**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Simulação de cenários agrícolas futuros para a cultura da soja no Brasil com base em
projeções de mudanças climáticas**

Evandro Henrique Figueiredo Moura da Silva

Dissertação apresentada para obtenção do título de Mestre
em Ciências. Área de concentração: Engenharia de
Sistemas Agrícolas

**Piracicaba
2018**

Evandro Henrique Figueiredo Moura da Silva
Engenheiro Agrônomo

**Simulação de cenários agrícolas futuros para a cultura da soja no Brasil com base em
projeções de mudanças climáticas**

versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **FÁBIO RICARDO MARIN**
Co-orientador:
Prof. Dr. **FELIPE GUSTAVO PILAU**

Dissertação apresentada para obtenção do título de Mestre
em Ciências. Área de concentração: Engenharia de
Sistemas Agrícolas

Piracicaba
2018

**Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP**

Moura da Silva, Evandro Henrique Figueiredo

Simulação de cenários agrícolas futuros para a cultura da soja no Brasil com base em projeções de mudanças climáticas / Evandro Henrique Figueiredo Moura da Silva. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011 - - Piracicaba, 2018.

95 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Cenários climáticos 2. DSSAT/CROPGRO-SOYBEAN 3. Risco climático 4.Segurança alimentar 5.Modelagem agrícola I. Título

AGRADECIMENTOS

À Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo, pela oportunidade do curso de mestrado em Engenharia de Sistemas Agrícolas. Ao Departamento de Engenharia de Biosistemas (LEB) pela infraestrutura disponibilizada para o desenvolvimento da pesquisa científica.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pela bolsa de mestrado e reserva técnica (Processo 2015/25702-3).

Ao Prof. Fábio Ricardo Marin, pelo engajamento e profissionalismo de sua orientação. Sou grato pela confiança depositada e assertividade de suas sugestões. Agradeço principalmente pela generosidade com que compartilha suas ideias, conhecimentos, projetos e oportunidades.

Ao Prof. Felipe Gustavo Pilau, sempre muito harmonioso e disposto a ensinar e discutir ideias. Agradeço, em especial, pelas preciosas sugestões na instalação e condução do primeiro experimento.

Aos funcionários do LEB, do Departamento de Produção Vegetal (LPV) e da Fazenda Areão da ESALQ/USP, sempre muito receptivos e dispostos a auxiliar.

Aos grupos GEPEMA (Grupo de Experimentação e Pesquisa em Modelagem Agrícola) e AGRIMET (Grupo de Pesquisa e Extensão em Meteorologia dos Cultivos Agrícolas), dos quais tive a honra de participar da coordenação ao longo do mestrado. Agradeço, em especial, a todos os membros sempre muito unidos e dedicados às atividades do grupo, tiveram, sem dúvidas, grande participação nesse trabalho.

À família — aos pais José Antônio e Sonia e aos irmãos Ewerton e Giulia e a sobrinha Olívia — sou grato pela sempre presente participação em minha vida, sobretudo, aos constantes incentivos ao estudo e à formação profissional. Aos meus pais agradeço, em especial, ao constante apoio, aos tantos ensinamentos, à liberdade que me proporcionam e pela imensa generosidade.

SUMÁRIO

RESUMO.....	6
ABSTRACT	7
1. INTRODUÇÃO.....	9
1.1. OBJETIVOS	12
1.1.1. Geral.....	12
1.1.2. Específicos	12
REFERÊNCIAS.....	12
2. ANÁLISE DE SENSIBILIDADE LOCAL DO MODELO DSSAT/CROPGRO-SOYBEAN PARA O SUDESTE BRASILEIRO	15
RESUMO.....	15
ABSTRACT	15
2.1. INTRODUÇÃO	16
2.2. MATERIAL E MÉTODOS	17
2.3. RESULTADOS E DISCUSSÃO.....	19
2.4. CONCLUSÃO.....	30
REFERÊNCIAS.....	31
3. CALIBRAÇÃO E AVALIAÇÃO DO MODELO DSSAT/CROPGRO-SOYBEAN PARA DIFERENTES GRUPOS DE MATURAÇÃO DE SOJA DO BRASIL	35
RESUMO.....	35
ABSTRACT	35
3.1. INTRODUÇÃO	35
3.2. MATERIAL E MÉTODOS	37
3.2.1. Descrição do Modelo	37
3.2.2. Grupos de maturação relativa selecionados e dados de campo	38
3.2.3. Experimentos de campo	39
3.2.4. Medidas biométricas	42
3.2.5. Calibração do modelo DSSAT/CROPGRO-SOYBEAN	42
3.2.6. Análise estatística de desempenho da modelagem	43
3.3. RESULTADOS E DISCUSSÃO.....	45
3.3.1. Parâmetros físico-hídricos do solo e dados meteorológicos de entrada	45
3.3.1. Calibração do modelo DSSAT/CROPGRO-SOYBEAN	46
3.3.2. Análise do desempenho do DSSAT/CROPGRO-SOYBEAN para os grupos de maturação relativa avaliados.....	53
3.4. CONCLUSÃO.....	55
REFERÊNCIAS.....	55
4. CENÁRIOS FUTUROS DE PRODUTIVIDADE DA SOJA BRASILEIRA SIMULADOS A PARTIR DE PROJEÇÕES CLIMÁTICAS	61
RESUMO.....	61
ABSTRACT	61
4.1. INTRODUÇÃO	61
4.2. MATERIAL E MÉTODOS	63
4.2.1. Definição e determinação das zonas edafoclimáticas homogêneas	63
4.2.2. Cenários de mudanças climáticas	64
4.2.3. Caracterização dos solos predominantes	65
4.3. RESULTADOS E DISCUSSÃO.....	65
4.3.1. Risco de produção agrícola para os cenários com base nas simulações do modelo DSSAT/CROPGRO-SOYBEAN.....	75
4.4. CONCLUSÃO.....	78

REFERÊNCIAS	78
5. CONCLUSÕES GERAIS	83
APÊNDICES	85
REFERÊNCIAS	86
ANEXO	95

RESUMO

Simulação de cenários agrícolas futuros para a cultura da soja no Brasil com base em projeções de mudanças climáticas

A garantia da segurança alimentar global é um dos grandes desafios da humanidade para as próximas décadas. O aumento populacional do planeta, até 2050, em cerca de 2 bilhões de pessoas em 2050, a tendência de ascensão da classe média e as projeções de mudanças climáticas têm sido consideradas como um dos grandes desafios futuros para as políticas internacionais de segurança alimentar. As projeções de alteração climática levam em consideração o aumento da concentração de gases de efeito estufa, sendo o CO₂ o principal deles. O setor agrícola pode ser o mais afetado pelas mudanças no clima. O Brasil é o maior exportador e o segundo maior produtor de soja (*Glycine max* L.) do mundo. Essa cultura representa mais de 60% de toda a proteína alimentar de origem vegetal produzida no mundo. Considerando essa problemática, o presente estudo teve como objetivo geral simular o crescimento da cultura da soja em pontos estrategicamente selecionados no Brasil, com base em séries históricas observadas e em cenários climáticos futuros. Para isso, o modelo DSSAT/CROPGRO-SOYBEAN foi calibrado para diferentes grupos de maturação relativa (6.0, 7.0, 8.0 e 9.0), de modo a abranger pelo menos 80% de toda a produção nacional. Especificamente para o grupo 6.0, foi necessário a instalação de um experimento de campo, em Piracicaba-SP nas safras 2015/16 e 2016/17. Para a projeção dos cenários climáticos futuros adotou-se a metodologia do projeto internacional *Agricultural Model Intercomparison and Improvement Project* (AgMIP). Esses cenários foram baseados nas projeções de concentrações futuras de CO₂ atmosférico (RCP 4.5 e RCP 8.5). Considerando as duas possibilidades de concentração futura de CO₂, selecionou-se três modelos climáticos globais (GCM) para cada zona homogênea. As zonas homogêneas foram agrupadas considerando a soma térmica, aridez e sazonalidade de temperatura. As produtividades futuras de soja foram simuladas para o período 2040-2069 (representando 2050). Notou-se que as mudanças climáticas podem contribuir para o aumento da produtividade de soja no Brasil para a maioria das zonas homogêneas nos cenários simulados, mas com aumento do risco climático da cultura em algumas regiões. As simulações e zonas homogêneas que apresentaram perdas de produtividade estavam estritamente relacionadas com o déficit hídrico.

Palavras-chave: Cenários climáticos; DSSAT/CROPGRO-SOYBEAN; Risco climático; Segurança alimentar

ABSTRACT

Simulation of future agricultural scenarios for the soybean crop in Brazil based on climate change projections

Ensuring global food security is one of humanity's greatest challenges for the coming decades. The rising population of the planet by about 2 billion people, the rising trend of the middle class and the projections of climate change have been considered as one of the great future challenges for international food security policies. The projections of climate change take into account the increase in the concentration of greenhouse gases, with CO₂ being the main one. The agricultural sector may be most affected by changes in climate. Brazil is the largest exporter and the second largest producer of soybeans (*Glycine max*) in the world. This crop represents more than 60% of all plant protein produced in the world. Considering this problem, the present study had as general objective to simulate soybean crop growth in strategically selected points in Brazil, based on observed historical series and future climatic scenarios. For this, the DSSAT / CROPGRO-SOYBEAN model was calibrated for different maturation groups (6.0, 7.0, 8.0 and 9.0), to cover at least 80% of all national production. Specifically for group 6.0, it was necessary to install a field experiment in Piracicaba-SP in the 2015/16 and 2016/17 seasons. For the projection of the future climate scenarios the methodology of the international Agricultural Model Intercomparison and Improvement Project (AgMIP) was adopted. These scenarios were based on projections of future concentrations of atmospheric CO₂ (RCP 4.5 and RCP 8.5). Considering the two possibilities of future CO₂ concentration, three global climate models (GCM) were selected for each homogeneous zone. The homogeneous zones were grouped considering the thermal sum, aridity and seasonality of temperature. Future soybean yields were simulated for the period 2040-2069 (representing 2050). It was noted that climate change may contribute to increase soybean productivity in Brazil for most of the homogeneous zones in the simulated scenarios, but with increasing climatic risk of the crop in some regions. The simulations and homogeneous zones that presented productivity losses were strictly related to the water deficit.

Keywords: Climate scenarios; DSSAT/CROPGRO-SOYBEAN; Climate risk; Food safety

1. INTRODUÇÃO

A função da agricultura é fornecer ao homem pelo menos 50 nutrientes, sem os quais a existência humana não seria possível. O fornecimento adequado desses nutrientes são atributos essenciais, embora não suficientes, para a construção de sociedades produtivas e saudáveis (WELCH; GRAHAM, 2005). O mundo experimentou, nas últimas décadas, incrementos constantes na oferta de alimentos; reduzindo a escassez de carboidratos e proteínas (EVENSON; GOLLIN, 2003). Analisando os efeitos da “Revolução Verde”, Evenson e Gollin (2002) mencionaram que tais incrementos se deram, principalmente, pelo desenvolvimento de cultivares agrícolas de alto rendimento. Ainda segundo os referidos autores, não fossem tais incrementos o mundo contaria com ingestão calórica cerca de 14% inferior a atual e a desnutrição infantil seria cerca de 7% maior.

Projeções para 2025 apontam que a proporção de desnutridos no mundo deverá cair de 788 milhões para menos de 650 milhões (FAO, 2016). Este documento também menciona uma tendência de aumento da renda per capita dos países em desenvolvimento e isso deverá influenciar os hábitos alimentares, com crescimento da demanda por calorias e proteínas (principalmente de origem animal), assim como incremento no consumo de açúcar, óleos e gorduras, em decorrência do maior consumo de alimentos processados.

Segundo Foley (2011), até o ano de 2050, o incremento populacional do planeta deverá ser entre dois e três bilhões de pessoas. Segundo o autor, tal acréscimo populacional será acompanhado pelo aumento da classe média nos países em desenvolvimento, que por sua vez, demandará por mais proteína animal na dieta das respectivas populações. O autor alerta a necessidade do aumento da produção de grãos para atender a esse consumo, principalmente pela razão da conversão alimentar. O autor também exemplifica que são necessários 30 quilogramas de grãos para produzir um quilograma de carne bovina, sendo a soja o principal (e provavelmente insubstituível) insumo proteico para a nutrição animal (SILVA, 2014).

Segundo dados da *United States Department of Agriculture* (2017a) o farelo de soja representou, em média, nas últimas cinco safras, o equivalente a 68,81% de toda a proteína de origem vegetal produzida mundialmente. Alguns subprodutos da soja são empregados diretamente na alimentação humana e, segundo Mattos et al (2015), esses são os insumos proteicos mais requeridos pela indústria alimentícia.

O Brasil destaca-se no cenário mundial de produção de soja, por ser o segundo maior produtor e o maior exportador mundial dessa *commodity* — do total de 120 milhões de hectares produzindo soja atualmente no mundo, mais de 33 milhões estão em território brasileiro

(USDA, 2017). A produção brasileira de soja cresceu mais de 60% nos últimos 10 anos (CONAB, 2017), sendo o “complexo soja”, o maior gerador de divisas para o Brasil, com negociações anuais que ultrapassam US\$ 20 bilhões, havendo projeções que apontam a produção nacional até 2019 como sendo responsável por 40% do comércio mundial do grão e 73% do óleo de soja (MAPA, 2017). A Figura 1 apresenta a distribuição da produção nacional de soja por unidade da federação (UF), considerando a média da produção brasileira do período de 1990 a 2015; sendo o estado do Mato Grosso o maior produtor nacional.

As projeções futuras de incremento na demanda por soja têm na questão das mudanças climáticas um desafio adicional, uma vez que as simulações de cenários feitas na última década apontam para a possibilidade de queda expressiva da produção nacional (ASSAD et al., 2008). No entanto, sabe-se que atualmente tais projeções agrícolas não levaram em conta o efeito positivo da elevação da concentração atmosférica de CO₂ às plantas, o que pode ter caracterizado tais projeções como excessivamente pessimistas.

A utilização de ferramentas de modelagem agrícola baseada em processos é cientificamente aceita para analisar os impactos da mudança climática na agricultura (ROSENZWEIG et al., 2014). Os modelos, por definição, são essencialmente teóricos e derivam de um conjunto de teoremas formulados a partir de premissas ou postulados (CHIANG; WAINWRIGHT, 2006). As teorias são abstrações do mundo real, nesse sentido buscam estreitar problemas complexos (POPPER, 2010), sendo, portanto, um recurso encontrado para isolar fatores e relações essenciais de uma complexa realidade, como é o caso do desenvolvimento de uma cultura agrícola e da sua interação com o meio que a cerca, por exemplo.

Esta dissertação vale-se do arcabouço conceitual desenvolvido na linha da modelagem baseada em processos mecanísticos. Tais modelos precisam respeitar uma determinada ordem de processos e suas respectivas propriedades, induzindo variáveis extras em diferentes níveis, desde agregados bioquímicos a órgãos vegetais (MARIN, 2014). O referido autor complementa que se aplica aos modelos uma gama maior de fenômenos baseados na física e nos processos fisiológicos envolvidos no crescimento da cultura e, pela integração do conjunto de equações, o sistema é então definido. Thornley e Johnson (1990) esclarecem que modelos mecanísticos, quando aplicados na pesquisa científica, são mais detalhados e representam melhor os sistemas biológicos e, assim, tendem a apresentar resultados que explicam melhor a realidade. Definindo-se adequadamente as condições de contorno do sistema no qual se aplica o modelo, pode-se alcançar com boa dose de exatidão as variáveis de interesse numa cultura agrícola: área de folhas, índice de área foliar, massa de grãos e teor de proteína, por exemplo.

Figura 1. Distribuição nacional da produção anual média de soja, por unidade da federação, considerando a média o período de 1990-2015. Dados IBGE (2016).

Esses modelos têm sido utilizados na literatura científica para análise de impactos das mudanças climáticas na agricultura (ASSENG et al., 2013), o que pode fornecer cenários agrícolas futuros aos diferentes setores da sociedade envolvidos no tema, permitindo avaliar com a devida antecedência a vulnerabilidade do sistema e oferecer subsídio para adaptação tecnológica do setor.

Assim, esse estudo assume como hipótese que é possível construir cenários futuros para a cultura da soja no Brasil considerando projeções climáticas futuras e utilizando-se de modelos baseados em processos para simulação do crescimento e desenvolvimento da cultura e um procedimento de *upscaling* adequadamente desenhado para este propósito.

1.1. Objetivos

1.1.1. Geral

Simular o crescimento da cultura da soja em pontos estrategicamente selecionados no Brasil com base em séries históricas observadas e em cenários climáticos futuros.

1.1.2. Específicos

- (i) conduzir um experimento de campo para obtenção de dados que permitam calibrar um modelo baseado em processos;
- (ii) coletar dados de literatura que possam servir como suporte ao processo de calibração do modelo;
- (iii) calibrar um modelo baseado em processo para estimativa do crescimento e desenvolvimento da cultura da soja e expressar o nível de incerteza alcançado;
- (iv) simular, para locais adequadamente selecionados, o desempenho da cultura da soja ao longo de 30 anos, comparando a condição atual e, ao menos, dois cenários de climas futuros.

REFERÊNCIAS

ASSAD, E. D. et al. **Aquecimento global e a nova geografia da produção agrícola no Brasil**. Brazil: Brazil Embrapa Unicamp, 2008.

ASSEN, S. et al. Uncertainty in simulating wheat yields under climate change. **Nature Climate Change**, v. 3, n. 9, p. 827–832, 2013.

CHIANG, A. C.; WAINWRIGHT, K. **Matemática para economistas**. Rio de Janeiro: Rio de Janeiro Elsevier Campus, 2006.

CONAB. **Séries históricas**. Disponível em:

<http://www.conab.gov.br/conteudos.php?a=1252&t=&Pagina_objcmsconteudos=3#A_objcmsconteudos>. Acesso em: 25 maio. 2017.

EVENSON, R.E; GOLLIN, D. Crop genetic improvement in developing countries: overview and summary. In: EVENSON, R.E; GOLLIN, D. (Ed.). . **Crop variety improvement and its effect on productivity**. CABI ed. [s.l: s.n.].

EVENSON, R. E.; GOLLIN, D. Assessing the impact of the green revolution, 1960 to 2000. **Science**, v. 300, n. 5620, p. 758–762, 2003.

FAO. **OECD-FAO Agricultural Outlook 2016-2025 SpECiAl FOCuS: Sub-SAhArAn AFriCA**. [s.l.] OECD/FAO, 2016.

FOLEY, J. A. CAN WE FEED THE WORLD & SUSTAIN THE PLANET?: EBSCOhost. **Scientific American**, v. 305, n. 5, p. 60–65, 2011.

IBGE, I. B. DE G. E E. **Produção agrícola municipal**. Disponível em: <<https://sidra.ibge.gov.br/tabela/1612>>. Acesso em: 2 out. 2017.

