

**UNIVERSIDADE ESTADUAL DO CENTRO-OESTE, UNICENTRO - PR**

**MODELAGEM DA PRODUTIVIDADE DE SOJA EM  
FUNÇÃO DE VARIÁVEIS METEOROLÓGICAS NO  
CENTRO-SUL DO PARANÁ**

DISSERTAÇÃO DE MESTRADO

**RODRIGO FERREIRA**

**GUARAPUAVA-PR**

**2018**

**RODRIGO FERREIRA**

**MODELAGEM DA PRODUTIVIDADE DE SOJA EM FUNÇÃO DE VARIÁVEIS  
METEOROLÓGICAS NO CENTRO-SUL DO PARANÁ**

Dissertação apresentada à Universidade Estadual do Centro-Oeste, como parte das exigências do Programa de Pós-Graduação em Agronomia - Mestrado, área de concentração em Produção Vegetal, para a obtenção do título de Mestre.

Prof. Dr. Jackson Kawakami

Orientador

Prof. Dr. Hilton Thadeu Zarate do Couto

Co-orientador

**GUARAPUAVA-PR**

**2018**

Catálogo na Fonte  
Biblioteca da UNICENTRO

FERREIRA, Rodrigo.

F383m Modelagem da produtividade de soja em função de variáveis meteorológicas no Centro-Sul do Paraná / Rodrigo Ferreira. – Guarapuava, PR : [s.n], 2018. 56f.

Orientador: Prof. Dr. Jackson Kawakami

Coorientador: Prof. Dr. Hilton Thadeu Zarate do Couto

Dissertação (mestrado) - Programa de Pós-Graduação em Agronomia. Área de concentração em Produção Vegetal. Universidade Estadual do Centro-Oeste, PR.

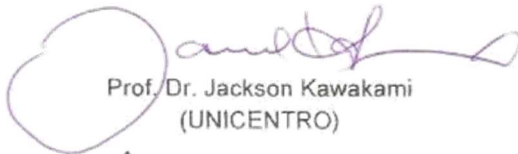
1. Agronomia – dissertação. 2. Meteorologia – produção. 3. CSM-CROPGRO. 4. Modelo Estatístico. 5. Simulação. 6. Regressão múltipla. I. Kawakami, Jackson. II. Couto, Hilton Thadeu Zarate do. III. UNICENTRO. IV. Título.

Rodrigo Ferreira

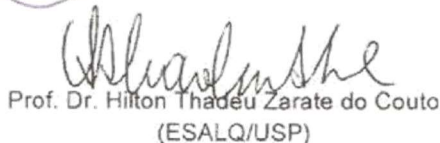
MODELAGEM DA PRODUTIVIDADE DA SOJA EM FUNÇÃO DE VARIÁVEIS  
METEREOLÓGICAS NO CENTRO-SUL DO PARANÁ

Dissertação apresentada à Universidade Estadual do Centro-Oeste, como parte das exigências do Programa de Pós-Graduação em Agronomia, área de concentração em Produção Vegetal, para a obtenção do título de Mestre.

Aprovada em 15 de fevereiro de 2018.



Prof. Dr. Jackson Kawakami  
(UNICENTRO)




Prof. Dr. Hilton Thadeu Zarate do Couto  
(ESALQ/USP)



Dr. José Mauricio Fernandes  
(EMABRAPA-TRIGO)



Prof. Dr. Leandro Rampim  
(UNICENTRO)



Dr. Vitor Spader  
(FAPA)

GUARAPUAVA-PR

2018

## AGRADECIMENTOS

A Deus, autor da vida e consumidor da minha fé.

À minha esposa Giselle, por todo apoio durante essa jornada.

Aos meus pais, por acreditarem em mim desde o início.

Ao Prof. Dr. Jackson Kawakami, pela orientação, aconselhamento, suporte nas decisões e pelo imenso acréscimo à minha formação profissional e pessoal.

Ao Prof. Dr. Hilton Thadeu Zarate do Couto, pela co-orientação e grande contribuição ao trabalho, pela confiança e disposição em ensinar.

Ao Dr. José Maurício Fernandes, pela co-orientação, confiança e abertura de novos horizontes.

Ao Dr. Vitor Spader e sua equipe, pelo encorajamento e por fornecer os dados base para o desenvolvimento do trabalho.

Ao Prof. Dr. Leandro Rampim, pelo aconselhamento e auxílio no aperfeiçoamento do trabalho.

Ao Me. Paulo José Alba, sua equipe e ao Eng. Agr. Sascha Schwarz, pelo suporte e grande ajuda no levantamento de dados à campo.

Ao Me. Leandro Taubinger, pelo auxílio e suporte no levantamento de dados à campo.

Ao Eng. Agr. Leandro Bren, pelo apoio e incentivo para enfrentar os novos desafios.

À Cooperativa Agrária, pela suporte e incentivo ao estudo e crescimento profissional.

À Lucília da Rosa de Lima, por sua prestatividade, atenção e auxílio durante todo o curso.

Aos professores do PPGA - Produção Vegetal, pelos conhecimentos compartilhados.

*“If the mountain were smooth, you couldn’t climb it”*

(Wintley Phipps)

## SUMÁRIO

<b>LISTA DE TABELAS</b> .....	<b>i</b>
<b>LISTA DE FIGURAS</b> .....	<b>ii</b>
<b>RESUMO</b> .....	<b>iii</b>
<b>ABSTRACT</b> .....	<b>iv</b>
<b>1. INTRODUÇÃO GERAL</b> .....	<b>1</b>
<b>1.1. Referências bibliográficas</b> .....	<b>5</b>
<b>2. OBJETIVOS</b> .....	<b>11</b>
<b>2.1. Geral</b> .....	<b>11</b>
<b>2.2. Específicos</b> .....	<b>11</b>
<b>3. CAPÍTULO I - MODELAGEM ESTATÍSTICA DA PRODUTIVIDADE DE SOJA EM FUNÇÃO DE VARIÁVEIS METEOROLÓGICAS NO CENTRO-SUL DO PARANÁ</b> .....	<b>12</b>
<b>RESUMO</b> .....	<b>12</b>
<b>ABSTRACT</b> .....	<b>13</b>
<b>3.1. Introdução</b> .....	<b>14</b>
<b>3.2. Materiais e métodos</b> .....	<b>16</b>
3.2.1. Desenvolvimento do modelo estatístico .....	16
3.2.2. Teste do modelo estatístico preditivo .....	18
<b>3.3. Resultados e discussão</b> .....	<b>19</b>
3.3.1. Desenvolvimento do modelo estatístico .....	19
3.3.2. Teste do modelo estatístico preditivo .....	21
<b>3.4. Conclusões</b> .....	<b>25</b>
<b>3.5. Referências bibliográficas</b> .....	<b>26</b>
<b>4. CAPÍTULO II - CSM-CROPGRO-Soybean: PREVISÃO DA PRODUTIVIDADE DE SOJA NA REGIÃO CENTRO-SUL DO ESTADO DO PARANÁ</b> .....	<b>30</b>
<b>RESUMO</b> .....	<b>30</b>
<b>ABSTRACT</b> .....	<b>31</b>
<b>4.1. Introdução</b> .....	<b>32</b>
<b>4.2. Materiais e métodos</b> .....	<b>33</b>
4.2.1. CSM-CROPGRO-Soybean .....	33
4.2.2. Descrição dos experimentos e coleta de dados .....	34
4.2.3. Calibração do modelo CSM-CROPGRO-Soybean .....	37

4.2.4. Teste do modelo CSM-CROPGRO-Soybean .....	38
<b>4.3. Resultados e discussão .....</b>	<b>39</b>
4.3.1. Ajuste dos coeficientes genéticos e calibração do modelo .....	39
4.3.2. Resultados das simulações de desenvolvimento e produtividade .....	40
<b>4.4. Conclusões .....</b>	<b>46</b>
<b>4.5. Referências bibliográficas .....</b>	<b>47</b>
<b>5. CONSIDERAÇÕES FINAIS .....</b>	<b>52</b>
<b>APÊNDICES .....</b>	<b>55</b>



