultural Model Intercomparison and Improvement Project (AgMIP): Protocols and pilot studies.** *Agricultural and Forest Meteorology*, 170, 166–182. doi:10.1016/j.agrformet.2012.09.011

- Rötter, R.P., Carter, T.R., Olesen, J.E., Porter, J.R., 2011. **Crop-climate models need an overhaul.** Nature Climate Change, 1, 175–177. doi:10.1038/nclimate1152
- Sellers, P.J., Randall, D.A., Collatz, G.J., Berry, J.A., Field, C.B., Dazlich, D.A., Zhang, C., Collelo, G.D., Bounoua, L., 1996. **A revised land surface parameterization (SiB2) for atmospheric GCMs. Part I: Model formulation.** Journal of Climate. doi:10.1175/1520-0442(1996)009<0676:ARLSPF>2.0.CO;2
- Senna, M.C.A., 2004. **Fração da Radiação Fotossinteticamente Ativa Absorvida pela Floresta Tropical Amazônica: Uma Comparação Entre Estimativas Baseadas em Modelagem, Sensoriamento Remoto e Medições de Campo.** 54 f. Dissertação - Mestrado em Meteorologia Agrícola - Universidade Federal de Viçosa, Viçosa - MG.
- Sheffield, J., Goteti, G., Wood, E.F., 2006. **Development of a 50-Year High-Resolution Global Dataset of Meteorological Forcings for Land Surface Modeling.** Journal of Climate. 19, 3088–3111. doi:10.1175/JCLI3790.1
- Sinclair, T.R., 1986. **Water and nitrogen limitations in soybean grain production I. Model development.** Field Crop Research, 15, 125–141. doi:10.1016/0378-4290(86)90082-1
- Stöckle, C.O., Donatelli, M., Nelson, R., 2003. **CropSyst, a cropping systems simulation model.** European Journal of Agronomy, 18, 289–307. doi:10.1016/S1161-0301(02)00109-0

- Strassburg, B.B.N., Latawiec, A.E., Barioni, L.G., Nobre, C.A., da Silva, V.P., Valentim, J.F., Vianna, M., Assad, E.D., 2014. **When enough should be enough: Improving the use of current agricultural lands could meet production demands and spare natural habitats in Brazil.** *Global Environmental Change*, 28, 84–97. doi:10.1016/j.gloenvcha.2014.06.001
- Thyer, M., Renard, B., Kavetski, D., Kuczera, G., Franks, S.W., Srikanthan, S., 2009. **Critical evaluation of parameter consistency and predictive uncertainty in hydrological modeling : A case study using Bayesian total error analysis.** *Water Resources Research*, 45, W00B14. doi:10.1029/2008WR006825
- Tourigny, E., 2014. **Multi-scale fire modeling in the neotropics: coupling a land surface model to a high resolution fire spread model, considering land cover heterogeneity.** 153 f. Doctorate - Thesis Course Graduate in Meteorology. Instituto Nacional de Pesquisas Espaciais. São José dos Campos-SP
- Varejão, C.G., Costa, M.H., Camargos, C.C.S., 2013. **A multi-objective hierarchical calibration procedure for land surface/ecosystem models.** *Inverse Problems in Science and Engineering*, 21:3, 357–386. doi:10.1080/17415977.2011.639453
- Vera-Diaz, M. del C., Kaufmann, R.K., Nepstad, D.C., Schlesinger, P., 2008. **An interdisciplinary model of soybean yield in the Amazon Basin: The climatic, edaphic, and economic determinants.** *Ecological Economics*, 65, 420–431. doi:10.1016/j.ecolecon.2007.07.015

Vera-Diaz, M.C., Kaufmann, R.K., Nepstad, D.C., 2009. **The environmental impacts of soybean expansion and infrastructure development in Brazil's Amazon Basin.** 21 p. Global Development and Environment Institute. Working Paper nº 09-05.

Vu, J.C. V, Allen Jr., L.H., Bowes, G., 1997. **Effects of elevated CO₂ and temperature on photosynthesis and Rubisco in rice and soybean.** *Plant, Cell and Environmental*, 20, 68–76. doi:10.1046/j.1365-3040.1997.d01-10.x