MAPA. **Soja lidera exportações do agronegócio brasileiro em abril — Ministério da Agricultura, Pecuária e Abastecimento**. Disponível em: <<http://www.agricultura.gov.br/noticias/soja-lidera-exportacoes-do-agronegocio-brasileiro-em-abril>>. Acesso em: 25 maio. 2017.

MATTOS, E. C. et al. Estudo da identidade histológica de subprodutos de soja (*Glycine max* L.). **Rev Inst Adolfo Lutz**, v. 74, p. 104–110, 2015.

MARIN, F. R. Eficiência de produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos. p. 262, 2014.

POPPER, K. **The logic of scientific discovery**. New York: New York Routledge, 2010.

ROSENZWEIG, C. et al. Assessing agricultural risks of climate change in the 21st century in a global gridded crop model intercomparison. **Proceedings of the National Academy of Sciences of the United States of America**, v. 111, n. 9, p. 3268–73, 4 mar. 2014.

SILVA, F. **INTER-RELAÇÕES ENTRE PRODUÇÃO E DEMANDA DA SOJA E DE PROTEÍNA ANIMAL**. [s.l.] Universidade Regional do Noroeste do Estado do Rio Grande do Sul, 2014.

THORNLEY, J. H. .; JOHNSON, I. . **Plant and crop modelling**. Armidale: The Blackburn Press, 1990.

USDA. **World Agricultural Supply and Demand Estimates**. Washington, D.C: WASDE-565, 2017. Disponível em: <<https://www.usda.gov/oce/commodity/wasde/latest.pdf>>. Acesso em: 25 maio. 2017.

WELCH, R. M.; GRAHAM, R. D. Agriculture: the real nexus for enhancing bioavailable micronutrients in food crops. **Journal of Trace Elements in Medicine and Biology**, v. 18, n. 4, p. 299–307, 2005.

2. ANÁLISE DE SENSIBILIDADE LOCAL DO MODELO DSSAT/CROPGRO-SOYBEAN PARA O SUDESTE BRASILEIRO

Resumo

A soja (*Glycine max* L.) é uma planta oleaginosa que se destaca por ser uma das principais culturas agrícolas do mundo, sendo a principal geradora de divisas para o Brasil. É uma espécie sensível ao fotoperíodo, sendo considerada uma planta de dia curto. Outros elementos meteorológicos podem também modificar a resposta da planta ao fotoperíodo, como a temperatura do ar. Modelos agrícolas baseados em processos têm a pretensão de representar na forma de algoritmos as relações fisiológicas e físicas que envolvem um cultivo agrícola e, deste modo, são mais complexos. Tais modelos contam, também, com uma série de parâmetros que nem sempre têm sua função identificada facilmente, ou mesmo que operam da mesma maneira em diferentes ambientes. Assim, a análise de sensibilidade pode contribuir para determinar o quão sensível as variáveis de saída de um modelo são em relação aos parâmetros e variáveis de entrada. Neste trabalho, buscou-se analisar a sensibilidade relativa, das variáveis: área foliar específica (AFE), índice de área foliar (IAF), massa seca vegetativa (VMS) e produtividade (MSG), a partir de variações de 15 parâmetros do modelo, configurado para simular uma cultura de soja nas condições do sudeste do Brasil. Dentre os parâmetros analisados, apenas os sete foram representativos ao analisar a sensibilidade relativa das variáveis de saída. Esses parâmetros estavam relacionados ao fotoperíodo, partição de carboidrato na planta e duração dos principais estádios fenológicos da cultura. O modelo conseguiu representar essa sensibilidade de forma coerente com aspectos fisiológicos da soja. As variáveis de saída relacionadas ao desenvolvimento vegetativo mostraram maior sensibilidade relativa em relação aos parâmetros de comprimento crítico do dia curto (CSDL) e número de semente por vagem (SDPDV), com diferentes sensibilidades relativas ao longo das fases fenológicas; e.g para a variável sensibilidade relativa da variável IAF para o parâmetro CSDL variou de $\sigma_r = 0$ e $\sigma_r = -161,81\%$.

Palavras-chave: Análise de crescimento; Fotoperíodo; Modelagem agrícola

Abstract

Soybean (*Glycine max* L.) is an oleaginous plant that stands out as one of the main agricultural crops in the world, being the main generator of foreign exchange for Brazil. It is a species sensitive to the photoperiod, being considered a plant of short days. Other weather elements can also modify the plant response to the photoperiod, such as air temperature. Process-based agricultural models have the pretension to represent in the form of algorithms the physiological and physical relationships involving an agricultural crop and thus are more complex in nature. These models also have a series of parameters that do not always have their function easily identified, or even that they operate in the same way in different environments. Thus, the sensitivity analysis can contribute to determine how sensitive the output variables of a model are in relation to parameters and input variables. The objective of this study was to analyze the relative sensitivity of leaf area specific index (AFE), leaf area index (LAI), vegetative dry mass (VMS) and productivity (MSG), based on variations of 15 model parameters, configured to simulate a soybean crop in southeastern Brazil. Among the analyzed parameters, only seven were representative when analyzing the relative sensitivity of the output variables. These parameters were related to the photoperiod, carbohydrate partition in the plant and duration of the main phenological stages of the crop. The model was able to represent this sensitivity in a manner consistent with the physiological aspects of soybean. The output variables related to the vegetative development showed higher relative sensitivity in relation to the parameters of short day critical length (CSDL) and seed number per pod (SDPDV), with different relative sensitivities during the phenological phases; e.g. for the relative sensitivity variable of the IAF variable for the CSDL parameter was varied from $\sigma_r = 0$ to $\sigma_r = -161.81\%$.

Keywords: Growth analysis; Photoperiod; Crop models

2.1. Introdução

Sistemas agrícolas são complexas combinações de vários componentes que interagem entre si e com o ambiente, nos seus amplos aspectos: físicos, químicos, fisiológicos e socioeconômicos. Essas complexas relações podem ser cientificamente estudadas por meio de modelos agrícolas (DOURADO-NETO, 1999; MARIN; RIBEIRO; MARCHIORI, 2014; ROSENZWEIG et al., 2013; RÖTTER et al., 2012). Por definição, os modelos são essencialmente teóricos e derivam de um conjunto de teorias formulados a partir de premissas ou postulados (CHIANG; WAINWRIGHT, 2006). Essas teorias, como também relata Popper (2010), são recursos encontrados para isolar fatores e relações essenciais de uma complexa realidade, são, portanto, abstrações do mundo real. Nessa direção, especificamente na agricultura, o uso de modelos de crescimento de plantas, baseados em processos fisiológicos são ferramentas consagradas na literatura científica para testes de hipóteses acadêmicas.

Os modelos agrícolas baseado em processos (MBP) são representações dinâmicas e mecanísticas do mundo real e contam com constantes, parâmetros e variáveis de entrada e saída relacionadas através de relações matemáticas. Constantes são quantidades que assumem valores fixos e independentes do tempo, das premissas ou dos componentes do modelo (WALLACH et al., 2001a). Já os parâmetros são quantidades que nem sempre podem ser mensuradas diretamente e em certas circunstâncias precisam ser estimadas por meio de conhecimentos especializados; por definição, são constantes em uma dada situação de interesse, normalmente após o processo de calibração do modelo (CHIANG; WAINWRIGHT, 2006). As variáveis podem ser definidas como: (a) variáveis de estado, que são quantidades que descrevem as condições dos componentes do sistema em qualquer momento particular e mudam com o tempo e com a interação entre os componentes do modelo e (b) variáveis explanatórias são características que podem ser medidas ou observadas diretamente em cada situação onde o modelo é aplicado (WALLACH et al., 2001a).

As fontes de incerteza dos MBP são inerentes aos parâmetros do modelo, a estrutura do modelo e aos dados de entrada. A alta complexidade desses modelos resulta na incerteza crescente de seus parâmetros. Nesses casos, boas práticas de modelagem exigem o uso de análise de sensibilidade (KUCHERENKO; TARANTOLA; ANNONI, 2012). Essas análises são relevantes porque podem identificar quais variáveis e/ou parâmetros precisam ser estimados

ou mensurados com maior acurácia ou, até mesmo, determinar a possibilidade de simplificação do modelo (SALTELLI et al., 2008).

A análise de sensibilidade também tem a finalidade de explicitar a relação entre os parâmetros do modelo e os processos de crescimento e desenvolvimento da cultura numa determinada condição de contorno, de modo a apresentar aos usuários a importância relativa dos parâmetros em relação às variáveis de saída mais relevantes para determinado estudo (FRIEND; SCHUGART; RUNNING, 1993; WHITE et al., 2000). Apresentando-se assim, como uma ferramenta essencial no processo de parametrização do modelo que se pretende estudar.

A análise de sensibilidade pode ser definida como local ou global. A análise de sensibilidade local examina a resposta da saída variando um parâmetro de cada vez e mantendo os demais parâmetros constantes (GUSTAFSON; SRINIVASAN; WASSERMAN, 1996). Já a análise de sensibilidade global calcula a contribuição fracionada dos parâmetros de entrada para a variância das saídas; sendo uma medida do efeito total de um dado parâmetro, incluindo todos os termos sinérgicos possíveis entre esse parâmetro e todos os outros em um valor central (HOMMA; SALTELLI, 1996).

Deste modo, o presente estudo tem por objetivo analisar a sensibilidade do modelo DSSAT/CROPGRO-SOYBEAN para as condições de Piracicaba-SP.

2.2. Material e Métodos

O modelo DSSAT/CROPGRO-SOYBEAN é composto por 18 parâmetros relacionados às características genéticas da cultura da soja. Nesse estudo, selecionou-se 15 parâmetros considerados *a priori* mais relevantes para os processos de interesse neste estudo. São eles: (a) CSDL (*critical short day length*) comprimento crítico do dia curto; (b) PPSEN (*slope of the relative response of development to photoperiod*) a resposta relativa do desenvolvimento da planta ao fotoperíodo; (c) EMFL (*time between plant emergence and flower appearance*) o tempo entre a emergência e o início do florescimento da planta (R1); (d) FLSH (*time between first flower and first pod*) o tempo entre R1 e início da frutificação (R3); (e) FLSD (*time between first flower and first seed*) tempo entre R1 e a formação da primeira semente (R5); (f) SDPM (*time between first seed and physiological maturity*) tempo entre R5 e a maturidade fisiológica (R7); (g) FLLF (*time between first flower and end of leaf expansion*) tempo entre R1 e o fim da expansão foliar; (h) LFMAX (*maximum leaf photosynthesis*) taxa máxima de fotossíntese foliar; (i) SLAVR (*specific leaf area*) área foliar específica; (j) XFRT

(*maximum fraction of daily growth that is partitioned to seed and shell*) fração máxima do crescimento diário que é dividida em sementes e casca ; (k) WTPSD (*maximum weight per seed*) peso máximo por semente; (l) SFDUR (*seed filling duration for pod cohort*) duração do enchimento de grãos; (m) SDPDV (*average seed per pod under standard growing conditions*) média da semente por vagem; (n) PODUR (*time required for cultivar to reach final pod load under optimal conditions*) tempo requerido para que a cultivar atinja a carga máxima de vagens; (o) THRSH (*threshing percentage, the maximum ratio of seed/(seed+shell) at maturity*) índice de colheita. O passo de variação dos parâmetros foi estabelecido em 4% em relação à condição padrão, sendo três intervalos crescentes e três decrescentes. Assumiu-se neste trabalho apenas as variações relativas superiores a 2%, em pelo menos uma das variáveis estudadas e/ou fase fenológica.

Para efeito de análise de sensibilidade, selecionaram-se quatro variáveis de saída: (a) área foliar específica (AFE); (b) índice de área foliar (IAF); (c) somatório da massa das folhas e caules, aqui chamado de massa seca vegetativa (VMS) e (d) produtividade (MSG). Relacionaram-se os valores das saídas aos diferentes estádios fenológicos: VC, R1, R3, R5 e R7, conforme a classificação fenológica descrita por Fehr e Caviness (1977). A variável MSG foi considerada na análise de sensibilidade levando-se em conta apenas os valores gerados no estágio fenológico R7. O modelo foi configurado para simular duas condições de cultivo quanto à disponibilidade hídrica (sequeiro e irrigado), sendo que o cultivo irrigado foi simulado assumindo um manejo da irrigação em que a água no solo era repostada integralmente sempre que a fração de umidade disponível atingisse 80% da capacidade de água disponível (CAD) — Para tanto adotou-se CAD de 100 mm.

A execução da análise de sensibilidade local considerou uma calibração previamente estabelecida e disponível no pacote de instalação do DSSAT versão 4.6, referente ao grupo de maturação 6.0. Os dados meteorológicos utilizados — temperatura do ar máxima e mínima (°C), chuva (mm) e radiação solar global (MJ m^{-2}) — foram coletados no Posto Meteorológico da Escola Superior de Agricultura Luiz de Queiroz em Piracicaba, SP (latitude de 22°42'30"S; longitude de 47°38'30"O; altitude de 566 m). Os parâmetros de solo necessários para simulação com o modelo são referentes a uma das áreas experimentais utilizadas para os experimentos desta dissertação (Cap. 3), cuja classificação é de um Nitossolo Vermelho Eutroférico latossólico (DOS SANTOS et al., 2006) e estão apresentadas na Tabela 1.

Tabela 1. Parâmetros do Nitossolo Vermelho Eutroférico latossólico para o modelo DSSAT/CROPGRO-SOYBEAN Profundidade do solo (PROF), ponto de murcha permanente (PPM), capacidade de campo (CCA), ponto de saturação (PSA), fator de crescimento radicular (FCR), condutividade hidráulica saturada (CHS), densidade do solo (DSO), carbono orgânico (COR), teor de argila (ARG), teor de silte (SIL), pH em água (PHA) e capacidade de troca catiônica (CTC).

PROF	PPM	CCA	PSA	FCR	CHS	DSO	COR	ARG	SIL	PHA	CTC
cm		cm ³ cm ⁻³			cm h ⁻¹	g cm ⁻³		%			mol _c kg ⁻¹
<u>Nitossolo Vermelho</u>											
0-20	0,249	0,338	0,494	0,9	0,67	1,48	3,85	48,0	18,9	5,5	6,5
20-40	0,249	0,338	0,494	0,8	0,67	1,48	3,85	60,0	11,4	5,5	6,5
40-60	0,306	0,363	0,457	0,8	0,16	1,40	3,85	60,4	15,0	5,5	6,8

A sensibilidade absoluta das variáveis em relação aos parâmetros foi calculada com a Equação 1 que, posteriormente, foi convertido no índice de sensibilidade relativa (Equação 2) (SALTELLI et al., 2004).

$$\sigma = \frac{\delta y}{\delta k} \quad (1)$$

em que σ é a sensibilidade absoluta, δy é a diferença entre os dados da variável de saída do modelo e δk é a diferença entre as variações do parâmetro de entrada.

$$\sigma_r = \sigma \frac{k}{y} \quad (2)$$

em que σ_r é a sensibilidade relativa, σ é a sensibilidade absoluta, k é o valor do parâmetro padrão e y é o valor de saída da variável padrão.

2.3. Resultados e Discussão

Dentre os 15 parâmetros analisados, apenas cinco (CSDL, EMFL, PPSN, FLSD e SDPDV) mostraram influência sob as variáveis de saída AFE, IAF e VMS.

Alterações no parâmetro CSDL exerceram considerável influência na duração do ciclo da cultura da soja. Para CSDL igual a 14,08 h o ciclo da cultura foi de 79 dias, a redução do parâmetro para 11,08 h implicou em um ciclo de 140 dias. Para Piracicaba durante o período referente aos primeiros estádios de desenvolvimento da cultura simulada, o fotoperíodo foi superior a 13 h. Desse modo, o modelo mostra coerência nos processos de indução floral quando

da alteração do fotoperíodo crítico, ou pelo acúmulo de graus-dia (COCKSHULL, 1984; DZOTSI; BASSO; JONES, 2013).

Notou-se que no estágio fenológico VC não houve sensibilidade de nenhuma das variáveis (AFE, IAF e VMS) com relação aos parâmetros acima mencionados (CSDL, EMFL, PPSN, FLSD e SDPDV), nas duas condições hídricas (Figuras 1, 2, 3 e 4). Isto parece coerente se considerado que durante os 15 primeiros dias após a emergência a planta de soja não sofre influência do fotoperíodo (NORMAN, 1978). Observa-se também diferenças na maioria dos pontos entre as diferentes fases fenológicas (e.g IAF sequeiro, para $\delta_{CSDL} = -12\%$ em R7 $\sigma_r = -161,81\%$, R5 $\sigma_r = -17,61\%$, R3 $\sigma_r = -2,4\%$ e R1 e VC $\sigma_r = 0$), como resultado da estratégia de modelagem empregada para contabilizar um fator de progressão diária que depende de dois fatores: (a) FUDAY, que é um fator de sensibilidade ao comprimento do dia (equação 3) e (b) FT, fator de sensibilidade a temperatura do dia (equação 4). A ponderação dessas duas variáveis descreve a forma do modelo determinar a fenologia da planta em unidades fototérmicas (TENG et al., 1998).

$$FUDAY = CURV(CSDVAR, CLDVAR, THVAR, DAYL) \quad (3)$$

em que CURV é a representação de uma função de comprimento do dia programada em linguagem FORTRAN que tem como variáveis independentes: (i) CSDVAR, que é o ponto onde o comprimento do dia favorece um progresso de desenvolvimento intensivo; (ii) CLDVAR, que é o comprimento do dia quando o desenvolvimento é mínimo; (iii) THVAR, que é a taxa mínima de desenvolvimento reprodutivo em dias longos e temperatura ótima e (iv) DAYL, que é uma rotina de cálculo de comprimento do dia.

$$FT(J) = CURV(TB, TO1, TO2, TM, TSDEP) \quad (4)$$

em que CURV é a representação de uma função de temperatura do ar programada em linguagem FORTRAN que tem como variáveis independentes: (i) TB é a temperatura base; (ii) TO1 e TO2 são os dois valores que definem o intervalo de temperaturas ótimas; (iii) TM é a temperatura acima da qual o desenvolvimento cessa e (iv) TSDEP é a temperatura média.

Observa-se um aumento expressivo nas variáveis AFE, IAF e VMS à medida que o fotoperíodo crítico (CSDL) diminui, isso ocorreu pelo maior desenvolvimento vegetativo determinado pela alongação do ciclo (Figura 1). Ainda na Figura 1, nota-se um drástico distanciamento do R7 em relação aos demais estádios fenológicos e com uma acentuada

sensibilidade nesse estágio em relação ao CSDL. A elongação do período juvenil observada é coerente pela diminuição do fotoperíodo crítico da soja (e.g 11,08) em locais onde o comprimento do dia é mais elevado (e.g Piracicaba) (WHIGHAM; MINOR, 1978), o que confere maior desenvolvimento vegetativo observado nessas condições. (e.g VMS sequeiro, para $\delta_{CSDL} = -12\%$ em R7 $\sigma_r = -118,13\%$, R5 $\sigma_r = -23,61\%$, R3 $\sigma_r = -10,69\%$ e R1 e VC $\sigma_r = 0$).