## LISTA DE TABELAS

<b>Tabela 1.</b> Variáveis meteorológicas transformadas selecionadas para construção do modelo preditivo de produção da soja .....	20
<b>Tabela 2.</b> Resumo da análise de variâncias, mostrando a soma dos quadrados (SQ), os quadrados médios (QM), a raiz do erro quadrático médio (REQM), o coeficiente de determinação $R^2$ do modelo .....	21
<b>Tabela 3.</b> Estimativa dos parâmetros das variáveis meteorológicas do modelo .....	21
<b>Tabela 4.</b> Comparativo entre produtividade de soja real e estimada através do modelo matemático, o coeficiente de determinação ( $R^2$ ), a raiz do erro quadrático médio (REQM) e o índice de concordância de Willmott ( $d$ ), no Distrito de Entre Rios-Guarapuava-PR .....	22
<b>Tabela 5.</b> Descrição dos locais dos experimentos .....	34
<b>Tabela 6.</b> Densidade do solo, volume de água em solo saturado (VASS), volume de água na capacidade de campo (VACC), volume de água em ponto de murcha permanente (VAMP), teores de argila, silte e carbono orgânico (CO) e pH do solo em água para os três locais do estudo .....	35
<b>Tabela 7.</b> Coeficientes genéticos do modelo CSM-CROPGRO-Soybean para sojas dos grupos de maturação 5,0 e 6,0 e os coeficientes modificados para as cultivares BMX Apolo RR, PRODUZA IPRO e TMG 7262 RR .....	37
<b>Tabela 8.</b> Produtividade de soja observada e simulada pelo CSM-CROPGRO-Soybean na região Centro-Sul do Paraná, percentual de desvio (D), raiz do erro quadrático médio (REQM) e índice de concordância de Willmott ( $d$ ), em três épocas de semeadura (E1 - 10 a 15 de outubro, E2 - 10 a 15 de novembro, E3 - 10 a 15 de dezembro) .....	42
<b>Tabela 9.</b> Condições meteorológicas do ano 2016/17 observadas nos três locais de ensaio e normal climatológica do Distrito de Entre Rios-Guarapuava-PR durante a estação de cultivo da soja .....	44

## LISTA DE FIGURAS

<b>Figura 1.</b> Produtividade de soja estimada em função da época de semeadura para o Distrito de Entre Rios-Guarapuava-PR .....	24
<b>Figura 2.</b> Dados de temperatura do ar máximas e mínimas, precipitação pluviométrica e radiação solar de 2012 a 2017 no Distrito de Entre Rios, Guarapuava-PR .....	36
<b>Figura 3.</b> Número de dias observados e simulados entre as datas de semeadura e o estágio R1 (SR1) e R8 (SR8) para as três cultivares de soja, nos municípios de Pinhão, Cândói e Distrito de Entre Rios-Guarapuava .....	41

## RESUMO

FERREIRA, Rodrigo. **Modelagem da produtividade de soja em função de variáveis meteorológicas no Centro-Sul do Paraná.** Guarapuava, 2018.

O presente estudo trouxe duas abordagens distintas para a previsão da produtividade da soja na região Centro-Sul do Paraná através da modelagem matemática de culturas. Foram utilizadas informações dos ensaios conduzidos pela Fundação Agrária de Pesquisa Agropecuária (FAPA) no Distrito de Entre Rios-Guarapuava-PR, Cândói-PR e Pinhão-PR, para as cultivares de soja BMX APOLO RR, PRODUZA IPRO e TMG7262 RR, semeadas em três épocas durante cinco safras (2012/13 a 2016/17). A primeira abordagem trata do desenvolvimento de um modelo estatístico da produção da soja em função de variáveis meteorológicas, avaliando sua capacidade em estimar os resultados de produtividade em diferentes épocas de semeadura. A segunda abordagem traz o modelo mecanístico CSM-CROPGRO-Soybean e o objetivo foi calibrar e avaliar a capacidade desse modelo para simular o desenvolvimento e produtividade de três cultivares de soja nas condições ambientais da região Centro-Sul do Paraná. O modelo estatístico se mostrou capaz de estimar a produtividade da soja nas diferentes épocas de semeadura ao longo dos anos do estudo. Em função das técnicas utilizadas em seu desenvolvimento, suas estimativas são mais restritas a ambientes similares aos do desenvolvimento do modelo. Quanto ao CSM-CROPGRO-Soybean, os resultados desse modelo mostram que os coeficientes genéticos das três cultivares de soja foram bem calibrados, resultando em características de desenvolvimento simuladas em concordância com os valores observados. A avaliação do modelo também mostrou concordância entre dados simulados e observados para produtividade da soja. Ambos os modelos apresentaram adequada capacidade em simular o desenvolvimento e produtividade da soja para a região Centro-Sul do Paraná e podem ser utilizados como ferramentas no auxílio do entendimento dos efeitos do ambiente sobre a produtividade da soja.

**Palavras-chave:** CSM-CROPGRO-Soybean, modelo estatístico, simulação, regressão múltipla.

## ABSTRACT

FERREIRA, Rodrigo. **Modeling soybean yield based on weather variables in the Central Region of Parana State.** Guarapuava, 2018.

The present study brought two distinct approaches for predicting soybean yield in the Central Region of Parana State through the mathematical crop modeling. It was used information from the soybean trials conducted by the Agraria Foundation for Agricultural Research (FAPA) in Entre Rios District-Guarapuava-PR, Candoi-PR and Pinhao-PR, for the soybean cultivars BMX APOLO RR, PRODUZA IPRO and TMG7262 RR, sowed in three seasons during five years (2012/13 to 2016/17). The first approach deals with the development of a statistical model for soybean yield as a function of weather variables, evaluating its capacity to estimate yields at different sowing times. The second approach brings the CSM-CROPGRO-Soybean mechanistic model and the objective was to calibrate and evaluate the capacity of this model to simulate the development and yield of three soybean cultivars in the environmental conditions of the Central Region of Parana State. The statistical model was able to estimate soybean yield at different sowing times throughout the study years. Due to the techniques used in its development, its estimates are more restricted to environments similar to those of model development. About CSM-CROPGRO-Soybean, the results of this model show that the genetic coefficients of the three soybean cultivars were well calibrated, resulting in simulated developmental characteristics in agreement with the observed values. The model evaluation also showed agreement between simulated and observed data for soybean yield. Both models presented adequate capacity to simulate the development and soybeans yields for the Central Region of Parana State and can be used as tools to help understanding the effects of the environment on soybean yield.

**Keywords:** CSM-CROPGRO-Soybean, statistical model, simulation, multiple regression.

## 1. INTRODUÇÃO GERAL

A cultura da soja é uma das culturas agrícolas mais importantes no Brasil. Os seus diversos usos, tanto na alimentação humana quanto para alimentação animal e usos industriais, fazem com que essa cultura seja estudada nos mais diversos aspectos e hoje o seu cultivo se estende por todo o território nacional. Essa expansão na área de cultivo, associada aos incrementos de produtividade obtidos pela evolução no melhoramento genético e também nas práticas de manejo da cultura, colocam o Brasil como o segundo maior produtor do grão, com área de 33,2 milhões de hectares e produção de 96,3 milhões de toneladas em 2016 (Anholetto e Massuquetti, 2015; FAO, 2017; OECD/FAO, 2017).

Nesse cenário o Estado do Paraná tem grande destaque entre os estados produtores do grão, sendo o segundo maior produtor da leguminosa, responsável por 16,3 % da área cultivada e 17,7 % da produção total de soja. Localizada na região central do estado, a microrregião de Guarapuava aparece como a quarta maior produtora de soja dentro do estado, com uma área de 326.310 ha e uma produção de 1,08 milhão de toneladas na safra 2015/16 (CONAB, 2017; IBGE, 2017).