Comparando-se o padrão de variação das variáveis de saída nos tratamentos irrigado e sequeiro (Figuras 1, 2, 3 e 4) observa-se um efeito pronunciado do estresse hídrico sobre a sensibilidade do modelo às variáveis de saída estudadas. Isto, por sua vez, reforça importância de se utilizar procedimentos estritos de calibração comparando-se sempre que possíveis experimentos irrigados (e bem manejado) e de sequeiro.

O parâmetro EM-FL representa o período compreendido entre a emergência da planta e o florescimento, sendo contabilizado em termos de unidades de tempo fototérmico. Embora o comprimento do ciclo não tenha sido influenciado por essa variável, o intervalo de tempo entre a emergência e o estágio R1 variou em 10 dias entre o menor e o maior valor de EM-FL, nas duas situações de disponibilidade hídrica (Figura 2). Observou-se uma redução no desenvolvimento das variáveis IAF e VMS (e.g IAF sequeiro, para $\delta_{EMFL} = -12\%$ em R7 $\sigma_r = 3,2\%$, R5 $\sigma_r = 9,53\%$, R3 $\sigma_r = 7,51\%$, R1 $\sigma_r = 2,4\%$ e VC $\sigma_r = 0$). De modo análogo, a redução das variáveis de saída foi observada no parâmetro FLSD (Figura 4), essa lógica é coerente ao observado fisiologicamente pelas plantas, que têm seu desenvolvimento vegetativo potencializado em dias mais longos e com temperaturas ótimas (BOOTE et al., 1998; FARIAS; NEPOMUCENO; NEUMAIER, 2007; NORMAN, 1978; TAIZ; ZEIGER, 2010).

Observou-se, também, uma baixa sensibilidade relativa obtida pela variação do parâmetro PPSEN (Figura 3). Apesar dessa aparente ausência de resposta, essa relação poderia ser alvo de estudos futuros envolvendo a análise de sensibilidade global do modelo, nos quais seria possível avaliar a influência sinérgica desse parâmetro (DRECHSLER, 1998; SALTELLI et al., 2008), em relação aos parâmetros diretamente relacionados ao fotoperíodo.

Figura 1. Sensibilidade relativa das variáveis AFE (área foliar específica), IAF (índice de área foliar) e VMS (massa seca vegetativa) ao parâmetro comprimento crítico do dia curto (CSDL), ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica. Sendo na condição padrão CSDL=12,58.

Figura 2. Sensibilidade relativa das variáveis AFE (área foliar específica), IAF (índice de área foliar) e VMS (massa seca vegetativa) ao parâmetro período entre R1 e R5 (EMFL), ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica. Sendo na condição padrão EMFL = 20,2.

Figura 3. Sensibilidade relativa das variáveis AFE (área foliar específica), IAF (índice de área foliar) e VMS (massa seca vegetativa) em relação ao parâmetro resposta relativa do desenvolvimento da planta ao fotoperíodo (PPSEN), ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica. Sendo na condição padrão $PPSEN = 0,311$.

Figura 4. Sensibilidade relativa das variáveis AFE (área foliar específica), IAF (índice de área foliar) e VMS (massa seca vegetativa) em relação ao parâmetro duração de período entre R5 e R7 (FLSD), ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica. Sendo na condição padrão FLSD = 16,0.

As variáveis IAF e VMS mostraram alta sensibilidade relativa ao parâmetro SDPDV. Esse parâmetro quando alterado, independente da direção da variação induz uma diminuição das variáveis vegetativas VMS e IAF, tanto no tratamento de sequeiro como no irrigado (Figura 5). Acentua-se que esse parâmetro deve ser trabalhado com bastante cautela no processo de calibração de cultivares. No algoritmo do modelo o SDPDV é uma unidade de proporção entre as variáveis SEEDNO (número de semente m^{-2}) e o PODNO (número de vagem m^{-2}) e essas variáveis se relacionam com uma série de rotinas como, por exemplo, o balanço de carbono e nitrogênio, na forma das equações 5 e 6.

$$\text{CGRSD} = \text{WSDDTN} * \text{AGRSD3} \quad (5)$$

em que CGRSD é a quantidade de carbono ($\text{g}[\text{CH}_2\text{O}] \text{ m}^{-2} \text{ d}^{-1}$) requerida para o enchimento da semente, WSDDTN é a taxa de crescimento diário da semente e AGRSD3 é o carboidrato requerido para o desenvolvimento da semente.

$$\text{CGRSH} = \text{WSDHTN} * \text{AGRSH1} \quad (6)$$

em que CGRSH é a quantidade de carbono ($\text{g}[\text{CH}_2\text{O}] \text{ m}^{-2} \text{ d}^{-1}$) requerida para o crescimento do fruto (vagem ou casca), WSDHTN é a taxa de crescimento diário da vagem e AGRSH1 é o carboidrato requerido para o desenvolvimento da vagem.

Vale notar que apesar do SDPDV não atuar como um definidor único do número de sementes e vagens produzidas por planta, ele tem, juntamente com outros algoritmos do modelo, papel determinante neste cômputo. Para a condição avaliada neste trabalho, por exemplo, quando apenas o parâmetro SDPDV foi alterado, o modelo modificou a fração translocada de carboidratos da parte vegetativa para as estruturas de frutificação, elevando a produção de vagens e/ou sementes. Essa estratégia coaduna com os mecanismos fisiológicos já conhecidos sobre a cultura que informam sobre a priorização dos frutos em termos de drenagem de carboidratos durante a fase reprodutiva em detrimento dos demais órgãos vegetais (ZIMMERMANN, 1960).

Figura 5. Sensibilidade relativa das variáveis área foliar específica (AFE), índice de área foliar (IAF) e massa seca vegetativa (VMS) em relação ao parâmetro média de semente por vagem (SDPDV), ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica. Sendo na condição padrão $SDPDV = 2,05$.

Com relação a variável MSG nota-se que o parâmetro CSDL tende a aumentar a variável quando a taxa de variação do parâmetro é negativa, assim como, quando ela é positiva (Figura 6). Notou-se apenas no intervalo de $0 \geq \delta_k \geq$ (com $k = \text{CSDL}$) uma tendência contrária: uma variação negativa do parâmetro acarretando em uma variação negativa da variável. A variação dos parâmetros EMFL e PPSEN, apresentaram relação inversa a variação da variável MSG (Figura 6). Como já foi discutido, esses parâmetros são fortemente influenciados pelo fotoperíodo e pela temperatura, de modo que é possível associar a ação desses fatores na produtividade final da cultura.

Figura 6. Sensibilidade relativa da variável produtividade (MSG) em relação aos parâmetros comprimento crítico do dia curto (CSDL), resposta relativa do desenvolvimento da planta ao fotoperíodo (PPSEN), EMFL (tempo entre VC e R1), taxa máxima de fotossíntese foliar (LFMAX) e área foliar específica (SLAVR), ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica. Sendo na condição padrão: CSDL = 12,58; PPSEN = 0,311; EMFL = 20,2; LFMAX = 1,030 e SLAVR = 375,0.

Os parâmetros FLSH, FLSD e SDPM controlam a duração de importantes etapas do processo de formação das estruturas de produção. Observa-se uma forte relação da disponibilidade de água no solo na sensibilidade relativa da variável MSG em relação aos referidos parâmetros (Figura 7). SDPM apresentou maior influência na variável de saída, podendo ser um importante parâmetro de ajuste no processo de calibração. Uma vez que esses parâmetros estão relacionados a intervalos fenológicos é preciso observar as condições climáticas e eventos obtidos em campo para um bom ajuste do modelo. Exemplificando, quando SDPM — intervalo entre R5 e R7 — é diminuído, a exigência da planta (em unidades fototérmicas) para completar o ciclo é, evidentemente, menor. Desse modo é fácil perceber que a produtividade aumentará até certos limites, como é demonstrado no terceiro quadrante da

Figura 7, para ambas as condições. Nota-se, entretanto, uma mudança na inclinação da curva para as condições de sequeiro e irrigado: na condição de sequeiro o alongamento do ciclo (R5 a R7) proporcionaria um aumento de produtividade, enquanto que no outro tratamento a produtividade diminuiria.

Figura 7. Sensibilidade relativa da variável produtividade (MSG) em relação aos parâmetros período entre R1 e R3 (FLSH), período entre R1 e R5 (FLSD) e período entre R5 e R7 (SDPM) ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica.

Na Figura 8 pode-se observar uma baixa sensibilidade da variável MSG aos parâmetros XFRT, SFDUR, SDPDV, PODUR e THRSH. No entanto, a relação de sensibilidade relativa é bastante pronunciada pelo parâmetro WTPSD para o tratamento irrigado, uma vez que o aumento da massa máxima por semente acarretaria em um aumento da produtividade final.

O estudo avança no sentido de contribuir para a elucidação da relação das variáveis de saída com os parâmetros de cultivar do modelo e suas relações com os processos fisiológicos das culturas. No entanto, a análise de sensibilidade local apresentou certa limitação como ferramenta para auxiliar na calibração e validação de modelos. A relação entre algumas variações pontuais dos parâmetros e a sensibilidade das variáveis são inconsistentes. Por exemplo, o parâmetro SDPDV quando alterado induziu a uma queda das variáveis vegetativas VMS e IAF, independente da direção da variação. Ou mesmo, o PPSEN que apresentou baixa sensibilidade relativa entre as variáveis de saída. Nesses casos a análise de sensibilidade global pode contribuir de modo mais efetivo para a calibração do modelo.

Figura 8. Sensibilidade relativa da variável produtividade (MSG) em relação aos parâmetros fração máxima do crescimento diário que é dividida em sementes e casca (XFRT), peso máximo por semente (WTPSD), duração do enchimento de grãos (SFDUR), média do número de semente por vagem (SDPDV), tempo requerido para que a cultivar atinja a carga máxima de vagens (PODUR) e índice de colheita (THRSH) ao longo do ciclo da cultura da soja em duas condições de disponibilidade hídrica.

2.4. Conclusão

O DSSAT/CROPGRO-SOYBEAN apresentou diferentes níveis de sensibilidade nos diferentes estádios fenológicas da cultura da soja para as variáveis AFE, IAF, VMS e MSG, nas duas condições de disponibilidade hídrica. As alterações do parâmetro CSDL e SDPDV apresentaram a maior influência, dentre os estudados, nas variáveis de saída relacionadas ao desenvolvimento vegetativo. O crescimento foi mais afetado pelos parâmetros SDPM, WTPSD, PPSN e EMFL. Notou-se que o modelo representa bem a sensibilidade da cultura da soja ao fotoperíodo. As variáveis de saída relacionadas ao desenvolvimento vegetativo apresentaram baixa sensibilidade ao parâmetro PPSN. A análise de sensibilidade local é uma ferramenta interessante para analisar aspectos fisiológicos do modelo, mas é limitada para fornecer subsídios para a calibração de modelos, uma vez que não considera efeitos sinérgicos entre as variações entre os parâmetros. Sugerem-se estudos que busquem correlacionar a sensibilidade entre parâmetros, para uma verificação mais peculiar.

REFERÊNCIAS

- BOOTE, K. J. et al. The CROPGRO model for grain legumes. In: TSUJI, G. Y.; HOOGENBOOM, G.; THORNTON, P. K. (Eds.). . **Understanding options for agricultural production**. [s.l.] Springer, 1998. p. 99–128.
- CHIANG, A. C.; WAINWRIGHT, K. **Matemática para economistas**. Rio de Janeiro: Rio de Janeiro Elsevier Campus, 2006.
- COCKSHULL, K. E. **Photoperiodic induction of flowering in short-day plants**. Light and the flowering process: Proceedings, 3rd Internatl. Symp. British Photobiology Society, Glasshouse Crops Research Institute, Littlehampton, England, Sept 7-9, 1983/ed. D. Vince-Prue, B. Thomas, KE Cockshull. **Anais...**London: Academic Press, 1984., 1984
- DOS SANTOS, H. G. et al. **Sistema brasileiro de classificação de solos**. 2^a ed. Brasília: Rio de janeiro: Embrapa Solos, 2006., 2006.
- DOURADO-NETO, D. Modelos fitotécnicos referentes à cultura de milho. **Piracicaba: ESALQ/USP**, 1999.
- DRECHSLER, M. Sensitivity analysis of complex models. **Biological Conservation**, v. 86, n. 3, p. 401–412, 1998.
- DZOTSI, K. A.; BASSO, B.; JONES, J. W. Development, uncertainty and sensitivity analysis of the simple SALUS crop model in DSSAT. **Ecological Modelling**, v. 260, p. 62–76, 2013.
- FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. Ecofisiologia da soja. **Embrapa Soja-Circular Técnica (INFOTECA-E)**, 2007.
- FEHR, W. R.; CAVINESS, C. E. Stages of soybean development. **Special Report 80**, p. 2–11, 1977.
- FRIEND, A. D.; SCHUGART, H. H.; RUNNING, S. W. A physiology-based gap model of forest dynamics. **Ecology**, v. 74, n. 3, p. 792–797, 1993.

GUSTAFSON, P.; SRINIVASAN, C.; WASSERMAN, L. Local sensitivity analysis. **Bayesian statistics**, v. 5, p. 197–210, 1996.

HOMMA, T.; SALTELLI, A. Importance measures in global sensitivity analysis of nonlinear models. **Reliability Engineering & System Safety**, v. 52, n. 1, p. 1–17, 1996.

KUCHERENKO, S.; TARANTOLA, S.; ANNONI, P. Estimation of global sensitivity indices for models with dependent variables. **Computer Physics Communications**, v. 183, n. 4, p. 937–946, 2012.

MARIN, F. R.; RIBEIRO, R. V; MARCHIORI, P. E. R. How can crop modeling and plant physiology help to understand the plant responses to climate change? A case study with sugarcane. **Theoretical and Experimental Plant Physiology**, v. 26, n. 1, p. 49–63, 2014.

NORMAN, A. . Background. In: NORMAN, A. G. (Ed.). . **Soybean physiology, agronomy, and utilization**. New York: New York Academic Press, 1978.

POPPER, K. **The logic of scientific discovery**. New York: New York Routledge, 2010.

ROSENZWEIG, C. et al. The agricultural model intercomparison and improvement project (AgMIP): protocols and pilot studies. **Agricultural and Forest Meteorology**, v. 170, p. 166–182, 2013.

RÖTTER, R. P. et al. Simulation of spring barley yield in different climatic zones of Northern and Central Europe: a comparison of nine crop models. **Field Crops Research**, v. 133, p. 23–36, 2012.

SALTELLI, A. et al. **Global sensitivity analysis: the primer**. [s.l.] John Wiley & Sons, 2008.

SALTELLI, A. et al. **Sensitivity analysis in practice: a guide to assessing scientific models**. [s.l.] John Wiley & Sons, 2004.

TAIZ, L.; ZEIGER, E. **Plant physiology**. 5. ed. Sunderland, MA: Sunderland, MA Sinauer Associates, 2010.

TENG, P. S. et al. Simulation of pest effects on crops using coupled pest-crop models: the potential for decision support. In: **Understanding options for agricultural production**. [s.l.] Springer, 1998. p. 221–266.

WALLACH, D. et al. Parameter estimation for crop models. **Agronomy journal**, v. 93, n. 4, p. 757–766, 2001.

WHIGHAM, D. K.; MINOR, H. C. Agronomic characteristics and environmental stress. **Soybean physiology, agronomy, and utilization**. Academic Press, New York, p. 77–112, 1978.

WHITE, M. A. et al. Parameterization and sensitivity analysis of the BIOME–BGC terrestrial ecosystem model: net primary production controls. **Earth interactions**, v. 4, n. 3, p. 1–85, 2000.

ZIMMERMANN, M. H. Transport in the phloem. **Annual Review of Plant Physiology**, v. 11, n. 1, p. 167–190, 1960.

3. CALIBRAÇÃO E AVALIAÇÃO DO MODELO DSSAT/CROPGRO-SOYBEAN PARA DIFERENTES GRUPOS DE MATURAÇÃO DE SOJA DO BRASIL

Resumo

A soja (*Glycine max* L.) é uma planta oleaginosa cujo centro de origem é o Noroeste da China. Essa planta, nas últimas décadas, transformou-se em uma das principais *commodities* agrícolas e é o principal gerador de divisas para o Brasil. Nesse contexto, ferramentas de modelagem de sistemas agrícolas têm contribuído para o estudo dessa espécie em diferentes condições edafoclimáticas. Dentre os instrumentos de modelagem destaca-se o modelo CROPGRO que é utilizado na plataforma DSSAT. Esse modelo demanda calibrações para diferentes regiões de estudo. Para tais calibrações a geração de dados de entrada se faz necessária, como dados meteorológicos e de desenvolvimento da cultura. O presente capítulo tem como objetivo calibrar o modelo DSSAT/CROPGRO-SOYBEAN para a soja em ambiente de produção brasileiro. A parametrização foi realizada com base nos dados observados e na simulação de massa seca vegetativa, índice de área foliar e produção de grãos, para os grupos de maturação relativa 6.0, 7.0, 8.2 e 9.2. Os indicadores de eficiência de modelagem (e.g coeficiente de eficiência de modelagem de Nash-Sutcliffe variando de 0,59 a 0,97) demonstraram um bom ajuste da simulação aos pontos observados.

Palavras-chave: Análise de crescimento; Parametrização; Modelagem agrícola

Abstract

Soybean (*Glycine max* L.) is an oil-bearing plant whose center of origin is northwest China. This plant, in the last decades, has become one of the main agricultural commodities and is the main generator of foreign exchange for Brazil. In this context, modeling tools of agricultural systems have contributed to the study of this species in different edaphoclimatic conditions. Among the modeling tools, it stands out the CROPGRO model that is used in the DSSAT platform. This model requires calibrations for different study regions. For such calibrations the generation of input data is necessary, such as meteorological and crop development data. The objective of this chapter is to calibrate the DSSAT/CROPGRO-SOYBEAN model for soybeans in a Brazilian production environment. The parameterization was performed based on observed data and the simulation of biomass accumulation, leaf area index and grain yield, for the relative maturity groups 6.0, 7.0, 8.2 and 9.2. Modeling efficiency indicators (e.g. Nash-Sutcliffe index ranging from 0.59 to 0.97) demonstrated a good fit of the simulation to the observed data.

Keywords: Growth analysis; Parameterization; Agricultural modeling

3.1. Introdução

O centro de origem da soja é a região da Manchúria (NORMAN, 1978), há evidências que o início da domesticação dessa espécie tenha ocorrido por volta do século XXX aC na China, Japão e Coreia (LEE et al., 2011). A produção mundial dessa cultura foi restrita ao sudeste asiático até as três primeiras décadas do século XX (HYMOWITZ, 1970). Entre as décadas de 1960 e 1970, essa cultura ganhou importância global sendo os EUA, o Brasil e a

Argentina os principais produtores e a soja tornou-se a principal fonte de proteína alimentar do mundo (BONATO; BONATO, 1987; USDA, 2017b).

A produção de soja em grande escala requereu que a cultura fosse difundida para diferentes condições edafoclimáticas do globo. Tais relações correlacionam as plantas com o meio que as cerca, evidentemente que essas variabilidades — meteorológicas e de solo — têm uma estreita relação com a produtividade agrícola. Essas variáveis podem ser estudadas através dos modelos de crescimento de plantas (SAU; BOOTE; RUÍZ-NOGUEIRA, 1999; WILKERSON et al., 1983; ZANON; STRECK; GRASSINI, 2016) sendo o CROPGRO um dos modelos mais utilizados mundialmente.

O modelo genérico CROPGRO foi desenvolvido inicialmente para as culturas da soja, amendoim e feijão (BOOTE et al., 1997, 1998; WILKERSON et al., 1983). Esse modelo é capaz de simular desenvolvimento diário da cultura da soja e a produção total obtida por safra (ALAGARSWAMY et al., 2000; BATTISTI, 2016; BHATIA et al., 2008; BOOTE et al., 1997; SAU; BOOTE; RUÍZ-NOGUEIRA, 1999). O CROPGRO foi desenvolvido a partir de uma série de modelos preexistentes, que agregam e.g: (i) variações ao longo do desenvolvimento fenológico; (ii) possibilidade de estabelecer diferentes datas de plantio; (iii) incorporação de dados meteorológicos, como precipitação pluvial, temperatura do ar e radiação solar; (iv) reações fisiológicas, como respiração e fotossíntese; (v) partição de carbono; (vi) translocação de nitrogênio e (vii) senescência (WILKERSON et al., 1983)

O CROPGRO apresenta uma abordagem flexível para os diferentes estádios fenológicos da cultura de interesse, com diferentes respostas à temperatura do ar, fotoperíodo, déficit hídrico e a concentração de nitrogênio no solo (BOOTE et al., 1998). O referido modelo está contido na plataforma *Decision Support System for Agrotechnology Transfer* (DSSAT) que simula o desenvolvimento de diferentes culturas levando em conta: (a) aspectos genéticos; (b) clima local; (c) características de solo e (d) manejo agrônômico (JONES et al., 1998). O DSSAT adota uma estrutura modular, de modo que cada módulo é um modelo independente e que interagem entre si, facilitando assim a aplicação dos modelos para diferentes propósitos (JONES et al., 2003).

Os modelos, assim como qualquer formulação teórica, são continuamente testados por meio da confrontação com dados experimentais. É uma etapa essencial para o aprimoramento da teoria e, conseqüentemente, para o desenvolvimento da modelagem agrícola como ciência. Para tal, a literatura enfatiza a importância de aumentar a qualidade da parametrização em modelos de simulação de culturas (MAKOWSKI et al., 2006).

Especificamente para a soja no ambiente de produção brasileiro, nota-se uma lacuna no conhecimento do potencial produtivo e do uso da modelagem agrícola. Estudos que agregam ensaios fitotécnicos da cultura da soja — em condição potencial — e com uso de modelos baseados em processos, são, ainda muito incipientes no Brasil. Trabalhos nessa direção já foram realizados nos EUA e Argentina (GRASSINI et al., 2015; LA MENZA et al., 2017; MERLOS et al., 2015). Este capítulo busca avançar em termos de parametrização do modelo DSSAT/CROPGRO-SOYBEAN para o sistema de produção da soja brasileira, tendo como objetivos: (i) calibrar o modelo DSSAT/CROPGRO-SOYBEAN para o sistema de produção da soja no Brasil e (iii) avaliar as previsões de acúmulo de biomassa, índice de área foliar e produção de grãos.

3.2. Material e Métodos

3.2.1. Descrição do Modelo

O CROPGRO simula o desenvolvimento da cultura da soja utilizando dados climáticos e de disponibilidade hídrica (JAGTAP; JONES, 2002), através da modelagem baseada em processos de desenvolvimento da cultura da soja. Essas simulações incluem a fenologia, desenvolvimento de dossel, acumulação e partição de biomassa, crescimento de raízes e estresse hídrico, entre outras. O modelo adota a escala de tempo diária e é projetado para simular todo o desenvolvimento da planta, sendo requeridos parâmetros físico-hídricos do solo e os dados de entrada: variáveis meteorológicas diárias — radiação solar (MJ m^{-2}), temperatura do ar, máxima e mínima ($^{\circ}\text{C}$), precipitação pluvial (mm) — e irrigação (mm) (BOOTE et al., 1998).

A intercepção de radiação é calculada pela lei de Beer e o desenvolvimento dos estádios fenológicos é baseado em funções de tempo térmico que descrevem a taxa de emissão de folhas, caule, vagens, formação de grãos e senescência (BOOTE; PICKERING, 1994). A acumulação e particionamento de biomassa são baseados em um algoritmo de eficiência de uso de radiação que é modificado pela temperatura do ar, pelo estresse hídrico e pela respiração de crescimento (JEUFFROY et al., 2006).

Apesar de robustos, tais modelos podem ter seu uso limitado pela necessidade de calibração de coeficientes de cultivares em uma ampla gama de ambientes. A calibração consiste na estimativa dos parâmetros do modelo para melhorar o ajuste entre os dados simulados e obtidos experimentalmente (WALLACH et al., 2001b). Para a cultura da soja isso é particularmente importante dada à ampla gama de grupos de maturação relativa (GMR). Os

GMR apresentam diferentes sensibilidades para o fotoperíodo, e consequentemente, duração dos principais estádios de desenvolvimento (CREGAN; HARTWIG, 1984).

3.2.2. Grupos de maturação relativa selecionados e dados de campo

Para o estudo da cultura da soja na escala nacional brasileira— envolvendo uma diversidade de condições climáticas e de solo em ambiente predominantemente tropical - foi necessário considerar diferentes GMR para a calibração do modelo. Buscou-se na literatura estudos que subsidiassem a calibração do modelo para diferentes os diferentes GRM e que fossem capazes de abranger, ao menos, 80% do território nacional. Para tanto, selecionou-se os seguintes bancos de dados e/ou experimentos de campo: (a) banco de dados experimentais #1 (E1) para o GRM 7.0 (PEREIRA, 2002); (b) banco de dados experimentais #2 (E2) para o GRM 8.0 (OLIVEIRA; NASCENTE; KLUTHCOUSKI, 2013) e (c) banco de dados experimentais #3 (E3) para o GRM 9.0 (COSTA, 2008). Pela dificuldade de se obter dados, para o GMR 6.0, notou-se a necessidade de conduzir outros dois experimentos de campo para esse GMR, como descrito na seção 3.2.3.

O CROPGRO foi parametrizado e simulado com dados de cultivares de quatro GRM em diferentes regiões do Brasil (COSTA, 2008; OLIVEIRA; NASCENTE; KLUTHCOUSKI, 2013; PEREIRA, 2002). Todos os experimentos tiveram um manejo adequado de fertilizantes e controle de pragas, doenças e plantas espontâneas. O espaçamento entre linhas variou de 0,45 a 0,50 m e a população de plantas entre 355 a 500 mil plantas ha⁻¹.

As propriedades dos solos (Tabela 1), para os experimentos E1 e E4 (Argissolo Vermelho-Amarelo) e E2 e E3 (Latossolo Amarelo) foram construídos com os dados físico-hídricos obtidos na plataforma WISE (*World Inventory of Soil Emission Potentials*). Para E5, Nitossolo Vermelho (EMBRAPA, 2006), utilizou-se dados locais, gentilmente disponibilizados pela equipe de pesquisa do Prof. Dr. Paulo Leonel Libardi.

Os dados meteorológicos utilizados para a calibração de E1, E2 e E3 foram obtidos de estações meteorológicas do Instituto Nacional de Meteorologia (INMET) para os municípios de Viçosa-MG, Santo Antônio de Goiás-GO e Paragominas-PA. No E4 os dados foram coletados no Posto Meteorológico da ESALQ/USP, para E5 os dados foram coletados na própria área experimental na Fazenda Areão, através de uma estação agrometeorológica (Apêndice B).

Tabela 1. Dados de entrada (propriedades do solo) para o modelo DSSAT/CROPGRO-SOYBEAN Profundidade do solo (PROF), ponto de murcha permanente (PPM), capacidade de campo (CCA), ponto de saturação (PSA), fator de crescimento radicular (FCR), condutividade hidráulica saturada (CHS), densidade do solo (DSO), carbono orgânico (COR), teor de argila (ARG), teor de silte (SIL), pH em água (PHA) e capacidade de troca catiônica (CTC).

PROF	PPM	CCA	PSA	FCR	CHS	DSO	COR	ARG	SIL	PHA	CTC
cm		cm ³ cm ⁻³			cm h ⁻¹	g cm ⁻³		%			mol _c kg ⁻¹
<u>Argissolo Vermelho-Amarelo</u>											
0-20	0,223	0,271	0,574	0,9	0,27	1,30	3,95	34,0	36,9	5,7	6,8
20-40	0,291	0,346	0,606	0,9	0,34	1,30	3,95	40,8	32,0	5,7	5,8
40-60	0,253	0,372	0,570	0,9	0,37	1,14	3,95	59,1	25,2	5,7	5,8
<u>Latosolo Amarelo</u>											
0-20	0,144	0,309	0,452	1,0	1,02	1,30	3,14	15,0	7,0	5,7	9,0
20-40	0,069	0,219	0,399	0,6	2,63	1,50	1,57	22,0	6,0	5,9	5,0
40-60	0,154	0,289	0,418	0,4	0,85	1,48	1,57	31,0	5,0	6,0	3,0
<u>Nitossolo Vermelho</u>											
0-20	0,249	0,338	0,494	0,9	0,67	1,48	3,85	48,0	18,9	5,5	6,5
20-40	0,249	0,338	0,494	0,8	0,67	1,48	3,85	60,0	11,4	5,5	6,5
40-60	0,306	0,363	0,457	0,8	0,16	1,40	3,85	60,4	15,0	5,5	6,8

3.2.3. Experimentos de campo

Dois experimentos foram realizados no município de Piracicaba-SP, nas safras 2015/16 (E4) e 2016/17 (E5) e em diferentes tipos de solo. Em ambos, utilizaram-se o mesmo material genético a BRS 399-RR (GMR 6.0), cultivar da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Essa cultivar apresenta características agronômicas representativas na agricultura brasileira como: (i) precocidade do ciclo; (ii) resistência ao herbicida glifosato; (iii) resistência e/ou tolerância a doenças (cancro da haste, oídio, podridão parda da haste, podridão radicular) e resistência a nematoides de galha (*Meloidogyne incognita* e *Meloidogyne javanica*), nematoide retiforme (*Rotylenchulus reniformis*) e nematoide de cisto (*Heterodera glycines*, raças 3 e 14) e baixo fator de reprodução (2,8) para *Pratylenchus brachyurus* (PIPOLO et al., 2015).

O experimento E4 foi conduzido na área de experimentação pertencente ao Departamento de Engenharia de Biosistemas da Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ/USP), latitude 22°42'32"S, longitude 47°37'45"O, altitude de 548 m, área adjacente ao Posto Meteorológico da ESALQ/USP. Adotaram-se dois tratamentos: sequeiro e irrigado (sem estresse hídrico), em delineamento inteiramente casualizado com quatro repetições.

A semeadura da soja foi realizada em 18 de dezembro de 2015. Adotou-se o tratamento de sementes com Piraclostrobina (2,5%), Tiofanato metílico (22,5%) e Fipronil (25%) (Standak

Top, Basf) na dosagem de 100 mL por 100 kg de sementes e micronutrientes — cobalto (0,45%), molibdênio (9,0%) e níquel (0,9%) (Up seeds, Produquímica) — na dosagem de 150 mL para cada 50 kg de sementes. A adubação foi realizada — com base na análise química do solo (Apêndice C) — no sulco de plantio foi de 200 kg ha⁻¹ de fosfato monoamônico (10% N e 46% P₂O₅, Heringer) e adubação de cobertura 175 kg ha⁻¹ de ureia (46% N, Heringer) no estágio VC e 220 kg ha⁻¹ no estágio R5. Adotou-se essa estratégia de adubação pela falta de produtos inoculantes de sementes na região de Piracicaba, como sugere o estudo de Crispino et al. (2001).

A semeadura foi realizada em sistema de plantio direto em transição, sendo a cultura antecessora a braquiária (*Urochloa decumbens*), com espaçamento de 0,45 m entre linhas e população de 355 mil plantas por hectare. As parcelas experimentais delimitadas foram compostas de 12 linhas de 10 m de comprimento, área total da parcela de 54 m². Adotaram-se como parcela útil as oito linhas centrais, sendo, portanto quatro linhas de bordadura.

Os tratos fitossanitários foram baseados em monitoramentos frequentes de pragas, doenças e plantas espontâneas. Buscou-se a mínima interferência possível desses agentes na cultura para atender ao conceito de produtividade potencial e atingível, conforme descrito por Marin (2014). Aplicou-se: (a) para as daninhas (*Amaranthus viridis*, *Urochloa decumbens* e *Cyperus rotundus*) 3L ha⁻¹ de glifosato (Roundup, 720 g kg⁻¹ i.a., WG, Monsanto); (b) para lagartas (*Pseudoplusia includens*, *Anticarsia gemmatalis* e *Spodoptera frugiperda*) 70 mL ha⁻¹ de Flubendiamida (Belt, 480g L⁻¹, Bayer); (c) para percevejos (*Piezodorus guildinii* e *Nezara viridula*) 220 mL ha⁻¹ de Tiametoxam com Lambda-Cialotrina (Engeo Pleno, 141 g L⁻¹ e 106 g L⁻¹, Syngenta). Observou-se a baixa incidência de pragas e doenças na área, provavelmente por ser o primeiro ciclo de soja na área.

As parcelas irrigadas (E4) tiveram o gotejamento como sistema de irrigação, por meio de gotejadores autocompensantes (PCJ, Netafin, 8 L h⁻¹). O manejo das parcelas irrigadas foi realizado pelo balanço hídrico climatológico sequencial (THORNTHWAITE; MATHER, 1955) — adotou-se o nível mínimo de umidade do solo em 80% da capacidade de água disponível (CAD), para tanto adotou-se CAD de 100 mm. Cabe ressaltar que o tratamento irrigado não teve como objetivo avaliar estatisticamente o efeito da irrigação e sim conduzir a lavoura sob duas condições de disponibilidade hídrica do solo para oferecer subsídios ao processo de modelagem.

O experimento E5 foi conduzido na Fazenda Areão, na área de experimentação pertencente ao Departamento de Engenharia de Biossistemas da ESALQ/USP, latitude 22°41'58"S, longitude 47°38'42"O e altitude de 511m, em delineamento inteiramente casualizado com quatro repetições. As parcelas experimentais delimitadas foram compostas de

12 linhas de 10 m de comprimento, e a área total de 54 m². Adotaram-se como parcela útil as oito linhas centrais, sendo, portanto, quatro linhas de bordadura.

A semeadura do material genético, no E5, foi realizada em 30 de outubro de 2016 em sistema de plantio convencional: gradagem com grade aradora seguido de subsolagem e grade niveladora na sequência. O tratamento de sementes seguiu ao mesmo protocolo do E4, acrescido da inoculação das sementes com *Bradyrhizobium japonicum* e *Bradyrhizobium elkanii* (Masterfix, Stoller) na concentração de 5×10^9 UFC mL⁻¹ (unidades formadoras de colônias). Adotou-se o espaçamento de 0,45 m entre linhas e população de 355 mil plantas por hectare. A adubação — com base na análise química do solo (Apêndice C) — foi realizada na análise química do solo, no sulco de plantio com 196 kg ha⁻¹ de superfosfato simples (18% P₂O₅, 16% Ca e 8% S, Yara) e pulverização do solo com 4 kg ha⁻¹ de ácido bórico (99,9% H₃BO₃, Quiborax). Aplicou-se também 8 kg de sulfato de magnésio heptahidratado (9% Mg e 11% S, Quiriros), para suprir a demanda de magnésio na cultura no estágio fenológico R3.

As parcelas do E5 delimitadas foram compostas de 12 linhas de 10 m de comprimento. Adotou-se como parcela útil as oito linhas centrais, sendo, portanto quatro linhas de bordadura e a área útil da parcela de 54 m². O sistema de irrigação do referido experimento foi realizado via aspersão, por meio de um pivô central (20psi, Irrigabras, 90 m³ h⁻¹). Adotou-se o cálculo de balanço hídrico climatológico sequencial, sendo estabelecido o nível mínimo de umidade do solo em 80% da capacidade de água disponível (CAD) para efeito de manejo da irrigação, com o intuito de garantir adequado suprimento hídrico na cultura.

O tratamento fitossanitário do E5 obedeceu aos mesmos princípios do E4, aplicou-se: (a) glifosato (Roundup, 720 g kg⁻¹ i.a., Monsanto) na dosagem de 3L.ha⁻¹, para o controle de *Raphanus raphanistrum* e *Urochloa decumbens*, já para o controle de *Digitaria insularis* foi realizado capina manual; (b) de Tiametoxam com Lambda-Cialotrina (Engeo Pleno, 141 g L⁻¹ e 106 g L⁻¹, Syngenta), para o controle de vaquinhas (*Diabrotica* spp); (c) Fluxapirroxade e Piraclostrobina (Orkestra, 167g L⁻¹, 333g L⁻¹, Basf) na dosagem 350 mL ha⁻¹, como preventivo de doenças fúngicas e (d) Acefato (Orthene, 750 g kg⁻¹ i.a, Nortox) para o controle de percevejos (*Piezodorus guildinii* e *Nezara viridula*). Nesse experimento notou-se uma maior pressão de pragas e doenças, em relação ao E4 necessitando de um maior número de pulverizações: três pulverizações para o E4 e sete para o E5.

3.2.4. Medidas biométricas

Durante o desenvolvimento da cultura da soja (E4 e E5) realizou-se análises biométricas frequentes. Todas as biometrias foram destrutivas (total de 6 plantas por amostra), em cada avaliação dos experimentos coletou-se: (a) área foliar total — todas as folhas da planta foram destacadas e digitalizadas — calculada através do software Quant (LIBERATO, 2003); (b) número de folíolos (contagem do número de folíolos em todas as ramificações); (c) número de ramificações; (d) massa seca das folhas; (e) massa seca do caule; (f) massa seca de raízes; (g) massa seca de vagens por planta; (h) massa seca de grãos; (i) número de vagens e (j) número de grãos por planta.

Para a obtenção da massa seca dos referidos órgãos vegetais, foram fracionados e colocados em estufa de ventilação forçada de ar a 70°C até atingirem massa constante. O material foi então pesado em balança de precisão 0,001g.

O acompanhamento da fenologia da cultura foi realizado de acordo com o sistema de classificação de estágio de desenvolvimento, proposto por Fehr e Caviness (1977) para a identificação dos principais eventos vegetativos e reprodutivos relacionados ao desenvolvimento da cultura (Apêndice A).