A ampla extensão territorial em que se cultiva a soja expõe a cultura a uma série de variações climáticas que, se não entendidas e manejadas apropriadamente, podem comprometer significativamente sua produção (Anholetto e Massuquetti, 2015). Uma das principais práticas de manejo da cultura da soja é a época de semeadura (Kantolic e Slafer, 2001; Mundstock, 2005; Sinclair *et al.*, 2005; Bastidas *et al.*, 2008; Alliprandini *et al.*, 2009; Pierozan Jr *et al.*, 2017), e determina a forma como a soja será exposta aos diferentes fatores climáticos, principalmente fotoperíodo e temperatura, constituindo a base para o zoneamento agrícola de risco climático, com as indicações das melhores épocas de semeadura para todo o Brasil. No Estado do Paraná, assim como para a região de Guarapuava, esse zoneamento indica a semeadura de soja no período de 11 de setembro até 31 de dezembro (MAPA, 2017).

As condições meteorológicas que mais influenciam na produtividade de soja são o fotoperíodo, radiação solar, temperatura e precipitação pluvial, afetando diretamente o desenvolvimento da cultura e seus efeitos podem ser cumulativos ao longo do ciclo de desenvolvimento da planta.

A disponibilidade de radiação solar para realização das reações da fotossíntese, bem como a qualidade incidente, compõe o elemento básico gerador de toda a cadeia de processos fisiológicos inerentes aos vegetais e é fator fundamental para a produção de biomassa na cultura da soja e, conseqüentemente, de grãos (Shibles e Weber, 1965; Casaroli *et al.*, 2007).

O intervalo de tempo em que há disponibilidade luminosa é chamado de fotoperíodo e está relacionado a diversos processos fisiológicos na planta de soja, que vão desde a indução floral até a formação de grãos, passando pela diferenciação meristemática, microsporogênese e desenvolvimento pós-florescimento. A soja é considerada uma planta de dias curtos, pois a indução floral tende a ser antecipada quando o comprimento do dia é menor, ocasionando a transformação precoce de folhas e hastes em estruturas reprodutivas, alterando o porte final da planta, reduzindo o índice de área foliar e conseqüentemente a disponibilidade de fotoassimilados, afetando os componentes de rendimento, como número de vagens por planta, grãos por vagem, massa de grãos e produtividade (Kiihl, 1982; Cregan e Hartwig, 1984; Kantolic e Slafer, 2001; Zhang *et al.*, 2001; Sinclair *et al.*, 2005; Nico *et al.*, 2015; Bianculli *et al.*, 2016; Zhang, J. *et al.*, 2016).

Alterações nos padrões de temperatura afetam diretamente a taxa fotossintética, a velocidade de divisão celular e a velocidade de transporte e acúmulo de fotoassimilados e, por conseguinte, o acúmulo de biomassa (Sionit *et al.*, 1987; Zhang, L. *et al.*, 2016).

Para a soja, a temperatura ideal de desenvolvimento está em torno de 30 °C, mantendo adequado crescimento até os 20 °C. Esse intervalo de temperaturas também é considerado adequado para processos de germinação e emergência de plântulas, sendo ideal temperatura de solo de 25 °C. Temperaturas abaixo de 10 °C praticamente anulam o desenvolvimento vegetativo além de modificar respostas ao fotoperíodo, retardando a indução floral, que ocorre somente quando há temperaturas superiores a 13 °C. Em contrapartida, temperaturas acima dos 40 °C causam efeitos adversos nas taxas de crescimento, redução do porte de plantas, redução do ciclo de desenvolvimento, aumento nas taxas de abortamento de flores e vagens e queda na produtividade, se agravando ainda mais quando associadas ao déficit hídrico (Mundstock, 2005; Sinclair *et al.*, 2005; Setiyono *et al.*, 2007; EMBRAPA, 2013).

Os efeitos de excedentes ou déficits hídricos também tem importante efeito sobre a produtividade, principalmente nos estágios iniciais de germinação e emergência da cultura, pela redução na uniformidade e população final de plantas, e durante toda a sua fase reprodutiva, pelo encurtamento do período de florescimento, abortamento de flores, vagens, grãos e menor peso de grãos (Sionit e Kramer, 1977; Sinclair, 1986; Maehler *et al.*, 2003; Zhang, J. *et al.*, 2016). A demanda hídrica da cultura é crescente ao longo de seu ciclo de desenvolvimento e atinge sua máxima necessidade a partir do florescimento (7 a 8 mm dia<sup>-1</sup>), mantendo-se elevada durante todo o período de enchimento de grãos antes de começar a declinar na maturação fisiológica (Mundstock, 2005; EMBRAPA, 2013).

Diante da complexidade das interações entre os cultivos e o ambiente em que estão inseridos, a modelagem vem como a ciência baseada na representação simplificada de um sistema que pode ser composta pelo conjunto de símbolos e relações matemáticas ordenadas logicamente (modelos) capazes de expressar essas interações (Corrêa *et al.*, 2011). De forma geral, os modelos podem ser descritos como um conjunto de representações matemáticas ou de equações que buscam expressar as relações que ocorrem num sistema real. Um elevado número de processos e um alto grau de complexidade entre seus componentes podem ser descritos e simulados através dessas equações, fornecendo ferramentas confiáveis para a predição de eventos físicos, químicos e biológicos.

De acordo com Karl e Trenberth (2003), Lobell *et al.* (2008), Challinor *et al.* (2009), Asseng *et al.* (2014) e Asseng *et al.* (2015), os modelos de simulação de culturas são ferramentas importantíssimas nos estudos das interações e mudanças no clima e os seus efeitos sobre os diversos cultivos e os possíveis impactos dessas mudanças nas condições ambientais sobre a produtividade. Além do mais, a aplicação de modelos de simulação de sistemas agrícolas atualmente representa poderosa ferramenta para a avaliação de cenários, opções de manejo e extrapolações de resultados experimentais no espaço e no tempo, outrossim, para atividades acadêmicas e de ensino, auxílio na pesquisa, sistemas de suporte e gerenciamento de decisões de manejo e também análise de planejamento estratégico e políticas de gestão (Loomis *et al.*, 1979; Boote *et al.*, 1996; Sinclair e Seligman, 1996; Jones *et al.*, 2003).

Em função da escala temporal simulada, da origem e tipo de dados de entrada, finalidade e aplicação, diversas classificações são sugeridas para diferenciar os modelos, mas basicamente são agrupados em dois grandes grupos: modelos matemáticos e modelos de simulação.

Os modelos de simulação nada mais são do que uma série de modelos matemáticos agrupados de forma a representar fenômenos extremamente complexos e para longos períodos de tempo, como por exemplo os modelos de circulação atmosférica global. Já os modelos matemáticos, de acordo com Paustian *et al.* (1992), podem ser classificados de três formas: empíricos ou estatísticos, mecanísticos e estocásticos.

De forma geral os modelos estatísticos baseiam-se em dados observacionais e consideram apenas as possíveis interações entre os elementos estudados, não levando em consideração os fenômenos envolvidos na geração dos processos em si. São derivados de análises de regressão usadas para ajustar uma curva ou equação matemática aos dados experimentais e exigem uma grande quantidade de informações para que possam ser desenvolvidos. Quando construídos baseados no conhecimento da estrutura de um sistema podem ser mais valiosos do que um complexo modelo mecanístico, baseado apenas nos

resultados de sua predição. Apresentam boa acurácia para descrever alguns fenômenos biológicos como a produtividade de culturas nas regiões onde foram desenvolvidos, porém, são extremamente restritos quando se trata da extrapolação de suas previsões (Baier, 1979; Thornley e Johnson, 1990; Paustian *et al.*, 1992; Addiscott, 1993; Dourado Neto *et al.*, 1998; Corrêa *et al.*, 2011).

Um dos primeiros e mais eficientes modelos estatísticos já desenvolvido data de 1735, quando Réaumur fez a associação entre o desenvolvimento das culturas e a temperatura do ar, propondo um modelo agrometeorológico baseado no conceito do acúmulo de graus-dia. Grandes avanços ocorreram a partir da década de 50, principalmente com os estudos do Professor C. T. de Wit, da Universidade de Wageningen – Holanda, estabelecendo relações entre transpiração, fotossíntese e dossel de plantas e seus efeitos sobre produtividade, consolidando as bases da modelagem em agricultura (De Wit, 1958; Corrêa *et al.*, 2011).

Os modelos mecanísticos de crescimento de culturas ou explanatórios passam a considerar em sua rotina as leis físicas, químicas e biológicas que regem o comportamento dos processos aos quais se propõe a prever e buscam elucidar as relações de causa e efeito entre seus componentes. Da mesma forma que os modelos estatísticos, também demandam um grande volume de dados para que possam ser desenvolvidos em virtude da necessidade de se entender como cada mecanismo atua na resposta, entretanto, apresentam baixa restrição quanto à extrapolação e espacialização de suas projeções, sendo considerados os mais versáteis entre os modelos matemáticos (Baier, 1979; Thornley e Johnson, 1990; Paustian *et al.*, 1992; Dourado Neto *et al.*, 1998; Corrêa *et al.*, 2011).

Com o avanço das ciências da computação e também do maior conhecimento dos processos fisiológicos das plantas diversos modelos mecanísticos foram desenvolvidos para os mais diferentes propósitos, como por exemplo o Agricultural Production Systems sIMulator (APSIM), a série CERES e o próprio CSM-Cropgro-Soybean, entre outros, que conseguem integrar em suas estruturas matemáticas as interações solo-planta-atmosfera (Boote *et al.*, 1997; Jones *et al.*, 2003; Hoogenboom, 2015).

Quando se trata de modelos estocásticos, além dos componentes estatísticos descritivos, esses abordam o elemento probabilístico em suas funções e possuem pelo menos uma variável randômica em sua mecânica, o que não significa dizer que seja imprevisível, mas sim que sua variação ocorre de forma estatística e que sua incerteza pode ser prevista probabilisticamente. Para o seu desenvolvimento são necessárias várias interações para que se obtenha um resultado estimado confiável, não em um único valor, mas em um grupo de possibilidades determinadas por sua probabilidade de ocorrência. Este tipo de modelo é muito utilizado em meteorologia e



são a base dos modelos de previsão do tempo e do clima (Thornley e Johnson, 1990; Law e Kelton, 1991; Paustian *et al.*, 1992; Addiscott, 1993; Corrêa *et al.*, 2011).

Podendo ser considerado como o principal propósito e também a linha mestra na maioria dos modelos de simulação de culturas, as previsões de produtividade a partir de informações ambientais estão intrinsicamente ligadas à história do desenvolvimento dessas ferramentas (Addiscott, 1993; Boote *et al.*, 1996; Sinclair e Seligman, 1996; Corrêa *et al.*, 2011; Dury *et al.*, 2012).

À medida que essa ciência foi evoluindo novas aplicações foram descobertas e cada vez mais fatores foram acrescentados a esses modelos, tornando-os cada vez mais complexos e com a capacidade de explicar uma diversidade de aspectos e processos, indo muito além da simples previsão de produtividade. Hoje existem plataformas inteiras desenvolvidas para congregarem conjuntamente diversos modelos de simulação que incluem, além dos modelos de previsão de produtividade, modelos matemáticos que simulam os efeitos de pragas, doenças, plantas daninhas e aleloquímicos, dinâmica de nutrientes e física dos solos, que se combinam à previsão de produtividade, gerando assim estimativas mais precisas e realistas (Dourado Neto *et al.*, 1998; Hammer *et al.*, 2002; Martínez *et al.*, 2011; Dury *et al.*, 2012; Chimonyo *et al.*, 2015; Holzworth *et al.*, 2015).

Estudos mais aprofundados da aplicabilidade e eficiência dos modelos de simulação no entendimento dos efeitos do clima e suas interações com os genótipos de soja e também às práticas de manejo na cultura podem trazer grande contribuição para o avanço e aprimoramento do conhecimento da produção de soja na região Centro Sul do Paraná.

## 1.1. Referências bibliográficas

ADDISCOTT, T. M. Simulation modelling and soil behaviour. **Geoderma**, v. 60, n. 1, p. 15-40, 1993.

ALLIPRANDINI, L. F.; ABATTI, C.; BERTAGNOLLI, P. F.; CAVASSIM, J. E.; GABE, H. L.; KUREK, A.; MATSUMOTO, M. N.; DE OLIVEIRA, M. A. R.; PITOL, C.; PRADO, L. C.; STECKLING, C. Understanding Soybean Maturity Groups in Brazil: Environment, Cultivar Classification, and Stability. **Crop Science**, v. 49, n. 3, p. 801-808, 2009.

ANHOLETO, C. D.; MASSUQUETTI, A. A soja brasileira e gaúcha no período de 1994-2010: uma análise da produção, exportação, renda e emprego. **Revista Economia e Desenvolvimento**, v. 13, n. 2, 2015.

ASSENS, S.; EWERT, F.; MARTRE, P.; ROTTER, R. P.; LOBELL, D. B.; CAMMARANO, D.; KIMBALL, B. A.; OTTMAN, M. J.; WALL, G. W.; WHITE, J. W.; REYNOLDS, M. P.; ALDERMAN, P. D.; PRASAD, P. V. V.; AGGARWAL, P. K.; ANOTHAI, J.; BASSO, B.; BIERNATH, C.; CHALLINOR, A. J.; DE SANCTIS, G.; DOLTRA, J.; FERERES, E.; GARCIA-VILA, M.; GAYLER, S.; HOOGENBOOM, G.; HUNT, L. A.; IZAURRALDE, R. C.; JABLOUN, M.; JONES, C. D.; KERSEBAUM, K. C.; KOEHLER, A. K.; MULLER, C.; NARESH KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. E.; PALOSUO, T.; PRIESACK, E.; EYSHI REZAEI, E.; RUANE, A. C.; SEMENOV, M. A.; SHCHERBAK, I.; STOCKLE, C.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; THORBURN, P. J.; WAHA, K.; WANG, E.; WALLACH, D.; WOLF, J.; ZHAO, Z.; ZHU, Y. Rising temperatures reduce global wheat production. **Nature Climate Change**, v. 5, n. 2, p. 143-147, 2015.

ASSENS, S.; ZHU, Y.; WANG, E.; ZHANG, W. Crop modeling for climate change impact and adaptation. In: (Ed.). **Crop Physiology: Applications for Genetic Improvement and Agronomy: Second Edition**: Elsevier Inc., 2014. p.505-546.

BAIER, W. Note on the terminology of crop-weather models. **Agricultural Meteorology**, v. 20, n. 2, p. 137-145, 1979.

BASTIDAS, A. M.; SETIYONO, T. D.; DOBERMANN, A.; CASSMAN, K. G.; ELMORE, R. W.; GRAEF, G. L.; SPECHT, J. E. Soybean Sowing Date: The Vegetative, Reproductive, and Agronomic Impacts. **Crop Science**, v. 48, n. 2, p. 727-740, 2008.

BIANCULLI, M. L.; AGUIRREZÁBAL, L. A. N.; PEREYRA IRUJO, G. A.; ECHARTE, M. M. Contribution of incident solar radiation on leaves and pods to soybean seed weight and composition. **European Journal of Agronomy**, v. 77, p. 1-9, 2016.

BOOTE, K. J.; JONES, J. W.; HOOGENBOOM, G. Simulation of crop growth: CROPGRO model. In: PEART, R. M. e CURRY, R. B. (Ed.). **Agricultural Systems Modeling and Simulation**. Boca Raton: CRC Press, 1997. p.651-692.

BOOTE, K. J.; JONES, J. W.; PICKERING, N. B. Potential uses and limitations of crop models. **Agronomy Journal**, v. 88, n. 5, p. 704-716, 1996.