3.2.5. Calibração do modelo DSSAT/CROPGRO-SOYBEAN

Os modelos mecanísticos como o DSSAT/CROPGRO-SOYBEAN podem ser ajustados para diferentes condições edafoclimáticas, com possibilidade de introdução de incertezas e propagação de erros no uso dos modelos. A calibração do modelo aparece como ferramenta para minimizar o erro, uma vez que permite o melhor ajuste entre os dados modelados e medidos em campo (WALLACH et al., 2001b). Dessa maneira, uma vez realizada a calibração dos parâmetros para uma cultivar definida em determinado ambiente de produção, o modelo é capaz de simular o desenvolvimento da cultura com a cultivar calibrada.

Com base nos dados biométricos gerados experimentalmente e coletados na literatura científica, iniciou-se o processo de calibração com os dados. Analisaram-se os principais parâmetros genéticos contidos no modelo DSSAT/CROPGRO-SOYBEAN, dentre esses destaca-se:

A metodologia de calibração do modelo seguiu o procedimento proposto por Boote (1999) em conjunto com o procedimento de calibração automática (para ajuste fino de parâmetros) conforme descrito em Marin et al (2011).

As variáveis analisadas para o grupo de maturação 6 (GM6) foram: massa seca vegetativa (VMS), índice de área foliar (IAF) e produtividade (MSG) para as condições irrigado (IRR) e sequeiro (SEQ), ao longo dos experimentos (I) e (II). Os dados obtidos por Pereira (2002), possibilitaram a calibração do modelo para o GM7 através das variáveis: massa seca de dossel (DMS), IAF e MSG, para soja irrigada nas datas de plantio (1) e (2). As variáveis DMS, IAF e MSG foram utilizadas para a calibração do GM8 (OLIVEIRA; NASCENTE; KLUTHCOUSKI, 2013) e GM9 (COSTA, 2008). : (a) CSDL (*critical short day length*) comprimento crítico do dia curto; (b) PPSEN (*slope of the relative response of development to photoperiod*) a resposta relativa do desenvolvimento da planta ao fotoperíodo; (c) EMFL (*time between plant emergence and flower appearance*) o tempo entre a emergência e o início do florescimento da planta (R1); (d) FLSH (*time between first flower and first pod*) o tempo entre R1 e início da frutificação (R3); (e) FLSD (*time between first flower and first seed*) tempo entre R1 e a formação da primeira semente (R5); (f) SDPM (*time between first seed and physiological maturity*) tempo entre R5 e a maturidade fisiológica (R7); (g) FLLF (*time between first flower and end of leaf expansion*) tempo entre R1 e o fim da expansão foliar; (h) LFMAX (*maximum leaf photosynthesis*) taxa máxima de fotossíntese foliar; (i) SLAVR (*specific leaf area*) área foliar específica; (j) XFRT (*maximum fraction of daily growth that is partitioned to seed and shell*) fração máxima do crescimento diário que é dividida em sementes e casca ; (k) WTPSD (*maximum weight per seed*) peso máximo por semente; (l) SFDUR (*seed filling duration for pod cohort*) duração do enchimento de grãos; (m) SDPDV (*average seed per pod under standard growing conditions*) média da semente por vagem; (n) PODUR (*time required for cultivar to reach final pod load under optimal conditions*) tempo requerido para que a cultivar atinja a carga máxima de vagens; (o) THRSH (*threshing percentage, the maximum ratio of seed/(seed+shell) at maturity*) índice de colheita.

3.2.6. Análise estatística de desempenho da modelagem

Os dados de entrada foram comparados estatisticamente aos simulados pelo DSSAT. Aplicou-se os testes estatísticos descritos por Krause, Boyle e Bäse (2005): (i) coeficiente de determinação (R^2 , equação 1); (ii) desvio médio absoluto (DMA, equação 2); (iii) raiz do erro quadrático médio (REQM, equação 3); índice de concordância de Wilmott (D, equação 4) e o coeficiente de eficiência de modelagem de Nash-Sutcliffe (COE, equação 5).

$$R^2 = \frac{\sum_{i=1}^n (E_i - \bar{O})^2}{\sum_{i=1}^n (E_i - \bar{O})^2 + \sum_{i=1}^n (E_i - O_i)^2} \quad (1)$$

em que O_i o valor observado, E_i o valor simulado e $\bar{O}$ a média dos valores observados.

$$DMA = \frac{\sum_{i=1}^n |e_t|}{n} \quad (2)$$

em que e_t a diferença do valor observado e o simulado e n o número de períodos

$$RQME = \sqrt{\frac{\sum (E_i - O_i)^2}{n}} \quad (3)$$

em que O_i o valor observado, E_i a média dos valores simulados n o número de períodos.

$$D = 1 - \left[\frac{\sum_{i=1}^n (M_i - E_i)^2}{\sum_{i=1}^n (|M_i - \bar{M}| + |E_i - \bar{M}|)^2} \right] \quad (4)$$

em que M_i é o valor medido de ordem i , E_i é o valor estimado de ordem i , $\bar{M}$ é a média dos valores medidos, e n o número dos valores medidos.

$$COE = 1 - \frac{\sum_{i=1}^n (E_i - E_s)^2}{\sum_{i=1}^n (E_i - \bar{E}_s)^2} \quad (5)$$

em que E_s é o valor medido, E_i é o valor estimado e $\bar{E}_s$ é a média dos valores medidos, e n o número dos valores medidos.

3.3. Resultados e Discussão

3.3.1. Parâmetros físico-hídricos do solo e dados meteorológicos de entrada

A temperatura média do ar no ciclo da cultura da soja, nas diferentes condições edafoclimáticas, variou entre 22,66 a 27,33°C (Tabela 2). Durante os experimentos o fator temperatura do ar não foi limitante para o desenvolvimento da cultura; visto que a temperatura basal da soja é 10°C, o seu ponto ótimo 30°C e acima de 40°C o desenvolvimento da planta cessa (BROWN, 1960; FARIAS; NEPOMUCENO; NEUMAIER, 2007; GARNER; ALLARD, 1930). Com relação à precipitação pluvial, para as condições tropicais, a cultura da soja apresenta uma demanda hídrica média entre 450 a 850 mm (FARIAS; NEPOMUCENO; NEUMAIER, 2007). Os experimentos E1 e E2 foram conduzidos com irrigação plena, suprimindo a depleção de água por evapotranspiração de 722,7 e 823 mm, respectivamente (PEREIRA, 2002).

Tabela 2. Médias da temperatura do ar máxima (TMAX), mínima (TMIN), média (TMED) e somatório da precipitação pluvial (Σ PREC).

Experimentos	TMAX (°C)	TMIN (°C)	TMED (°C)	Σ PREC (mm)
E1 (safra 1997/98)	30,62	22,28	26,46	547,0
E1 (safra 1998/99)	30,54	21,22	25,64	608,5
E2 (safra 2007/08)	25,77	19,54	22,66	813,2
E3 (safra 2007)	27,18	22,46	24,82	966,4
E4 (safra 2015/16)	33,04	21,43	27,23	687,0
E5 (safra 2016/17)	33,02	21,64	27,33	982,0

No E4 o tratamento conduzido em condição de sequeiro apresentou dois períodos de estresse hídrico. O primeiro, com duração de aproximadamente 10 dias, coincidiu com o final do período vegetativo e início do florescimento. Nessa fase, o estresse hídrico pode induzir ao abortamento floral (WHIGHAM; MINOR, 1978). O outro período, de cinco dias, ocorreu no estágio fenológico R6. A deficiência hídrica nessa fase induz a diminuição do período de enchimento de grãos, estimulado pela aceleração da senescência, com consequente redução na produtividade (DE SOUZA; EGLI; BRUENING, 1997) (Figura 1). Nesse experimento o suprimento hídrico proporcionou uma produtividade 5.435 kg ha⁻¹ no tratamento irrigado, enquanto no tratamento sequeiro a produtividade foi de 3.076 kg ha⁻¹. Já em E5, não foi observado a ocorrência de estresse hídrico ao longo do desenvolvimento da lavoura para o

tratamento de sequeiro, as produtividades obtidas foram de 5.704 kg ha⁻¹ (irrigado) e 5.694 kg ha⁻¹ (sequeiro).

Figura 1. Balanço hídrico climatológico para o E4 (cultivar BRS399, Piracicaba-SP, safra 2015/16), apresentando o excedente hídrico (EXC) e a deficiência hídrica (DEF) ao longo da cultura da soja para os tratamentos irrigado (a) e sequeiro (b). Adotou-se CAD de 100 mm.

3.3.1. Calibração do modelo DSSAT/CROPGRO-SOYBEAN

A calibração do modelo iniciou-se pelo ajuste dos parâmetros relacionados a fenologia da cultura, ajustando-se os parâmetros EM-FL e SD-PM. Esses parâmetros relacionam, respectivamente, os períodos compreendidos entre a emergência da plântula e o florescimento (R1) e o início da formação da semente (R5) à maturidade fisiológica (R7) da cultura. O ajustamento desses parâmetros possibilitou o alinhamento do ciclo fenológico da simulação ao observado no campo.

Na sequência, tratou-se de ajustar os parâmetros relacionados ao acúmulo de matéria seca da cultura ao longo do ciclo, que são: LFMAX e SLAVR. O primeiro parâmetro computa a taxa máxima de fotossíntese ($\text{mg CO}_2 \text{ m}^{-2}\text{s}^{-1}$) a 30°C, alta luminosidade e assumindo a concentração padrão de CO_2 atmosférico (400 ppm). Esse parâmetro variou de 1,0 a 3,0 dentre os grupos de maturação calibrados. No segundo parâmetro, a variação do parâmetro refere-se à área foliar específica ($\text{cm}^2 \text{ g}^{-1}$) da cultivar em condições padrões de crescimento, o parâmetro variou de 275 a 500 dentre as cultivares trabalhadas. Com isso obteve-se o ajustamento das curvas de IAF e acúmulo de massa seca (Figura 2a, 2b, 3a, 3b, 4a, 4b, 5a, 5b, 6a e 6b).

Na terceira fase da calibração buscou-se então ajustar os parâmetros, de cada GMR, que controlam o intervalo entre as fases fenológicas (dia fototérmico) do ciclo reprodutivo, que são: (i) FL-SH, variando de 9 a 13 (ii) FL-SD, variando de 15 a 16 (iii) SD-PM, variando de 16,4 a 31 e (iv) SFDUR, variando de 16 a 23 (Figuras 2c, 3c, 4c, 5c, 6c).

Figura 2. Variação temporal das simulações de massa seca do dossel (DMS), índice de área foliar (IAF) e produtividade (MSG) para a variedade Capinópolis, grupo de maturação relativa 7.0, safra 1997/98 e safra 1998/99, em Viçosa-MG.

Figura 3. Variação temporal das simulações de massa seca do dossel (DMS), índice de área foliar (IAF) e produtividade (MSG) para a cultivar BRS Valiosa, grupo de maturação relativa 8.2, safra 2007/08 (E2), em Santo Antônio de Goiás-GO.

Figura 4. Variação temporal das simulações de massa seca do dossel (DMS), índice de área foliar (IAF) e produtividade (MSG) para a cultivar BRS Tracajá, grupo de maturação relativa 9.2, safra 2007 (E3), em Paragominas-PA.

Figura 5. Variação temporal das simulações de massa seca vegetativa (VMS), índice de área foliar (IAF) e produtividade (MSG) para a cultivar BRS399, grupo de maturação relativa 6.0, safra 2015/16 (E4), em Piracicaba-SP.

Figura 6. Variação temporal das simulações de massa seca vegetativa (VMS), índice de área foliar (IAF) e produtividade (MSG) para a cultivar BRS399, grupo de maturação relativa 6.0, safra 2016/17 (E5), em Piracicaba-SP.

3.3.2. Análise do desempenho do DSSAT/CROPGRO-SOYBEAN para os grupos de maturação relativa avaliados

Como o DSSAT/CROPGRO-SOYBEAN tem a finalidade de simular o desenvolvimento e o crescimento da cultura, a comparação entre os valores simulados e as observações de campo para diferentes variáveis da planta ao longo do ciclo são particularmente importantes para avaliação do desempenho do modelo (Tabela 3). Para a variável massa seca de grãos, o RQME de 857,91 kg ha⁻¹ para a cultivar BRS 399 RR (E5) foi maior que o valor obtido por Battisti (2016) (RQME = 759 kg ha⁻¹) para a cultivar BRS 284 (GRM 6.0) também em condição de sequeiro. Para a condição irrigado o RQME de 969,72 kg ha⁻¹, Ruíz-Nogueira, Boote e Sau (2001) observaram para uma cultivar Manjor (GRM 0.0), a tendência de o modelo subestimar a produtividade (RQME = 505 kg ha⁻¹) em condições de ausência de restrição hídrica.

O RQME de 0,24 para a cultivar BRS 399 RR foi inferior ao obtido por Setiyono et al (2008) (RQME = 0,52) para a cultivar NE 3001 (GRM 3.0). Já a cultivar BRS Valiosa (E2) apresentou um RQME = 1,45, superior ao obtido por Wang et al (2003) (RQME=1,07) para a cultivar Dekalb 390 RR. Martorano et al (2008) obtiveram valores para a cultivar Fepagro RS-10 de D = 0,97 para variável de acúmulo de biomassa e D = 0,83 para o IAF. As variáveis relacionadas ao acúmulo de massa seca e IAF indicaram alta capacidade preditiva do modelo, com R² variando de 0,82 a 0,99 para E2 (GMR 8.2) e E5 (GMR 6.0), respectivamente.

A variável de produtividade (MSG) obtida para a cultivar BRS 399 RR (E5) indicou boa capacidade preditiva do modelo (R² = 0,99 e D = 0,95), valor superior ao encontrado por Battisti (2016) (R² = 0,79 e D = 0,93) para a cultivar BRS 284.

Com relação ao COE, obtiveram-se valores de 0,59 a 0,97 dentre as variáveis analisadas. Para a cultivar BRS 399 RR (E5), as variáveis vegetativas (VMS e IAF) obtiveram uma melhor eficiência de modelagem em relação a variável de produtividade, para as duas condições de disponibilidade hídrica.

Tabela 3. Análise estatística do desempenho de modelagem das variáveis vegetativas e de produção produtiva, para os experimentos E1, E2, E3, E4 e E5. Média dos valores simulados (MEi), média dos valores observados (MOi), coeficiente de determinação (R^2), desvio médio absoluto (DMA), raiz do erro quadrático médio (REQM), índice de concordância de Wilmott (D) e o coeficiente de eficiência de modelagem de Nash-Sutcliffe (COE).

Variáveis	ME _i	MO _i	R ²	DMA	RQME	D	COE
<u>E1</u>							
DMS (kg ha ⁻¹) (97/98)	5042,83	5183	0,95	874	1232,17	0,96	0,89
IAF (m ² m ⁻²) (97/98)	4,8	4,918	0,86	0,92	1,04	0,91	0,73
MSG (kg ha ⁻¹) (97/98)	6476	6525	—	290	290	—	—
DMS (kg ha ⁻¹) (98/99)	6365,6	6525,4	0,92	1287,33	1397,91	—	—
IAF (m ² m ⁻²) (98/99)	4,65	4,58	0,96	0,41	0,63	0,97	0,91
MSG (kg ha ⁻¹) (98/99)	3680	3750	—	70	70	0,93	0,81
<u>E2</u>							
DMS (kg ha ⁻¹)	2966,67	4533,33	0,99	1567	1779,39	0,91	0,71
IAF (m ² m ⁻²)	3,67	4,07	0,82	1,27	1,45	0,93	0,76
MSG (kg ha ⁻¹)	3708	3620	—	88	38	—	—
<u>E3</u>							
DMS (kg ha ⁻¹)	4969,46	4712,31	0,99	437	441,41	0,99	0,98
IAF (m ² m ⁻²)	5,17	4,33	0,86	1,19	1,28	0,86	0,69
MSG (kg ha ⁻¹)	3379	3341	—	38	38	—	—
<u>E4</u>							
VMS (kg ha ⁻¹) (irrigado)	3436,71	3615,51	0,99	182	189,08	0,99	0,97
IAF (m ² m ⁻²) (irrigado)	3,07	3,51	0,96	0,48	0,54	0,94	0,79
MSG (kg ha ⁻¹) (irrigado)	4830	5435	—	605	605	—	—
VMS (kg ha ⁻¹) (sequeiro)	1741,71	1947,91	0,98	177	231,03	0,96	0,87
IAF (m ² m ⁻²) (sequeiro)	1,62	1,81	0,96	0,19	0,24	0,92	0,61
MSG (kg ha ⁻¹) (sequeiro)	2931	3076	—	145	145	—	—
<u>E5</u>							
VMS (irrigado)	3027,31	2458,95	0,99	521	712,76	0,97	0,87
IAF (irrigado)	3,06	2,72	0,98	822	0,61	0,97	0,89
MSG (irrigado)	3398,5	4127,75	0,98	679	969,72	0,93	0,59
VMS (sequeiro)	3027,31	2360,12	0,97	660	884,58	0,95	0,78
IAF (sequeiro)	3,06	2,71	0,97	0,47	0,68	0,97	0,86
MSG (sequeiro)	3407,75	4129,25	0,99	681	857,91	0,95	0,74

3.4. Conclusão

O modelo DSSAT/CROPGRO-SOYBEAN apresentou boa capacidade preditiva para os grupos de maturação 6.0, 7.0, 8.0 e 9.0 indicando um alto potencial de aplicação para as condições da soja tropical no Brasil. A riqueza de dados disponíveis na literatura e dos experimentos conduzidos para este trabalho contribuíram para a parametrização de diferentes grupos de maturação relativa de soja. Isso proporcionou utilizar dados existentes, que normalmente são subutilizados para estudos de modelagem e permitem, assim, avanço mais rápido desta linha de pesquisa em países como o Brasil. Os erros de simulação foram comparáveis aos estudos com outras cultivares e locais relatados na literatura. A simulação do modelo apresentou boa precisão e acurácia para acúmulo de biomassa, índice de área foliar e produtividade.

REFERÊNCIAS

ALAGARSWAMY, G. et al. Evaluation and application of the CROPGRO-Soybean simulation model in a Vertic Inceptisol. **Agricultural Systems**, v. 63, n. 1, p. 19–32, 2000.

BATTISTI, R. **Calibration, uncertainties and use of soybean crop simulation models for evaluating strategies to mitigate the effects of climate change in Southern Brazil**. Piracicaba: Universidade de São Paulo, 2016.

BHATIA, V. S. et al. Analysis of potential yields and yield gaps of rainfed soybean in India using CROPGRO-Soybean model. **agricultural and forest meteorology**, v. 148, n. 8, p. 1252–1265, 2008.

BONATO, E. R.; BONATO, A. L. V. A soja no Brasil: história e estatística. **Embrapa Soja-Documentos (INFOTECA-E)**, 1987.

BOOTE, K. J. et al. Evaluation of the CROPGRO-Soybean model over a wide range of experiments. In: **Applications of systems approaches at the field level**. [s.l.] Springer, 1997. p. 113–133.

BOOTE, K. J. et al. The CROPGRO model for grain legumes. In: TSUJI, G. Y.; HOOGENBOOM, G.; THORNTON, P. K. (Eds.). . **Understanding options for agricultural production**. [s.l.] Springer, 1998. p. 99–128.

BOOTE, K. J. Concepts for calibrating crop growth models. **DSSAT version**, v. 3, n. 4, p. 179–200, 1999.

BOOTE, K. J.; PICKERING, N. B. Modeling photosynthesis of row crop canopies. **HortScience**, v. 29, n. 12, p. 1423–1434, 1994.

BROWN, D. M. Soybean ecology. I. Development-temperature relationships from controlled environment studies. **Agronomy Journal**, v. 52, n. 9, p. 493–496, 1960.

COSTA, J. DE P. R. DA. **Modelagem e simulação das interações biosfera-atmosfera em plantio de soja na Amazônia**. [s.l.] Universidade Federal de Viçosa, 2008.

CREGAN, P. B.; HARTWIG, E. E. Characterization of flowering response to photoperiod in diverse soybean genotypes. **Crop Science**, v. 24, n. 4, p. 659–662, 1984.

CRISPINO, C. C. et al. Adubação nitrogenada na cultura da soja. **Embrapa Soja. Comunicado Técnico**, 2001.

DE SOUZA, P. I.; EGLI, D. B.; BRUENING, W. P. Water stress during seed filling and leaf senescence in soybean. **Agronomy Journal**, v. 89, n. 5, p. 807–812, 1997.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. Ecofisiologia da soja. **Embrapa Soja-Circular Técnica (INFOTECA-E)**, 2007.

FEHR, W. R.; CAVINESS, C. E. Stages of soybean development. **Special Report 80**, p. 2–11, 1977.

GARNER, W. W.; ALLARD, H. A. Photoperiodic response of soybeans in relation to temperature and other environmental factors. **J. agric. Res**, v. 41, n. 1, p. 0, 1930.

GRASSINI, P. et al. Soybean yield gaps and water productivity in the western US Corn Belt. **Field Crops Research**, v. 179, p. 150–163, 2015.

HYMOWITZ, T. On the domestication of the soybean. **Economic Botany**, v. 24, n. 4, p. 408–421, 1970.

JAGTAP, S. S.; JONES, J. W. Adaptation and evaluation of the CROPGRO-soybean model to predict regional yield and production. **Agriculture, ecosystems & environment**, v. 93, n. 1, p. 73–85, 2002.

JEUFFROY, M. H. et al. Crop models with genotype parameters. **Working with crop models**. (Eds D Wallach, D Makowski, JW Jones) pp, p. 281–308, 2006.

JONES, J. W. et al. Decision support system for agrotechnology transfer: DSSAT v3. In: **Understanding options for agricultural production**. [s.l.] Springer, 1998. p. 157–177.

JONES, J. W. et al. The DSSAT cropping system model. **European journal of agronomy**, v. 18, n. 3, p. 235–265, 2003.

KRAUSE, P.; BOYLE, D. P.; BÄSE, F. Comparison of different efficiency criteria for hydrological model assessment. **Advances in Geosciences**, v. 5, p. 89–97, 2005.

LA MENZA, N. C. et al. Is soybean yield limited by nitrogen supply? **Field Crops Research**, v. 213, p. 204–212, 2017.

LEE, G.-A. et al. Archaeological soybean (*Glycine max*) in East Asia: does size matter? **PloS one**, v. 6, n. 11, p. e26720, 2011.

LIBERATO, J. R. **Desenvolvimento e avaliação do Software Quant para quantificação de doenças de plantas por análise de imagens**. [s.l.] Universidade Federal de Viçosa, 2003.

MAKOWSKI, D. et al. Parameter estimation for crop models. **Working with dynamic crop**

models. Elsevier, Amsterdam, p. 101–149, 2006.

MARIN, F. R. et al. Parameterization and evaluation of predictions of DSSAT/CANEGRO for Brazilian sugarcane. **Agronomy Journal**, v. 103, n. 2, p. 304–315, 2011.

MARIN, F. R. Eficiência de produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos. p. 262, 2014.

MARTORANO, L. G. et al. **Evaluation of the CROPGRO/DSSAT model performance for simulating plant growth and grain yield of soybeans, subjected to no-tillage and conventional systems in the subtropical southern Brazil**. Embrapa Trigo-Artigo em anais de congresso (ALICE). **Anais...Italian Journal of Agronomy= Rivista di Agronomia**, Udine, v. 3, n. 3, p. 795-796, Jul./Sept. 2008. Supl. Edição dos Anais do 10th Congress of the European Society for Agronomy, Bologna, sept. 2008., 2008

MERLOS, F. A. et al. Potential for crop production increase in Argentina through closure of existing yield gaps. **Field Crops Research**, v. 184, p. 145–154, 2015.

NORMAN, A. . Background. In: NORMAN, A. G. (Ed.). . **Soybean physiology, agronomy, and utilization**. New York: New York Academic Press, 1978.

OLIVEIRA, P. DE; NASCENTE, A. S.; KLUTHCOUSKI, J. Soybean growth and yield under cover crops. **Revista Ceres**, v. 60, n. 2, p. 249–256, 2013.

PEREIRA, C. R. **Análise do crescimento e desenvolvimento da cultura de soja sob diferentes condições ambientais**. [s.l.] Universidade Federal de Viçosa, 2002.

PIPOLO, A. E. et al. **BRS 399RR: soja precoce e resistente a nematóides**. Embrapa Soja-**Folderes/Folhetos/Cartilhas (INFOTECA-E)** Londrina: Embrapa Soja, 2015., , 2015. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1030662/1/folderBRS399RR1.pdf>

RUÍZ-NOGUEIRA, B.; BOOTE, K. J.; SAU, F. Calibration and use of CROPGRO-soybean

model for improving soybean management under rainfed conditions. **Agricultural Systems**, v. 68, n. 2, p. 151–173, 2001.

SAU, F.; BOOTE, K. J.; RUÍZ-NOGUEIRA, B. Evaluation and improvement of CROPGRO-soybean model for a cool environment in Galicia, northwest Spain. **Field Crops Research**, v. 61, n. 3, p. 273–291, 1999.

SETIYONO, T. D. et al. Leaf area index simulation in soybean grown under near-optimal conditions. **Field Crops Research**, v. 108, n. 1, p. 82–92, 2008.

THORNTON, C. W.; MATHER, J. R. **The Water Balance**. [s.l.] Drexel Institute of Technology, Laboratory of Technology, 1955.

USDA, U. S. D. OF A. **World agricultural supply and demand estimates**. Washington, DC: The Department, 2017.

WALLACH, D. et al. Parameter estimation for crop models. **Agronomy journal**, v. 93, n. 4, p. 757–766, 2001.

WANG, F. et al. Site-specific evaluation of the CROPGRO-soybean model on Missouri claypan soils. **Agricultural Systems**, v. 76, n. 3, p. 985–1005, 2003.

WHIGHAM, D. K.; MINOR, H. C. Agronomic characteristics and environmental stress. **Soybean physiology, agronomy, and utilization**. Academic Press, New York, p. 77–112, 1978.

WILKERSON, G. G. et al. Modeling soybean growth for crop management. **Transactions of the ASAE**, v. 26, n. 1, p. 63–73, 1983.

ZANON, A. J.; STRECK, N. A.; GRASSINI, P. Climate and management factors influence soybean yield potential in a subtropical environment. **Agronomy Journal**, v. 108, n. 4, p. 1447–1454, 2016.

4. CENÁRIOS FUTUROS DE PRODUTIVIDADE DA SOJA BRASILEIRA SIMULADOS A PARTIR DE PROJEÇÕES CLIMÁTICAS

Resumo

O Brasil é um dos maiores países produtores de soja (*Glycine max* L.), que é a principal fonte de proteína do planeta. Dada sua importância econômica e social, é importante considerar as projeções futuras da produção dessa oleaginosa dentro do debate internacional de mudanças climáticas. Assim, este trabalho buscou avaliar o impacto das mudanças climáticas na produtividade da cultura da soja no Brasil, considerando-se uma área representativa de 80% da produção nacional. Para tal, utilizou-se o modelo DSSAT/CROPGRO-SOYBEAN, que foi calibrado para as condições edafoclimáticas das regiões brasileiras produtoras de soja. Os cenários de mudanças climáticas do IPCC selecionados nesse estudo foram RCP4.5 (2020-2050) e RCP8.5 (2020-2050). Em alguns cenários observou-se diminuição na produtividade de soja para algumas regiões produtoras, com consequente aumento do risco climático. De modo geral, para os RCP 4.5 e RCP 8.5, a produção brasileira pode apresentar ganhos médios em produtividade entre 7 e 9%, com aumento do risco climático em algumas regiões. O efeito compensador do CO₂ atmosférico, tanto elevando a fotossíntese bruta como a produtividade da água da cultura, considerado por este tipo de modelo, foi identificado como uma das causas para a elevação da produtividade.

Palavras-chave: Segurança alimentar; RCP 4.5; RCP 8.5; GCM

ABSTRACT

Brazil is one of the largest soybean producing countries (*Glycine max* L.), and soybeans are the main source of protein on the planet. This given its economic and social importance, it is important to consider future projections of oilseed production in the international debate on climate change. Thus, this work aimed to evaluate the impact of climate change on soybean crop productivity in Brazil, considering a representative area of 80% of the national production. For this, the DSSAT/CROPGRO-SOYBEAN model was calibrated for the soil and climatic conditions of the Brazilian soy producing regions. The IPCC climate change scenarios selected in this study were RCP4.5 (2020-2050) and RCP8.5 (2020-2050). In some scenarios, a decrease in soybean yield was observed for some producing regions, with a consequent increase in climatic risk. In general, for RCP 4.5 and RCP 8.5, Brazilian production may present average productivity gains between 7 and 9%, with increased climatic risk in some regions. The compensatory effect of atmospheric CO₂, both raising gross photosynthesis and crop water productivity, considered by this type of model, was identified as one of the causes for productivity increase.

Keywords: Food safety; RCP 4.5; RCP 8.5; GCM

4.1. Introdução

A estratégia da *Food and Agriculture Organization* (FAO) para a garantia da segurança alimentar da humanidade foi delineada na importante conferência *World Food Summit* de 1996. Nessa conferência definiu-se segurança alimentar como: acesso físico e econômico de todas as pessoas a alimentos seguros, nutritivos e em quantidade suficiente às necessidades e preferências alimentares para uma vida ativa e saudável (SHAW, 2007). Assim,

para a garantia da segurança alimentar da população mundial os governos e instituições privadas demandam constantes estudos e estimativas de produção agrícola em decorrência de cenários de mudanças climáticas (IPCC, 2014).

O estudo dos impactos das mudanças climáticas na produção de culturas agrícolas pode ser importante fonte de estudos a despeito das possíveis consequências na economia e na sociedade (CONWAY, 2012). Essa perspectiva é ainda mais relevante ao se considerar a projeção de incremento populacional, que deverá ser de aproximadamente 2,4 bilhões de pessoas para o ano de 2050 (WHEELER; VON BRAUN, 2013). Tal incremento populacional estará concentrado em países em desenvolvimento, como o sul-asiático, e na África subsaariana,

A intensa discussão em torno das mudanças climáticas globais e seu impacto na segurança alimentar, nas últimas décadas, continuam demandando projeções acerca do clima futuro e seu impacto na agricultura. Essas projeções, segundo Marin (2014) contêm uma série de incertezas oriundas dos diferentes componentes do sistema de análise (e.g, clima, culturas, práticas de manejo). Nesse sentido, ainda segundo o referido autor, adota-se um conjunto de cenários climáticos possíveis, ao invés de apenas uma simulação gerada por um único modelo climático. Tal abordagem é utilizada pelo *Agricultural Model Intercomparison and Improvement Project* (AgMIP) que adota cenários climáticos futuros através do agrupamentos (do inglês, *ensembles*) de modelos climáticos futuros definidos pelo *Coupled Model Intercomparison Project* (CMIP5) (CMIP5, 2013; ROSENZWEIG et al., 2013). Esses cenários, ainda considerando a abordagem do AgMIP, são utilizados conjuntamente com os modelos agrícolas baseado em processos (MBP); que são baseados em processos físicos e fisiológicos (do inglês, *process based crop model*). Essas ferramentas são consagradas na literatura científica para testes de hipóteses acadêmicas e avaliação do impacto de mudanças climáticas na agricultura (MARIN, 2014; ROSENZWEIG et al., 2013),

No contexto de produção de alimentos e segurança alimentar, o Brasil destaca-se como principal exportador de soja do mundo (CONAB, 2017). A soja é a principal geradora de divisas brasileiras e a principal fonte de proteína alimentar do planeta (CONAB, 2017; MATTOS et al., 2015; SILVA, 2014). Segundo dados da *United States Department of Agriculture* (2017b) o farelo de soja representou, nas últimas cinco safras, o equivalente a 68,81% de toda a proteína de origem vegetal produzida mundialmente. Ainda segundo dados do USDA, essa produção proteica procede de mais de 120 milhões de hectares agrícolas, dos quais mais de 33 milhões de hectares estão em território brasileiro.

A discussão sobre o impacto das mudanças climáticas vem sendo alvo de estudos para a cultura da soja. Streck e Alberto (2006) verificaram a influência da mudança climática na produção de soja e outras culturas utilizando ferramentas de simulação de cenários, projetando um período de 100 anos futuros para a região de Santa Maria –RS. Battisti (2016) analisou a influência dos cenários de mudanças climáticas na cultura da soja na região do sudeste brasileiro. Mourtzinis et al (2015) estimaram perdas de 2,4% para cada variação crescente 1°C na temperatura do ar, na produção dos EUA. Tais trabalhos agregaram a discussão científica aqui retratada e identificaram alguns riscos inerentes a produção de soja quando associados às mudanças climáticas.

Com base no exposto, estudos de projeções de produtividades agrícolas que considerem os cenários de mudanças climáticas são de grande relevância no debate internacional sobre segurança alimentar. O presente capítulo tem como objetivo simular a produção de soja com base em cenários de mudanças climáticas para o período 2040-2069 (representando 2050).

4.2. Material e Métodos

Nessa seção serão descritos os procedimentos para a geração dos cenários futuros, em áreas que abrangessem, ao menos, 80% da produção de soja no Brasil. Para tal considerou-se os quatro grupos de maturação representativos para as áreas produtoras: os grupos 6.0, 7.0, 8.0 e 9.0. As calibrações adotadas para as simulações futuras foram apresentadas no capítulo anterior desta dissertação.

4.2.1. Definição e determinação das zonas edafoclimáticas homogêneas

O conceito de zonas edafoclimáticas homogêneas (ZH), aqui adotado, parte da metodologia descrita por van Wart et al (2013) que se baseia em um esquema matemático de matrizes. Nessas matrizes, cada variável usada para delinear as ZH's é dividida em intervalos de classe; de tal maneira que cada zona é determinada por um conjunto de classes que se cruzam. Especificamente para essas matrizes, os autores consideraram três variáveis: (a) soma da temperatura diária média acumulada acima da temperatura base; (b) o índice de aridez anual, que é a razão entre a precipitação total anual média e a evapotranspiração potencial total anual e (c) sazonalidade da temperatura, quantificada como o desvio padrão das temperaturas médias

mensais. Desse modo, os autores criaram um mapa composto de diversas zonas edafoclimáticas homogêneas, cuja metodologia é bastante aceita na comunidade científica internacional (EWERT et al., 2015; MARIN, 2014; PINTO, 2015; VAN BUSSEL et al., 2015; VAN OORT et al., 2017; VAN WART et al., 2013).

No presente estudo, buscou-se delimitar as ZH's que abrangessem ao menos 80% de toda a produção nacional. Para a delimitação dessa área elencou-se os municípios produtores de soja com os dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2015), contabilizando uma média de produção do período de 2010 a 2015. A partir desses dados foram estabelecidas as zonas edafoclimáticas homogêneas.

4.2.2. Cenários de mudanças climáticas

O presente estudo adota a metodologia descrita pelo projeto *Agricultural Model Intercomparison and Improvement Project* (AgMIP). Essa metodologia é descrita por Hudson e Ruane (2013) em um algoritmo em linguagem “R” (R DEVELOPMENT CORE TEAM, 2011) que permite criar cenários futuros baseados em projeções de concentrações futuras de CO₂ atmosférico, os RCP's (do inglês, *Representative Concentration Pathways*). O projeto AgMIP, por sua vez, utilizou dados do *Coupled Model Intercomparison Project Phase 5* (CMIP5, 2013) que envolve cenários de grupos de modelagem climática, totalizando 20 modelos de circulação global, os GCMs (do inglês, *General Circulation Model*). A base de dados desenvolvida pelo AgMIP foi disponibilizada para uso neste trabalho e os cenários foram criados para dez zonas edafoclimáticas homogêneas, representando mais de 80% do território nacional produtor de soja. Utilizou-se os 20 GCM's disponíveis e selecionou-se três: (i) o de menor incremento de temperatura média; (ii) o de incremento mediano e (iii) o GCM de maior incremento de temperatura média para cada ZH. Foram selecionadas duas projeções de concentração de CO₂ (RCP 4.5 e RCP 8.5), permitindo assim a comparação com a série da linha de base (série climática atual).

O RCP 4.5 é baseado no modelo MiniCAM, do Instituto de Investigação de Mudança Global e o Laboratório Nacional do Noroeste do Pacífico. Este cenário assume a possibilidade de estabilização nas concentrações de gases pelo emprego de tecnologias e estratégias para reduzir as emissões de gases de efeito estufa até 2100, com forçamento radiativo de aproximadamente 4,5 W m⁻² e concentração de CO₂ em torno de 650 ppm (THOMSON et al., 2011). Como o presente trabalho se propõe a estudar os cenários futuros até o ano de 2050, a

concentração de CO₂ aqui utilizada será de 526 ppm para o RCP 4.5 (SMITH; WIGLEY, 2006; WISE et al., 2009).

O RCP 8.5 é baseado no modelo MESSAGE, desenvolvido pelo Instituto Internacional de Análise de Sistemas Aplicados, na Áustria e é caracterizado pelo aumento das emissões de gases de efeito estufa que levam a altas concentrações desses gases ao longo do tempo, onde o forçamento radiativo é maior do que $8,5 \text{ W m}^{-2}$ e a concentração de CO₂ maior do que 1370 ppm até o ano de 2100 (RIAHI et al., 2011). Considerando a projeção para o ano de 2050, adotar-se-á a concentração de 628 ppm (RIAHI; NAKICENOVIC, 2007).