CASAROLI, D.; FAGAN, E. B.; SIMON, J.; MEDEIROS, S. P.; MANFRON, P. A.; DOURADO NETO, D.; VAN LIER, Q. J.; MÜLLER, L.; MARTIN, T. N. Radiação solar e aspectos fisiológicos na cultura da soja. **Revista da FZVA**, v. 14, n. 2, 2007.

CHALLINOR, A. J.; OSBORNE, T.; MORSE, A.; SHAFFREY, L.; WHEELER, T.; WELLER, H.; VIDALE, P. L. Methods and resources for climate impacts research. **Bulletin of the American Meteorological Society**, v. 90, n. 6, p. 836-848, 2009.

CHIMONYO, V. G. P.; MODI, A. T.; MABHAUDHI, T. Perspective on crop modelling in the management of intercropping systems. **Archives of Agronomy and Soil Science**, v. 61, n. 11, p. 1511-1529, 2015.

CONAB. Companhia Nacional de Abastecimento. **Acompanhamento da Safra Brasileira - Grãos**, 2017. Disponível em: < [http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17\\_09\\_12\\_10\\_14\\_36\\_boletim\\_graos\\_s\\_eteembro\\_2017.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17_09_12_10_14_36_boletim_graos_s_eteembro_2017.pdf) >. Acesso em: 05 Dez. 2017.

CORRÊA, S. T. R.; DOURADO NETO, D.; LORENÇONI, R.; SCARPARE, F. V.; VIVIAN, R.; RUIZ, E. T. Aplicações e limitações da modelagem em agricultura: Revisão. **Revista de Agricultura**, v. 86, n. 1, p. 1-13, 2011.

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.

DE WIT, C. Transpiration and Crop Yields. No. **REP-10707**. CIMMYT, 1958.

DOURADO NETO, D.; TERUEL, D. A.; REICHARDT, K.; NIELSEN, D. R.; FRIZZONE, J. A.; BACCHI, O. O. S. Principles of crop modelling and simulation: II. The implications of the objective in model development. **Scientia Agricola**, v. 55, n. SPE, p. 51-57, 1998.

DURY, J.; SCHALLER, N.; GARCIA, F.; REYNAUD, A.; BERGEZ, J. E. Models to support cropping plan and crop rotation decisions. A review. **Agronomy for Sustainable Development**, v. 32, n. 2, p. 567-580, 2012.

EMBRAPA. **Tecnologias de produção de soja: Região Central do Brasil 2014**. Londrina: Embrapa Soja, 2013.

FAO. Food And Agriculture Organization of the United Nations. **FAOSTAT Production Crops**, 2017. Disponível em: < <http://www.fao.org/faostat/en/#data/QC> >. Acesso em: 28 Dez. 2017.

HAMMER, G. L.; KROPFF, M. J.; SINCLAIR, T. R.; PORTER, J. R. Future contributions of crop modelling—from heuristics and supporting decision making to understanding genetic regulation and aiding crop improvement. **European Journal of Agronomy**, v. 18, n. 1–2, p. 15-31, 2002.

HOLZWORTH, D. P.; SNOW, V.; JANSSEN, S.; ATHANASIADIS, I. N.; DONATELLI, M.; HOOGENBOOM, G.; WHITE, J. W.; THORBURN, P. Agricultural production systems modelling and software: Current status and future prospects. **Environmental Modelling and Software**, 2015.

HOOGENBOOM, G., J.W. JONES, P.W. WILKENS, C.H. PORTER, K.J. BOOTE, L.A. HUNT, U. SINGH, J.I. LIZASO, J.W. WHITE, O. URYASEV, R. OGOSHI, J. KOO, V. SHELIA, AND G.Y. TSUJI. **Decision Support System for Agrotechnology Transfer (DSSAT) Version 4.6** (<http://dssat.net>). DSSAT Foundation, Prosser, Washington. 2015.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal**, 2017. Disponível em: < <https://sidra.ibge.gov.br/tabela/1612#resultado> >. Acesso em: 03 Set. 2017.

JONES, J. W.; HOOGENBOOM, G.; PORTER, C. H.; BOOTE, K. J.; BATCHELOR, W. D.; HUNT, L. A.; WILKENS, P. W.; SINGH, U.; GIJSMAN, A. J.; RITCHIE, J. T. The DSSAT cropping system model. **European Journal of Agronomy**, v. 18, n. 3–4, p. 235-265, 2003.

KANTOLIC, A. G.; SLAFER, G. A. Photoperiod sensitivity after flowering and seed number determination in indeterminate soybean cultivars. **Field Crops Research**, v. 72, n. 2, p. 109-118, 2001.

KARL, T. R.; TRENBERTH, K. E. Modern global climate change. **Science**, v. 302, n. 5651, p. 1719-1723, 2003.

KIIHL, R. D. S. **Influence of photoperiod upon certain growth and reproductive characteristics of soybean varieties and segregation of characters in the F2 generation**. Mississippi State University, 1982.

LAW, A. M.; KELTON, W. D. **Simulation modeling and analysis**. 3 ed. New York: McGraw-Hill 1991.

LOBELL, D. B.; BURKE, M. B.; TEBALDI, C.; MASTRANDREA, M. D.; FALCON, W. P.; NAYLOR, R. L. Prioritizing climate change adaptation needs for food security in 2030. **Science**, v. 319, n. 5863, p. 607-610, 2008.

LOOMIS, R. S.; RABBINGE, R.; NG, E. Explanatory models in crop physiology. **Annual Review of Plant Physiology**, v. 30, n. 1, p. 339-367, 1979.

MAEHLER, A. R.; PIRES, J. L. F.; COSTA, J. A.; FERREIRA, F. G. Potencial de rendimento da soja durante a ontogenia em razão da irrigação e arranjo de plantas. **Pesquisa Agropecuária Brasileira**, v. 38, n. 2, p. 225-231, 2003.

MAPA. Ministério da Agricultura, Pecuária e Abastecimento. **Portaria nº 16, de 20 de julho de 2017**, 2017. Disponível em: < <http://www.agricultura.gov.br/assuntos/riscos-seguro/risco-agropecuario/portarias/safra-vigente/parana> >. Acesso em: 13 Dez. 2017.

MARTÍNEZ, B. C.; ROSADO, O. R.; LÓPEZ, F. G.; HERNÁNDEZ, P. P.; BECERRA, Á. M.; VILLAMIL, L. V. Application of simulation models in agricultural research and planning, a review. **Tropical and Subtropical Agroecosystems**, v. 14, n. 3, p. 999-1010, 2011.

MUNDSTOCK, C. M. T., A. L. **Soja: Fatores que afetam o crescimento e o rendimento de grãos**. Porto Alegre: Ed. Evangraf, 2005.

NICO, M.; MIRALLES, D. J.; KANTOLIC, A. G. Post-flowering photoperiod and radiation interaction in soybean yield determination: Direct and indirect photoperiodic effects. **Field Crops Research**, v. 176, p. 45-55, 2015.

OECD/FAO. **OECD-FAO Agricultural Outlook 2017-2026**. Paris: OECD Publishing, 2017. Disponível em: < [http://dx.doi.org/10.1787/agr\\_outlook-2017-en](http://dx.doi.org/10.1787/agr_outlook-2017-en) >.

PAUSTIAN, K.; PARTON, W. J.; PERSSON, J. Modeling soil organic matter in organic-amended and nitrogen-fertilized long-term plots. **Soil Science Society of America Journal**, v. 56, n. 2, p. 476-488, 1992.

PIEROZAN JR, C.; KAWAKAMI, J.; SCHWARZ, K.; UMBURANAS, R. C.; DEL CONTE, M. V.; MÜLLER, M. M. L. Sowing Dates and Soybean Cultivars Influence Seed Yield, Oil and Protein Contents in Subtropical Environment. **Journal of Agricultural Science**, v. 9, n. 6, p. 188-198, 2017.

SETIYONO, T. D.; WEISS, A.; SPECHT, J.; BASTIDAS, A. M.; CASSMAN, K. G.; DOBERMANN, A. Understanding and modeling the effect of temperature and daylength on soybean phenology under high-yield conditions. **Field Crops Research**, v. 100, n. 2, p. 257-271, 2007.

SHIBLES, R.; WEBER, C. Leaf area, solar radiation interception and dry matter production by soybeans. **Crop Science**, v. 5, n. 6, p. 575-577, 1965.

SINCLAIR, T.; NEUMAIER, N.; FARIAS, J.; NEPOMUCENO, A. Comparison of vegetative development in soybean cultivars for low-latitude environments. **Field Crops Research**, v. 92, n. 1, p. 53-59, 2005.

SINCLAIR, T. R. Water and nitrogen limitations in soybean grain production I. Model development. **Field Crops Research**, v. 15, n. 2, p. 125-141, 1986.

SINCLAIR, T. R.; SELIGMAN, N. A. G. Crop modeling: from infancy to maturity. **Agronomy Journal**, v. 88, n. 5, p. 698-704, 1996.

SIONIT, N.; KRAMER, P. J. Effect of water stress during different stages of growth of soybean. **Agronomy Journal**, v. 69, n. 2, p. 274-278, 1977.

SIONIT, N.; STRAIN, B. R.; FLINT, E. P. Interaction of temperature and CO<sub>2</sub> enrichment on soybean: photosynthesis and seed yield. **Canadian Journal of Plant Science**, v. 67, n. 3, p. 629-636, 1987.

THORNLEY, J. H.; JOHNSON, I. R. **A mathematical approach to plant and crop physiology**. Caldwell: The Blackburn Press, 1990.

ZHANG, J.; LIU, J.; YANG, C.; DU, S.; YANG, W. Photosynthetic performance of soybean plants to water deficit under high and low light intensity. **South African Journal of Botany**, v. 105, p. 279-287, 2016.

ZHANG, L.; WANG, R.; HESKETH, J. D. Effects of photoperiod on growth and development of soybean floral bud in different maturity. **Agronomy Journal**, v. 93, n. 4, p. 944-948, 2001.

ZHANG, L.; ZHU, L.; YU, M.; ZHONG, M. Warming decreases photosynthates and yield of soybean [*Glycine max* (L.) Merrill] in the North China Plain. **The Crop Journal**, v. 4, n. 2, p. 139-146, 2016.

## **2. OBJETIVOS**

### **2.1. Geral**

Estudar modelos de simulação da produtividade da cultura da soja na região Centro-Sul do Paraná, Brasil.

### **2.2. Específicos**

Desenvolver e avaliar um modelo estatístico de simulação da produtividade da cultura da soja em função de variáveis meteorológicas para a região Centro-Sul do Paraná, Brasil.

Calibrar e avaliar a capacidade do modelo CSM-CROPGRO-Soybean (DSSAT) para prever a produtividade da soja para a região Centro-Sul do Paraná, Brasil.

### 3. CAPÍTULO I - MODELAGEM ESTATÍSTICA DA PRODUTIVIDADE DA SOJA EM FUNÇÃO DE VARIÁVEIS METEOROLÓGICAS NO CENTRO-SUL DO PARANÁ - BRASIL

#### RESUMO

Diversos fatores meteorológicos podem influenciar o desenvolvimento e a produtividade da soja e uma das formas de se compreender as interações desses fatores e os diferentes genótipos de soja é através da utilização de modelos de simulação de culturas. O objetivo deste estudo foi desenvolver um modelo estatístico para estimar a produtividade da cultura da soja em função de variáveis meteorológicas e avaliar sua capacidade em estimar a produtividade em diferentes épocas de semeadura da cultura para a região Centro-Sul do Paraná. Para o desenvolvimento do modelo foram utilizadas as informações dos ensaios conduzidos pela Fundação Agrária de Pesquisa Agropecuária (FAPA) nos anos 2015/16 e 2016/17 no Distrito de Entre Rios-Guarapuava-PR, Cândói-PR e Pinhão-PR. As características avaliadas foram: datas de emergência (VE), florescimento pleno (R2) e maturação fisiológica (R8), além da produtividade ( $\text{kg ha}^{-1}$ ). Os dados meteorológicos utilizados foram: temperaturas mínima, média e máxima ( $^{\circ}\text{C}$ ), precipitação diária (mm), radiação solar diária total ( $\text{MJ m}^{-2} \text{ dia}^{-1}$ ) e fotoperíodo diário (h). A partir das datas de VE, R2 e R8, os dados meteorológicos foram reorganizados em períodos de 7, 14, 21 e 28 dias antecedentes a essas datas, compondo assim as variáveis meteorológicas agrupadas. Essas variáveis meteorológicas agrupadas foram submetidas a análise de regressão linear, utilizando-se a técnica Passo-a-Passo, selecionando-se as variáveis meteorológicas componentes do modelo estatístico. A avaliação foi realizada a partir da comparação entre as produtividades estimadas pelo modelo e as informações obtidas dos ensaios da FAPA, no Distrito de Entre Rios-Guarapuava-PR, nos anos 2012/13 até 2016/17, em três épocas de semeadura. As variáveis escolhidas para o modelo foram: média do fotoperíodo 28 dias antes de VE (MHRAD28EM), média da temperatura mínima do ar 21 dias antes de VE (TMIN21EM), temperatura média do ar 28 dias antes de R2 (TMED28FL) e somatório da precipitação diária 21 dias antes de R2 (SRAIN21FL). O modelo geral apresentou valores do coeficiente de determinação ( $R^2$ ) de 0,96, raiz do erro quadrático médio (REQM) de  $1.026,46 \text{ kg ha}^{-1}$  e índice de concordância de Willmott ( $d$ ) com valor de 0,99, evidenciando que o modelo é capaz de estimar a produtividade da soja na região Centro-Sul do Paraná.

**Palavras-chave:** regressão múltipla, simulação, clima.



# CHAPTER I - STATISTICAL MODEL OF SOYBEAN YIELD BASED ON WEATHER VARIABLE IN THE CENTRAL REGION OF PARANA STATE - BRAZIL

## ABSTRACT

Several meteorological factors can influence the development and yield of soybean and one of the ways to understand the interactions of these factors and the different soybean genotypes is through the use of crop simulation models. The objective of this study was to develop a statistical model to estimate soybean yield as a function of meteorological variables and to evaluate its capacity to estimate yields at different sowing times for the Central Region of Parana State, Brazil. For the development of the model, it was used the information from the soybean trials conducted by the Agraria Foundation for Agricultural Research (FAPA) in the years 2015/16 and 2016/17 in the District of Entre Rios-Guarapuava-PR, Candoi-PR and Pinhao-PR. The characteristics evaluated were: dates of emergence (VE), full flowering (R2) and physiological maturation (R8), and yield (kg ha<sup>-1</sup>). The meteorological data used were: minimum, average and maximum temperature (° C), daily precipitation (mm), total daily solar radiation (MJ m<sup>-2</sup> day<sup>-1</sup>) and daily photoperiod (h). From the VE, R2 and R8 dates, the meteorological data were reorganized in periods of 7, 14, 21 and 28 days antecedent to these dates, thus composing the grouped meteorological variables. These grouped meteorological variables were submitted to linear regression analysis, using the Stepwise technique, selecting the meteorological variables components of the statistical model. The evaluation was carried out based on the comparison between the estimated yield and the data obtained from the FAPA trials, in the District of Entre Rios-Guarapuava-PR, in the years 2012/13 to 2016/17, in three sowing seasons. The variables selected for the model were: mean photoperiod 28 days before VE (MHRAD28EM), mean minimum air temperature 21 days before VE (TMIN21EM), mean air temperature 28 days before R2 (TMED28FL) and sum of daily precipitation 21 days before R2 (SRRAIN21FL). The general model shows values of the coefficient of determination (R<sup>2</sup>) of 0.96, root mean square error (RMSE) of 1,026.46 kg ha<sup>-1</sup> and Willmott's concordance index (*d*) with a value of 0.99, evidencing that the model is able to estimate the soybean yield in the Central Region of Parana State, Brazil.