Com base no exposto, definiram-se seis cenários de mudanças climáticas: (a) Cenário 1, RCP 4.5 e GCM com o menor incremento de temperatura do ar; (b) Cenário 2, RCP 4.5 e GCM com o incremento mediano na temperatura do ar; (c) Cenário 3, RCP 4.5 e GCM com o maior incremento de temperatura do ar; (d) Cenário 4, RCP 8.5 e GCM com o menor incremento de temperatura do ar; (e) Cenário 5, RCP 8.5 e GCM com incremento mediano na temperatura do ar e (f) Cenário 6, RCP 8.5 e GCM com o maior incremento de temperatura do ar.

4.2.3 Caracterização dos solos predominantes

Os perfis de solos necessários para simulações no DSSAT/CROPGRO-SOYBEAN para as diferentes ZH's foi baseada com base na análise regional a partir de mapas de solos provenientes do Projeto Radam Brasil (RADAMBRASIL, 1973), utilizando o software estatístico R selecionou-se o solo predominante em cada ZH. Após a seleção buscou-se perfis de solo compatíveis na base de dados WISE (*World Inventory of Soil Emission Potentials*), projeto desenvolvido pelo ISRIC do *Dutch National Research Programme on Global Air Pollution and Climate Change*.

4.3. Resultados e Discussão

As 10 ZH selecionadas representaram mais de 80% da produção de soja no Brasil (Anexo 1). Para os cenários 1, 2 e 3 (Tabela 1) observou-se um incremento médio de 2,08°C, 1,68°C e 1,78% nas temperaturas máxima e mínima e no saldo de radiação, respectivamente. Em outra direção a precipitação pluvial apresentou uma variação negativa média de 6,66%. Sendo a ZH 6801 a mais afetada com a diminuição das chuvas, podendo chegar a uma

diminuição média de 31,28% ao longo da safra (considerando o período de outubro a março) e o maior incremento no saldo de radiação superior a 10%.

Nos cenários 4, 5 e 6 observou-se um incremento médio de 2,8°C, 2,36°C e 2,74 MJ m⁻² nas temperaturas máxima e mínima e no saldo de radiação, respectivamente. A precipitação pluvial apresentou a variação negativa média de 6,64 %. A ZH 6801, da mesma forma que nos cenários de 1 a 3, seria a mais afetada em termos de volume de chuvas no período de safra; com diminuição média de 26,58% ao longo da safra e o maior incremento no saldo de radiação superior a 10%.

Tabela 1. Variação de temperatura do ar máxima (TMAX °C), mínima (TMIN °C), saldo de radiação (%) e precipitação pluvial (%); obtidas pelos modelos de circulação global (GCM) para as zonas edafoclimáticas homogêneas (ZH), para os cenários 1, 2 e 3 (RCP 4.5).

ZH	TMAX (°C)	TMIN (°C)	SRAD (%)	PREC (%)	GCM
<u>Cenário 1</u>					
8601	0,98	1,05	0,20	1,33	inmcm4
8701	1,11	1,10	1,38	4,90	inmcm4
8801	3,23	0,87	5,24	-4,45	inmcm4
8401	1,06	1,25	-0,43	7,38	CGCM3
7501	0,99	0,95	0,36	-1,66	inmcm4
9701	1,01	1,06	4,19	4,77	inmcm4
9301	0,71	0,78	0,99	0,22	inmcm4
9401	0,78	0,74	1,39	-2,45	inmcm4
6801	1,30	1,48	9,48	-19,14	MIROC5
7701	1,10	0,41	1,93	1,52	NorEMS1M
<u>Cenário 2</u>					
8601	1,68	1,47	0,20	2,20	BNUESM
8701	2,41	1,95	2,93	-14,73	BNUESM
8801	1,92	1,40	5,43	-1,33	BNUESM
8401	1,40	1,42	-0,39	15,48	BNUESM
7501	1,73	1,70	0,36	-6,29	BNUESM
9701	1,60	1,55	4,25	6,37	BNUESM
9301	1,87	1,36	0,99	-12,35	BNUESM
9401	1,68	1,35	1,45	-3,58	BNUESM
6801	2,12	1,96	9,76	-26,37	BNUESM
7701	1,52	1,27	1,69	-7,84	BNUESM
<u>Cenário 3</u>					
8601	3,84	2,28	0,15	-18,42	CanESM2
8701	2,80	2,22	2,93	4,09	MIROCESM
8801	4,05	2,55	5,43	-15,90	CanESM2
8401	3,92	2,76	-0,57	-4,48	CanESM2
7501	2,56	1,91	0,41	-15,30	LanESM2
9701	3,83	2,42	4,31	-17,52	CanESM2
9301	2,32	3,69	0,94	-12,08	CSIROmk3603
9401	2,26	2,55	-23,16	-17,00	CSIROmk3603
6801	2,88	2,69	10,03	-31,28	IPLSCM5AMR
7701	3,66	2,28	1,69	-15,87	CanESM2

Tabela 2. Variação de temperatura do ar máxima (TMAX °C), mínima (TMIN °C), saldo de radiação (%) e precipitação pluvial (%); obtidas pelos modelos de circulação global (GCM) para as zonas edafoclimáticas homogêneas (ZH), para os cenários 4, 5 e 6 (RCP 8.5).

ZH	TMAX (°C)	TMIN (°C)	SRAD (%)	PREC (%)	GCM
<u>Cenário 4</u>					
8601	1,31	1,57	0,84	1,27	inmcm4
8701	1,52	1,80	2,93	4,96	inmcm4
8801	1,65	1,53	5,33	1,03	inmcm4
8401	1,34	1,88	-0,40	8,86	MIROC5
7501	1,28	1,73	0,83	3,39	inmcm4
9701	1,47	1,60	5,09	2,93	inmcm4
9301	1,00	1,28	1,05	2,38	inmcm4
9401	1,13	1,15	1,46	-0,17	inmcm4
6801	1,53	1,86	9,70	-18,84	inmcm4
7701	1,17	1,41	1,72	-2,31	inmcm4
<u>Cenário 5</u>					
8601	2,45	2,21	0,24	1,05	BNUESM
8701	3,12	2,76	2,95	-13,02	BNUESM
8801	2,49	2,16	5,48	-1,29	BNUESM
8401	2,32	2,16	-0,46	11,61	BNUESM
7501	2,61	2,49	0,46	-13,00	BNUESM
9701	2,26	2,30	4,35	8,31	BNUESM
9301	2,25	2,11	0,95	-10,72	BNUESM
9401	1,90	2,11	1,50	1,98	BNUESM
6801	2,44	2,65	9,85	-19,33	BNUESM
7701	2,25	1,96	1,78	-11,58	BNUESM
<u>Cenário 6</u>					
8601	4,78	2,98	0,11	-16,75	CanESM2
8701	4,39	3,05	3,00	-16,67	CanESM2
8801	5,93	2,77	5,33	-7,22	MIROCESM
8401	5,07	3,60	-0,69	-5,01	CanESM2
7501	4,58	3,11	0,36	-22,25	MIROCESM
9701	5,33	3,49	4,28	-22,02	CanESM2
9301	3,15	2,93	0,92	-9,27	ACCESS10
9401	3,39	3,04	1,50	-20,21	ACCESS10
6801	4,58	3,77	10,11	-26,58	CanESM2
7701	5,33	3,30	1,70	-10,81	CanESM2

Observa-se que apenas considerando as alterações climáticas a produtividade de soja seria reduzida em média em 19% (Tabela 3) e 22% (Tabela 4) considerando todas as possibilidades de simulação para o RCP 4.5 e RCP 8.5, respectivamente. Tendência semelhante de queda de produtividade foi identificada por Assad et al (2008). Essas possibilidades simuladas não foram definidas como possíveis cenários neste estudo, uma vez que o aumento da concentração de CO₂ é tido como uma das projeções futuras com menor incerteza dentre as variáveis de interesse agrônomo.

Assim, todos os cenários estabelecidos para este trabalho consideram o incremento de CO₂, tornando as perspectivas futuras mais otimistas dados os efeitos positivos do CO₂ sobre a fisiologia da cultura. Incluindo o CO₂, as projeções de mudanças climáticas poderiam levar a um incremento médio de 9% na produção de soja no Brasil, considerando todas as possibilidades simuladas para o cenário RCP 4.5 (Tabela 3).

Este incremento na produtividade, por sua vez, além do efeito direto sobre a fotossíntese da cultura, é também acompanhada pelo DMP_EP que é o aumento na produtividade da água da cultura (kg m⁻³), como mostra a equação 1.

$$\text{DMP_EP} = \text{BIOMAS} / \text{CEPR}(0) \quad (1)$$

em que BIOMAS é o acúmulo de biomassa (kg ha⁻¹) (Equação 2) e CEPR é o acúmulo de transpiração (mm) do plantio a colheita.

$$\text{BIOMAS} = (\text{LFWT} + \text{STMWT} + \text{PWAD}) * \text{PLTPOP} \quad (2)$$

em que LFWT é a massa seca de folhas (g m⁻²), STMWT é a massa seca de caules (g m⁻²), PWAD é a massa seca de vagens e PLTPOP é a população de plantas emergidas (plantas m⁻²). O acúmulo de massa seca fracionada de cada uma das estruturas relacionadas pode ser calculada pelas equações 3, 4 e 5.

$$\text{STMW} = \text{STMWT} + \text{GROSTM} - 6.25 * \text{NSINK} * \text{STMWT} / (\text{LFWT} + \text{STMWT}) \quad (3)$$

$$\text{PANWT} = \text{PWAD} + \text{GROP} + 3.12 * \text{NSINK} * \text{STMWT} / (\text{LFWT} + \text{STMWT}) \quad (4)$$

$$\text{LFWT} = \text{LFWT} + \text{GROLF} - 6.25 * \text{NSINK} * \text{LFWT} / (\text{LFWT} + \text{STMWT}) \quad (5)$$

em que NSINK é a demanda de nitrogênio requerido para o enchimento do grão (g planta dia⁻¹), GROSTM é a taxa de crescimento dos caules (g planta dia⁻¹), GROP é a taxa de crescimento das vagens (g planta dia⁻¹) e GROLF é a taxa de crescimento das folhas (g planta dia⁻¹).

A taxa de crescimento diário de cada estrutura da planta é definida por um algoritmo que, evidentemente, considera a assimilação de carbono. A lógica pela qual o DSSAT/CROPGRO-SOYBEAN calcula o incremento produtivo pode ser sintetizado pela equação 6, a qual apresenta a taxa de crescimento diário das vagens.

$$\text{GROP} = \text{CARBO} + (\text{STMWT} - \text{SWMIN}) \quad (6)$$

em que CARBO é o carboidrato disponível e SWMIN é o valor mínimo de massa seca que o caule pode atingir durante o preenchimento de grãos (g planta^{-1}). A variável CARBO é contabilizada pela função de máximo (Equação 7).

$$\text{CARBO} = \text{AMAX1} (\text{PCARB} * \text{CO2FP} * \text{TFP} * \text{WFP} * \text{NFP} * \text{RSFP} * \text{SLPF}) \quad (7)$$

em que PCARB é a produção potencial de matéria seca sob água ideal, nitrogênio e temperatura; CO2FP é o fator CO_2 relacionado às funções de fotossíntese; TFP é o fator de temperatura relacionado às funções de fotossíntese; WFP é o fator água relacionado às funções de fotossíntese; NFP é o fator nitrogênio relacionado às funções de fotossíntese; RSFP é fator de reserva para a fotossíntese e SLPF é a taxa relativa de redução do crescimento em solos de baixa fertilidade, fator não relacionado ao conteúdo de nitrogênio no solo.

De modo análogo ao DMPEM, observa-se na variável de saída YPEM (do inglês, yield-evapotranspiration productivity, $\text{kg ha}^{-1} \text{mm}^{-1}$) que expressa a produtividade da água da cultura, razão entre a produtividade e a evapotranspiração; ambas representam um indicador de eficiência do uso da água no acúmulo de matéria seca.

Com base no exposto, o incremento de produtividade é coerente com os processos fisiológicos de uma cultura com via C3 de assimilação de carbono, uma vez que o aumento da concentração de CO_2 resulta na redução da condutância estomática através da diminuição do grau de abertura estomática (BOOTE; PICKERING; ALLEN, 1997; FIELD; JACKSON; MOONEY, 1995; TUBIELLO; EWERT, 2002) apresentando consequências importantes como a maior eficiência na acumulação de biomassa e maiores rendimentos produtivos, como observado nas variáveis HWAM_B (Tabelas 3 e 4).

Tabela 3. Variações de produtividade sem considerar o incremento de CO₂ atmosférico na simulação (HWAM_A) e com o incremento de CO₂ atmosférico na simulação (HWAM_B); acúmulo de matéria seca por unidade de evapotranspiração sem considerar o incremento de CO₂ atmosférico (DMPEM_A) e com o incremento de CO₂; acúmulo de massa seca de grãos por unidade de evapotranspiração sem considerar o incremento de CO₂ atmosférico YPEM_A e com o incremento YPEM_B, obtidos pelos modelos de circulação global (GCM) para as zonas edafoclimáticas homogêneas (ZH), para os cenários 1, 2 e 3 (RCP 4.5).

	ZH	HWAM_A (%)	DMPEM_A (%)	YPEM_A (%)	HWAM_B (%)	DMPEM_B (%)	YPEM_B (%)
CENÁRIO 1	8601	-11,42	-11,01	25,80	7,81	11,43	55,56
	8701	-3,12	-8,07	31,40	22,80	17,10	68,23
	8801	-4,59	-9,05	29,00	14,53	11,08	66,00
	8401	-15,68	-13,64	8,83	21,22	25,35	71,74
	7501	-11,32	-9,88	28,63	14,77	14,72	67,72
	9701	-0,92	-9,04	32,38	21,05	13,12	59,76
	9301	-16,80	-15,23	14,46	19,87	4,80	39,21
	9401	-8,92	-8,91	29,63	20,78	11,09	56,44
	6801	-13,27	-9,57	53,19	8,70	25,03	113,09
	7701	-22,92	-24,67	11,81	0,33	17,48	73,49
CENÁRIO 2	8601	-19,18	12,77	55,59	5,60	9,56	51,31
	8701	-7,017	16,28	63,92	12,46	12,64	58,81
	8801	-12,03	-12,10	22,16	9,33	8,01	47,84
	8401	-21,55	43,48	97,18	24,34	27,67	74,98
	7501	-17,84	-8,24	30,11	13,49	17,56	70,69
	9701	-7,71	15,80	62,83	16,51	10,68	53,98
	9301	-23,76	-7,55	21,47	10,55	1,87	32,48
	9401	-15,46	0,10	40,07	5,37	9,12	52,01
	6801	-27,30	5,67	68,97	-1,58	2,83	65,08
	7701	-37,65	18,05	73,68	-5,89	10,95	64,01
CENÁRIO 3	8601	-26,95	-21,52	1,31	1,65	27,52	58,71
	8701	-10,92	-34,48	-39,77	9,36	48,73	108,54
	8801	-19,47	-19,28	9,74	2,16	1,51	34,83
	8401	-27,42	-23,74	-2,67	15,57	73,92	122,48
	7501	-24,37	-15,90	13,45	3,09	9,12	50,77
	9701	-16,34	-15,63	9,79	7,84	37,68	73,44
	9301	-30,73	-23,14	-3,41	1,70	8,53	33,87
	9401	-22,02	-35,81	-59,81	3,93	17,08	56,60
	6801	-41,34	-32,45	11,41	-8,68	27,96	189,52
	7701	-52,39	-48,70	-25,55	-11,21	57,21	59,78

Tabela 4. Variações de produtividade sem considerar o incremento de CO₂ atmosférico na simulação (HWAM_A) e com o incremento de CO₂ atmosférico na simulação (HWAM_B); acúmulo de matéria seca por unidade de evapotranspiração sem considerar o incremento de CO₂ atmosférico (DMPEN_A) e com o incremento de CO₂; acúmulo de massa seca de grãos por unidade de evapotranspiração sem considerar o incremento de CO₂ atmosférico YPEM_A e com o incremento YPEM_B, obtidos pelos modelos de circulação global (GCM) para as zonas edafoclimáticas homogêneas (ZH), para os cenários 4, 5 e 6 (RCP 8.5).

	ZH	HWAM_A (%)	DMPEN_A (%)	YPEM_A (%)	HWAM_B (%)	DMPEN_B (%)	YPEM_B (%)
CENÁRIO 4	8601	-13.16	-12.66	21.87	11.27	16.27	60.34
	8701	-5.42	-8.54	29.10	28.25	24.09	77.45
	8801	-6.93	-10.76	25.52	15.95	15.27	59.14
	8401	-14.98	-13.09	18.78	33.54	38.25	88.72
	7501	-10.90	-9.22	29.80	22.40	22.78	80.39
	9701	1.01	-9.67	32.24	28.29	19.33	69.04
	9301	-18.22	-16.67	12.42	3.52	9.08	44.45
	9401	-10.58	-10.20	27.33	11.99	15.64	61.98
	6801	-22.22	-15.62	39.00	18.92	27.96	113.33
	7701	-21.34	-23.42	14.21	35.38	33.14	96.88
CENÁRIO 5	8601	-18.42	-16.51	13.58	5.48	12.07	50.40
	8701	-14.90	-13.53	19.69	17.31	19.70	66.45
	8801	-13.45	-15.23	15.43	8.89	10.49	47.67
	8401	-17.04	-15.05	13.08	30.71	35.22	80.01
	7501	-21.52	-14.08	17.96	12.96	19.17	71.35
	9701	-10.24	-15.50	17.58	16.17	13.01	53.59
	9301	-29.24	-22.48	-2.24	-8.76	2.90	27.60
	9401	-16.90	-14.12	18.59	4.96	11.71	52.01
	6801	-27.09	-21.37	30.71	12.18	21.32	101.48
	7701	-36.66	-36.13	-4.64	15.65	16.96	72.35
CENÁRIO 6	8601	-34.71	-26.91	-11.55	-13.56	0.46	19.55
	8701	-24.10	-19.66	5.03	5.85	12.37	47.68
	8801	-27.80	-26.77	-8.02	-6.59	-0.93	20.78
	8401	-37.87	-33.65	-21.26	2.87	10.37	30.50
	7501	-35.55	-21.26	-0.55	-4.57	11.74	48.17
	9701	-29.11	-24.59	-10.16	-6.21	3.90	20.01
	9301	-33.39	-26.13	-8.88	-12.96	-0.88	20.67
	9401	-24.14	-19.33	7.82	-3.27	6.36	39.48
	6801	-49.53	-38.94	-8.23	-18.66	-1.77	48.15
	7701	-54.61	-50.57	-31.11	-7.81	-0.62	37.30

Na mesma direção, Bernacchi et al (2007) conduzindo a cultura da soja em experimento com atmosfera enriquecida de CO₂ (FACE , do inglês, *free air CO₂ enrichment*) observaram uma redução de até 16% na evapotranspiração da cultura da soja, considerando [CO₂] de 550ppm. Ainsworth et al (2002) fizeram uma meta-análise de diversos trabalhos envolvendo a resposta da cultura da soja a elevação da concentração de CO₂ atmosférico e relatam que, em média: (i) houve aumento geral de 37% na biomassa; (ii) incremento na taxa de crescimento relativo em 12%; (iii) aumento de 19% no número de vagens; (iv) aumento do rendimento de semente em torno de 24%; (v) diminuição de 11% na atividade total da Rubisco; (vi) diminuição de 40% na condutância estomática e (vii) aumento de 39% na taxa fotossintética líquida.