**Keywords:** multiple regression, simulation, climate.

### 3.1. Introdução

A agricultura é um expressivo componente da economia do Brasil, e está consolidada como setor gerador de elevada exportação. Nesse contexto, a soja figura entre uma das principais atividades do agronegócio brasileiro. Na safra 2016/2017 a área cultivada da cultura no Brasil atingiu 33,9 milhões de ha, com produção total ultrapassando 114,0 milhões de toneladas (CONAB, 2017), garantindo posição de destaque perante o mundo como fornecedor da oleaginosa (FAO, 2017; OECD/FAO, 2017).

Apesar das dimensões continentais do Brasil, a soja encontra-se amplamente disseminada por todo o território, expondo a cultura a uma série de variações climáticas que, se não entendidas e manejadas apropriadamente, podem comprometer significativamente os rendimentos da cultura (Anholetto e Massuquetti, 2015).

Entre os principais fatores meteorológicos que influenciam o desenvolvimento e a produtividade da soja citam-se a radiação solar, o fotoperíodo, a temperatura e a disponibilidade hídrica (Shibles e Weber, 1965; Sionit e Kramer, 1977; Cregan e Hartwig, 1984; Sinclair, 1986; Sionit *et al.*, 1987; Sinclair *et al.*, 2005; Casaroli *et al.*, 2007).

A disponibilidade de radiação solar para realização das reações da fotossíntese, bem como a qualidade incidente compõe o elemento básico gerador de toda a cadeia de processos fisiológicos inerentes aos vegetais e são fatores fundamentais para a produção de biomassa na cultura da soja e, conseqüentemente, de grãos (Shibles e Weber, 1965; Casaroli *et al.*, 2007).

O fotoperíodo está relacionado a diversos processos fisiológicos na planta de soja, que vão desde a indução floral até a formação de grãos, passando pela diferenciação meristemática, microsporogênese e desenvolvimento pós-florescimento. A soja é considerada uma planta de dias curtos, pois a indução floral tende a ser antecipada quando o comprimento do dia é menor, ocasionando a transformação precoce de folhas e hastes em estruturas reprodutivas, alterando o porte final da planta, reduzindo o índice de área foliar e conseqüentemente a disponibilidade de fotoassimilados, afetando os componentes de rendimento, como número de vagens por planta, grãos por vagem, massa de grãos e produtividade (Kiihl, 1982; Cregan e Hartwig, 1984; Kantolic e Slafer, 2001; Zhang *et al.*, 2001; Nico *et al.*, 2015; Bianculli *et al.*, 2016; Zhang, J. *et al.*, 2016).

O aumento na temperatura pode causar a antecipação do período de florescimento bem como encurtar de forma geral o período total de crescimento. Também pode causar redução na taxa fotossintética durante o período de antese e de enchimento de grãos, além de reduzir a velocidade de transporte e o acúmulo de açúcares solúveis totais nas folhas, caules e grãos,

resultando em menor acúmulo de biomassa e, conseqüentemente, menor produtividade (Sionit *et al.*, 1987; Tao *et al.*, 2006; Tacarindua *et al.*, 2013; Kumagai e Sameshima, 2014; Choi *et al.*, 2016; Zhang, L. *et al.*, 2016).

A temperatura ideal de desenvolvimento da soja está em torno de 30 °C, mantendo um bom crescimento até os 20 °C. Esse intervalo de temperaturas também é considerado adequado para os processos de germinação e emergência de plântulas, sendo ideal uma temperatura de solo de 25 °C. Temperaturas abaixo de 10 °C praticamente anulam o desenvolvimento vegetativo além de modificar as respostas ao fotoperíodo, retardando a indução floral, que ocorre somente quando há temperaturas superiores a 13 °C. Temperaturas acima dos 40 °C causam efeitos adversos em plantas de soja como: redução do porte, redução do ciclo de desenvolvimento, aumento nas taxas de abortamento de flores e vagens e queda na produtividade, se agravando ainda mais quando associadas ao déficit hídrico (Mundstock, 2005; Sinclair *et al.*, 2005; Setiyono *et al.*, 2007; EMBRAPA, 2013b).

A disponibilidade de água durante o ciclo de desenvolvimento da cultura da soja é de extrema importância, uma vez que a demanda hídrica da cultura é crescente ao longo de seu ciclo de desenvolvimento e atinge sua máxima necessidade a partir do florescimento (7 a 8 mm dia<sup>-1</sup>), mantendo-se elevada durante todo o período de enchimento de grãos antes de começar a declinar na maturação fisiológica (Mundstock, 2005; EMBRAPA, 2013b). Entretanto, em dois momentos o estresse hídrico pode comprometer o potencial produtivo. O primeiro momento é nos estágios iniciais de germinação e emergência da cultura, pela redução na uniformidade e população final de plantas, e o segundo durante toda a sua fase reprodutiva, pelo encurtamento do período de florescimento, abortamento de flores, vagens, grãos e diminuição do peso de grãos (Sionit e Kramer, 1977; Sinclair, 1986; Maehler *et al.*, 2003; Zhang, J. *et al.*, 2016).

Além da complexidade dos ambientes de cultivo, as práticas de manejo empregadas na cultura também podem afetar a produtividade. A época de semeadura, por exemplo, interfere diretamente no fotoperíodo, radiação solar e temperatura, afetando ciclo, taxas de crescimento, arquitetura de planta, componentes do rendimento e, por conseguinte, a produtividade (Kantolic e Slafer, 2001; Mundstock, 2005; Sinclair *et al.*, 2005; Bastidas *et al.*, 2008; Alliprandini *et al.*, 2009; Pierozan Jr *et al.*, 2017).

Uma das formas de se compreender melhor essas interações entre os ambientes de cultivo, práticas de manejo e os diferentes genótipos de soja é através da utilização de modelos de simulação de culturas. A utilização da modelagem como ferramenta no auxílio do entendimento vem sendo utilizada há bastante tempo, como por exemplo, já na década de 70 Monteith (1972) criou modelos estatísticos para estabelecer as relações entre interceptação da

radiação, eficiência de absorção e a partição dos fotoassimilados durante o crescimento das plantas.

A partir de então, novas propostas foram apresentadas (Thornley, 1976) e já surgem os primeiros sistemas de classificação dos modelos matemáticos já existentes em função do aumento na complexidade de construção e propósito, além de esforços para melhorar a avaliação da precisão dos mesmos (Baier, 1979; Loomis *et al.*, 1979; Willmott, 1982).

Sendo assim, o objetivo deste estudo foi desenvolver um modelo estatístico da produtividade da cultura da soja em função de variáveis meteorológicas e avaliar sua capacidade em estimar os resultados de produtividade em diferentes épocas de semeadura da cultura na região Centro-Sul do Paraná.

## **3.2. Materiais e métodos**

### **3.2.1. Desenvolvimento do modelo estatístico**

Para o desenvolvimento do modelo estatístico foi construído um banco de dados utilizando as informações dos ensaios conduzidos pela Fundação Agrária de Pesquisa Agropecuária (FAPA) nos anos agrícolas de 2015/16 e 2016/17 em 3 locais: 1 - estação experimental da FAPA no Distrito de Entre Rios - Guarapuava-PR; 2 - Fazenda Santa Clara - Cândói-PR; 3 - Fazenda Fundo Grande - Pinhão-PR, com altitudes de 1100 m, 936 m e 830 m, respectivamente. A classificação climática nos três locais, segundo Köppen, é Cfb (Kottek *et al.*, 2006), e a pedológica para os municípios de Cândói e Pinhão é dada como Latossolo Vermelho Distrófico típico, enquanto que para Entre Rios, a classificação é descrita como Latossolo Bruno Alumínico típico (EMBRAPA, 2013a).