As variações de produtividade média futura de soja acenam incrementos de produtividade na região do Oeste baiano de 5,85 a 22,8 % em todos os cenários simulados. Os demais estados que compõem a região do Matopiba (Maranhão, Tocantins, Piauí e Bahia) apresentam maior variabilidade dentre os cenários, acenando para incrementos de mais de 20% no cenário mais otimista e queda na produtividade de até 16% no cenário mais pessimista (Figura 1 e 2). Nos estados que compõem o Centro-Oeste observa-se grande variabilidade entre os cenários e as regiões de cada estado, com projeções de queda de produtividade em torno de 8% até ganhos superiores a 35%, para os cenários 3 e 4, respectivamente.

As regiões Sul e Sudeste do Brasil apresentaram queda de produtividade nos cenários 2, 3 e 5; com perdas de produtividade de até 18,7% (Figura 2 e 3). Tais perdas de produtividade parecem estar relacionadas com a diminuição da precipitação pluvial (e consequente aumento da radiação solar) ao longo das safras simuladas (Tabela 3 e 4), corroborando com as projeções feitas por Battisti (2016) para a mesma região.

Figura 1. Variação (%) na produtividade futura de soja no Brasil, cenários 1, 2 e 3 (RCP 4.5).

Figura 2. Variação (%) na produtividade futura de soja no Brasil, cenários 4, 5 e 6 (RCP 8.5).

4.3.1. Risco de produção agrícola para os cenários com base nas simulações do modelo DSSAT/CROPGRO-SOYBEAN

Dentre as 10 zonas consideradas a ZH 8701 foi a única zona a apresentar diminuição do risco climático em todos os cenários simulados, com possibilidade de ganhos de produtividade quando comparado com o cenário atual (BL) (Figura 3). No cenário 6 para esta ZH, apesar da diminuição de chuva (-16,67%) (Tabela 2), notou-se que o aumento da eficiência do uso da água (12,37%) (Tabela 4) pela interferência da maior concentração do CO₂ atmosférico, parece ter compensado os efeitos na produtividade de soja, resultando em aumento da produtividade média em 35%.

O cenário 6 apresentou um maior risco climático em quase todas as ZH produtoras de soja, exceto em 8401 e 8701. As zonas 6801 e 9301 (Figura 4) seriam as mais afetadas nos cenários 2, 5 e 6, com o aumento do risco climático. Nessas duas ZH, observou-se, nos referidos cenários, uma queda na eficiência do uso da água com menor volume de chuvas ao longo da safra simulada. Para essas condições sugere-se estudos em relação a alteração na data de plantio ou uso da irrigação como efeito mitigador às mudanças climáticas.

Figura 3. Probabilidade acumulada de produtividade de soja (kg. ha⁻¹) para as zonas homogêneas 8601, 8801, 8401, 7501, 7701 para os cenários climáticos 1 a 6.

Figura 4. Probabilidade acumulada de produtividade de soja (kg ha^{-1}) para as zonas homogêneas 6801, 9501, 9301, 8701, 9701 para os cenários simulados 1 a 6.

4.4. Conclusão

Os cenários de clima futuro, que na maioria dos casos apontaram aumento de temperatura e leve queda na precipitação média para as principais regiões produtoras de soja do Brasil, quando inseridos no modelo DSSAT/CROPGRO-SOYBEAN calibrado para os grupos de maturação 6 a 9, resultaram em aumento de produtividade média de soja entre 7 e 9%. Apesar dos cenários apresentarem redução na precipitação pluvial, observou-se um efeito compensador do incremento de CO₂. Para todas as zonas homogêneas analisadas, houve aumento do risco climático da cultura, atribuída principalmente a mudança no padrão de chuvas e aumento do estresse por deficiência hídrica. Sugerem-se estudos adicionais para analisar efeitos de redução da vulnerabilidade da cultura como o desenvolvimento de técnicas de manejo e de

REFERÊNCIAS

AINSWORTH, E. A. et al. A meta-analysis of elevated [CO₂] effects on soybean (glycine max) physiology, growth and yield. **Global Change Biology**, v. 8, n. 8, p. 695–709, 2002.

ASSAD, E. D. et al. **Aquecimento global e a nova geografia da produção agrícola no Brasil**. Brazil: Brazil Embrapa Unicamp, 2008.

BATTISTI, R. **Calibration, uncertainties and use of soybean crop simulation models for evaluating strategies to mitigate the effects of climate change in Southern Brazil**. Piracicaba: Universidade de São Paulo, 2016.

BERNACCHI, C. J. et al. Decreases in stomatal conductance of soybean under open-air elevation of [CO₂] are closely coupled with decreases in ecosystem evapotranspiration. **Plant Physiology**, v. 143, n. 1, p. 134–144, 2007.

BOOTE, K. J.; PICKERING, N. B.; ALLEN, L. H. Plant modeling: advances and gaps in our capability to predict future crop growth and yield in response to global climate change. **Advances in Carbon Dioxide Effects Research**, n. advancesincarbo, p. 179–228, 1997.

CMIP5. **CMIP5 - Overview**. Disponível em: <<http://cmip-pcmdi.llnl.gov/cmip5/>>. Acesso em: 16 set. 2017.

CONAB. **Séries históricas**. Disponível em: <http://www.conab.gov.br/conteudos.php?a=1252&t=&Pagina_objcmsconteudos=3#A_objcmsconteudos>. Acesso em: 25 maio. 2017.

CONWAY, G. **One billion hungry: can we feed the world?** London: Cornell University Press, 2012.

EWERT, F. et al. Crop modelling for integrated assessment of risk to food production from climate change. **Environmental Modelling & Software**, v. 72, p. 287–303, 2015.

FIELD, C. B.; JACKSON, R. B.; MOONEY, H. A. Stomatal responses to increased CO₂: implications from the plant to the global scale. **Plant, Cell & Environment**, v. 18, n. 10, p. 1214–1225, 1995.

HUDSON, N.; RUANE, A. Guide for Running AgMIP Climate Scenario Generation Tools with R. **AgMIP**. Available online: <http://www.agmip.org/wp-content/uploads/2013/10/Guide-for-Running-AgMIPClimate-Scenario-Generation-with>, 2013.

IBGE. **Sistema IBGE de Recuperação Automática - SIDRA**. Disponível em: <<https://sidra.ibge.gov.br/pesquisa/pam/tabelas>>. Acesso em: 14 set. 2017.

IPCC, I. P. ON C. C. **Climate Change 2014—Impacts, Adaptation and Vulnerability: Regional Aspects**. New York: Cambridge University Press, 2014.

MARIN, F. R. Eficiência de produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos. p. 262, 2014.

MATTOS, E. C. et al. Estudo da identidade histológica de subprodutos de soja (*Glycine max* L.). **Rev Inst Adolfo Lutz**, v. 74, p. 104–110, 2015.

MOURTZINIS, S. et al. Climate-induced reduction in US-wide soybean yields underpinned by region-and in-season-specific responses. **Nature plants**, v. 1, n. 2, p. nplants201426, 2015.

PINTO, H. M. S. **Projeções de risco de produção de cana-de-açúcar no Estado de São Paulo baseadas em simulações multimodelos e cenários climáticos futuros**. Piracicaba: Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo, 31 ago. 2015.

RADAMBRASIL, P. **Levantamento de recursos naturais**. [s.l.] Ministério das Minas e Energia, Departamento Nacional da Produção Mineral, Projeto Radambrasil, 1973.

RIAH, K. et al. RCP 8.5—A scenario of comparatively high greenhouse gas emissions. **Climatic Change**, v. 109, n. 1–2, p. 33, 2011.

RIAH, K.; NAKICENOVIC, N. **Greenhouse Gases - Integrated Assessment, Technological Forecasting and Social Change**. Special Issue ed. [s.l.: s.n.]. v. 74

ROSENZWEIG, C. et al. The agricultural model intercomparison and improvement project (AgMIP): protocols and pilot studies. **Agricultural and Forest Meteorology**, v. 170, p. 166–182, 2013.

SHAW, D. J. World Food Summit, 1996. In: **World Food Security**. [s.l.] Springer, 2007. p. 347–360.

SILVA, F. **INTER-RELAÇÕES ENTRE PRODUÇÃO E DEMANDA DA SOJA E DE PROTEÍNA ANIMAL**. [s.l.] Universidade Regional do Noroeste do Estado do Rio Grande do Sul, 2014.

SMITH, S. J.; WIGLEY, T. M. L. Multi-gas forcing stabilization with Minicam. **The Energy Journal**, p. 373–391, 2006.

STRECK, N. A.; ALBERTO, C. M. Estudo numérico do impacto da mudança climática sobre o rendimento de trigo, soja e milho. **Pesquisa Agropecuária Brasileira**, v. 41, n. 9, p. 1351–1359, 2006.

R Development Core Team. R. **A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2011. Available in: <<http://www.r-project.org>>. Access in: 31 Jan. 2017.

THOMSON, A. M. et al. RCP4. 5: a pathway for stabilization of radiative forcing by 2100. **Climatic change**, v. 109, n. 1–2, p. 77, 2011.

TUBIELLO, F. N.; EWERT, F. Simulating the effects of elevated CO₂ on crops: approaches and applications for climate change. **European journal of agronomy**, v. 18, n. 1, p. 57–74, 2002.

USDA, U. S. D. OF A. **World agricultural supply and demand estimates**. Washington, DC: The Department, 2017.

VAN BUSSEL, L. G. J. et al. From field to atlas: Upscaling of location-specific yield gap estimates. **Field Crops Research**, v. 177, p. 98–108, 2015.

VAN OORT, P. A. J. et al. Can yield gap analysis be used to inform R&D prioritisation? **Global Food Security**, v. 12, p. 109–118, 2017.

VAN WART, J. et al. Use of agro-climatic zones to upscale simulated crop yield potential. **Field crops research**, v. 143, p. 44–55, 2013.

WHEELER, T.; VON BRAUN, J. Climate change impacts on global food security. **Science**, v. 341, n. 6145, p. 508–513, 2013.

WISE, M. et al. Implications of limiting CO₂ concentrations for land use and energy. **Science**, v. 324, n. 5931, p. 1183–1186, 2009.

5. CONCLUSÕES GERAIS

- (i) a análise de sensibilidade local do modelo DSSAT/CROPGRO-SOYBEAN foi capaz indicar os parâmetros mais relevantes para o processo de calibração;
- (ii) a calibração utilizada no modelo foi satisfatória para o sistema de produção de soja brasileira;
- (iii) observou-se um efeito compensador do incremento de CO₂, haja vista o aumento de temperatura do ar e diminuição da precipitação pluvial;
- (iv) o estresse hídrico foi o principal fator de perda de produtividade média de soja nos cenários estudados;
- (v) as projeções indicaram um aumento de produtividade médio de 7 a 9%;
- (vi) os cenários apontam maior variabilidade climática para algumas zonas homogêneas.

APÊNDICES

APÊNDICE A - METODOLOGIA NA AVALIAÇÃO DO DESENVOLVIMENTO FENOLÓGICO DA CULTURA DA SOJA

O desenvolvimento das fases fenológicas no DSSAT/CROPGRO-SOYBEAN segue a descrição fenológica proposta por Fehr e Caviness (1977) (BOOTE et al., 1998). Nesse estudo foram determinados os estádios fenológicos vegetativos (VC a V(n)) e os estágios reprodutivos (R1 a R8). A escala fenológica foi fundamental para o processo de calibração das cultivares estudadas.

Tabela 1. Descrição dos estádios fenológicos da cultura da soja.

Estádio Fenológico	Descrição
VE	Emergência, cotilédones acima do solo;
VC	Cotilédones abertos e folhas unifolioladas desenroladas o suficiente para que as bordas das folhas não estejam tocando;
V1	Folhas unifolioladas completamente desenvolvidas;
V2	Folha trifoliolada totalmente desenvolvida no nó acima da folha unifoliolada;
V3	Três nós na haste principal com folhas totalmente desenvolvidas, começando com os nós unifoliolados.
V(n)	n é o número de nós no tronco principal com folhas totalmente desenvolvidas começando com os nós unifoliolados;
R1	início do florescimento, uma flor aberta em qualquer nó da haste principal;
R2	Floração plena, flor aberta em um dos dois nós superiores na haste principal com uma folha totalmente desenvolvida;
R3	início da frutificação, vagem com 5 mm de comprimento em um dos quatro nós superiores na haste principal com uma folha totalmente desenvolvida;
R4	frutificação plena, vagens de 2 cm de comprimento em um dos quatro nós superiores na haste principal com uma folha completamente desenvolvida;
R5	início da formação de sementes, semente de 3 mm de comprimento em uma vagem em um dos quatro nós superiores na haste principal com folha totalmente desenvolvida;
R6	enchimento de grão, contendo uma semente verde que preenche a cavidade da vagem em um dos quatro nós superiores na haste principal com uma folha completamente desenvolvida;
R7	início da maturação, uma vagem normal na haste principal que atingiu a maturidade (cor de vagem madura).
R8	maturação completa, 95% das vagens que atingiram a cor da vagem madura.

Fonte: Fehr e Caviness (1997)

REFERÊNCIAS

BOOTE, K. J. et al. The CROPGRO model for grain legumes. In: TSUJI, G. Y.; HOOGENBOOM, G.; THORNTON, P. K. (Eds.). . **Understanding options for agricultural production**. [s.l.] Springer, 1998. p. 99–128.

FEHR, W. R.; CAVINESS, C. E. Stages of soybean development. **Special Report 80**, p. 2–11, 1977.

APÊNDICE B — DADOS METEOROLÓGICOS DE ENTRADA NO MODELO DSSAT/CROPGRO-SOYBEAN

Figura 1. Estação agrometeorológica instalada na lavoura de soja, Fazenda Areão (Esalq/USP).

Os dados de E5 foram coletados a partir de uma estação agrometeorológica instalada na área experimental (Figura 1). Especificamente para a geração de dados de entrada do modelo DSSAT/CROPGRO-SOYBEAN utilizou-se os sensores: (a) temperatura e umidade relativa do ar (HMP155, Vaisala, Inc.); (b) saldo radiômetro (NR-Lite2, Kipp & Zone, Inc.); e (c) um pluviômetro (TE525MM, Texas Instruments, Inc.) (Figura 7). Para a coleta dos dados utilizou-se uma *datalogger* (CR1000, Campbell Scientific, Inc.). Para o E4, utilizou-se os dados coletados no Posto Meteorológico da ESALQ/USP (Figura 6), cuja distância da área experimental é de 30 m.

Dados meteorológicos obtidos pelas estações meteorológicas do Instituto Nacional de Meteorologia (INMET) ao longo dos experimentos para os municípios de Viçosa-MG (Figura 2 e 3), Santo Antônio de Goiás-GO (Figura 4) e Paragominas-PA (Figura 5).

Figura 2. Dados meteorológicos do experimento 1 (E1, safra 1997/98), Viçosa-MG: saldo de radiação, temperatura do ar mínima, média e máxima, e precipitação pluvial.

Figura 3. Dados meteorológicos do experimento 1 (E1, safra 1998/99), Viçosa-MG : saldo de radiação, temperatura do ar mínima, média e máxima, e precipitação pluvial.

Figura 4. Dados meteorológicos do experimento 2 (E2, safra 2007/08), Santo Antônio de Goiás- GO: saldo de radiação, temperatura do ar mínima, média e máxima, e precipitação pluvial.

Figura 5. Dados meteorológicos do experimento 3 (E3, safra 2007), Paragominas- PA : saldo de radiação, temperatura do ar mínima, média e máxima, e precipitação pluvial.

Figura 6. Dados meteorológicos do experimento 4 (E4, safra 2015/16): saldo de radiação, temperatura do ar mínima, média e máxima, e precipitação pluvial.

Figura 7. Dados meteorológicos do experimento 5 (E5, safra 2016/17), Piracicaba-SP: saldo de radiação, temperatura mínima, média e máxima, e precipitação pluvial.

APÊNDICE C — ANÁLISE QUÍMICA DO SOLO NOS EXPERIMENTOS E4 E E5

A análise química do solo foi realizada no Laboratório de Fertilidade do Solo, Departamento de Ciência do Solo (ESALQ/USP), a partir de uma amostra composta (para cada experimento) de 10 subamostras homogêneas coletadas na camada de 0,20-0,40 m de profundidade, em Piracicaba-SP (Tabela 1 e 2).

Tabela 1. Análise química do solo (Nitossolo Vermelho) – E4.

Resultado Análise Química do Solo- E1		
pH (H ₂ O)	—	5,5
M.O	Colorimétrica (g.dm ⁻³)	22
P	Resina (mg.dm ⁻³)	16
S	Fosfato de cálcio (mmolc.dm ⁻³)	10
K	Resina (mmolc.dm ⁻³)	3,4
Ca	Resina (mmolc.dm ⁻³)	40
Mg	Resina (mmolc.dm ⁻³)	17
Al - Cloromtria	KCl (mmolc.dm ⁻³)	<1
H + Al	SMP (mmolc.dm ⁻³)	34
SB	(mmolc.dm ⁻³)	50,4
CTC	(mmolc.dm ⁻³)	94,4
V	%	64
M	%	2
Boro	água quente (mg.dm ⁻³)	0,42
Cobre	DTPA (mg.dm ⁻³)	2,2
Ferro	DTPA (mg.dm ⁻³)	69
Manganês	DTPA (mg.dm ⁻³)	30,7
Zinco	DTPA (mg.dm ⁻³)	3,1

Tabela 2. Análise química do solo (Argissolo Vermelho-Amarelo) – E5.

Resultado Análise Química do Solo- E1		
pH (H ₂ O)	—	5,7
M.O	Colorimétrica (g.dm ⁻³)	23
P	Resina (mg.dm ⁻³)	23
S	Fosfato de cálcio (mmolc.dm ⁻³)	36
K	Resina (mmolc.dm ⁻³)	6,2
Ca	Resina (mmolc.dm ⁻³)	43
Mg	Resina (mmolc.dm ⁻³)	13
Al - Cloromtria	KCl (mmolc.dm ⁻³)	<1
H + Al	SMP (mmolc.dm ⁻³)	34
SB	(mmolc.dm ⁻³)	62,2
CTC	(mmolc.dm ⁻³)	96,2
V	%	65
M	%	0
Boro	água quente (mg.dm ⁻³)	0,91
Cobre	DTPA (mg.dm ⁻³)	5,3
Ferro	DTPA (mg.dm ⁻³)	18
Manganês	DTPA (mg.dm ⁻³)	41,3
Zinco	DTPA (mg.dm ⁻³)	4,6

ANEXO**ANEXO 1- DELIMITAÇÃO DAS ZONAS HOMOGÊNEAS (ZH)**