Os ensaios foram conduzidos em delineamento de blocos casualizados com três repetições, organizados em esquema de parcela sub-subdividida, totalizando 27 tratamentos. Os tratamentos nas parcelas foram três épocas de semeadura, sendo: 1º época - 10 a 15 de outubro; 2º época - 10 a 15 de novembro e 3º época - 10 a 15 de dezembro. Como tratamentos das subparcelas foram utilizadas três densidades de semeadura: 150, 250 e 350 mil plantas ha<sup>-1</sup>. Os tratamentos nas sub-subparcelas foram três cultivares de soja: BMX Apolo RR, PRODUZA IPRO e TMG7262 RR, pertencentes aos grupos de maturação 5.5, 6.0 e 6.2, respectivamente. Cada unidade experimental constituiu-se de quatro linhas de 5 m de comprimento, espaçadas em 0,4 m.

Nos três locais os ensaios foram implantados e conduzidos sob o sistema de semeadura direta na palhada utilizando-se equipamento mecanizado de semeadura de parcelas e o ajuste de densidade, quando necessário, foi realizado através de desbaste manual após a emergência das plântulas.

As características avaliadas em cada parcela foram: datas de emergência (VE), florescimento pleno (R2) e maturação fisiológica (R8), conforme escala proposta por Fehr e Caviness (1977), número de plantas por área ( $m^{-2}$ ), além dos componentes de rendimento: número de grãos por área ( $m^{-2}$ ), massa de mil grãos (g) e produtividade ( $kg\ ha^{-1}$ ) ajustada para 13% de umidade.

Para a obtenção dos dados meteorológicos diários foram utilizadas estações meteorológicas automáticas pertencentes à FAPA instaladas em cada um dos locais de pesquisa. Os dados meteorológicos utilizados foram: temperaturas mínima, média e máxima ( $^{\circ}C$ ), precipitação diária (mm), radiação solar diária total ( $MJ\ m^{-2}\ dia^{-1}$ ). O fotoperíodo diário (h) foi obtido dos bancos de dados da *National Aeronautics And Space Administration* (NASA) fornecendo as informações de latitude e longitude de cada local (Nasa, 2017). A partir das datas do estágios fenológicos VE, R2 e R8 de cada cultivar os dados meteorológicos foram reorganizados em períodos de 7, 14, 21 e 28 dias antecedentes a essas datas, respectivamente, e para cada período foram calculadas as variáveis meteorológicas agrupadas, cujas nomenclaturas seguiram o seguinte formato: (variável meteorológica) + (período) + (evento), como demonstrado no exemplo: TMED7EM, que significa temperatura média do ar no período de sete dias antecedentes à emergência da cultura.

Essas variáveis meteorológicas agrupadas foram submetidas à análise de correlação de Spearman com a produtividade, visando encontrar as maiores relações de dependência entre as mesmas (Sas, 2011). As variáveis que apresentaram altos coeficientes de correlação e significativos ( $p < 0,0001$ ) foram selecionadas para compor o conjunto de dados inicial do processo de seleção/exclusão, concluindo assim o primeiro ciclo de seleção.

Das variáveis advindas desse primeiro ciclo de seleção foram eliminadas as que apresentaram coeficientes de correlação muito próximos ou redundantes e na sequência foram submetidas a análise de regressão utilizando a técnica Passo-a-Passo (Stepwise) para identificar o melhor conjunto de preditores para o modelo considerando que a importância de cada variável é dada como um valor de significância estatística do coeficiente associado à variável para o modelo, concluindo assim a segunda etapa de seleção (Sas, 2011; Chatterjee e Hadi, 2015).

Essas variáveis foram então submetidas às transformações lineares (a própria variável), quadráticas, inversas, logarítmicas e cúbicas, visando testar diferentes ajustes de cada variável

à produtividade da soja, sendo renomeadas para variáveis transformadas e que passaram a compor um novo banco de dados (Apêndice B), sendo novamente submetidas a análise de regressão utilizando a técnica Passo-a-Passo, selecionando-se somente as que foram significativas ( $p < 0,01$ ) e que contribuíram para aumentar o valor de  $R^2$  do modelo (Chatterjee e Hadi, 2015), encerrando a terceira fase de seleção.

A partir das variáveis selecionadas nessa terceira fase, cinco modelos foram criados utilizando-se diferentes combinações das mesmas. Os modelos foram testados utilizando-se os mesmos dados usados para a seleção das variáveis meteorológicas pelo método da Raiz do Erro Quadrático Médio (REQM) e pelo coeficiente de determinação  $R^2$ , escolhendo-se a combinação de variáveis que apresentou o menor REQM e o maior  $R^2$  e que passaram a compor o modelo preditivo de produtividade descrito na Equação 1 (Chatterjee e Hadi, 2015).

### 3.2.2. Avaliação do modelo estatístico preditivo

Para a avaliação do modelo um novo banco de dados foi construído a partir das informações obtidas dos ensaios em rede conduzidos pela FAPA, na estação experimental do Distrito de Entre Rios - Guarapuava-PR, nas safras de 2012/13 até 2016/17. As cultivares utilizadas, os dados meteorológicos e as características avaliadas foram as mesmas utilizadas no desenvolvimento do modelo.

O modelo foi utilizado para estimar a produtividade geral da soja para o Distrito de Entre Rios-Guarapuava-PR e também para estimar a produtividade da soja em cada ano, cada uma das três épocas de semeadura (1º época - 10 a 15 de outubro, 2º época - 10 a 15 de novembro e 3º época - 10 a 15 de dezembro) e para cada época de semeadura em cada ano, para o mesmo local.

Os resultados de produtividade obtidos nos ensaios foram comparados aos obtidos através da estimativa do modelo preditivo e o ajuste da equação de regressão do modelo foi avaliado pelo coeficiente de determinação ( $R^2$ ), pelo método da Raiz do Erro Quadrático Médio (REQM) (Wallach e Goffinet, 1987) e também pelo índice de concordância de Willmott ( $d$ ) (Willmott *et al.*, 1985).

### 3.3. Resultados e discussão

#### 3.3.1. Desenvolvimento do modelo estatístico

Como resultado do primeiro ciclo de seleção, 53 variáveis meteorológicas agrupadas foram escolhidas e encontram-se descritas no Apêndice A. Nesse conjunto inicial de dados observa-se que há redundância entre as variáveis, como por exemplo média do fotoperíodo diário (MHRAD), cujas variantes temporais antecedentes à data de emergência da soja (28EM, 21EM, 14EM e 7EM) apresentaram altos índices de correlação e todas foram altamente significativas. Para a fase seguinte apenas a média do fotoperíodo diário no período de 28 dias antecedentes a data de emergência (MHRAD28EM) permaneceu, excluindo-se as outras variantes. Esse processo de seleção/exclusão foi realizado com todas as variáveis agrupadas para melhorar a acurácia da seleção na fase seguinte.

Quando analisamos as variáveis meteorológicas e seus impactos na produtividade da soja, um ponto importante durante o desenvolvimento do modelo estatístico é a criação dos diferentes períodos para cada uma delas. Isso se faz necessário para diminuir a oscilação da mesma para as datas de VE, R2 e R8, pois se utilizássemos o valor único de cada variável meteorológica para uma data específica sua amplitude seria intensa entre os diferentes anos e épocas de semeadura, prejudicando consideravelmente a sensibilidade das análises estatísticas e dificultando a escolha das variáveis meteorológicas mais importantes para o modelo (Chatterjee e Hadi, 2015).

Da segunda fase de seleção cinco variáveis foram escolhidas e foram as seguintes: MHRAD28EM (média do fotoperíodo no período de 28 dias antecedentes à emergência), TMIN21EM (média da temperatura mínima do ar no período de 21 dias antecedentes à emergência), TMED28FL (temperatura média do ar no período de 28 dias antecedentes ao florescimento), SSRAD14FL (somatório da radiação solar diária no período de 14 dias antecedentes ao florescimento) e SRAIN21FL (somatório da precipitação pluviométrica diária no período de 21 dias antecedentes ao florescimento).

Como resultado da análise de regressão na terceira fase de seleção, nove variáveis transformadas foram selecionadas, conforme se observa na Tabela 1.

A construção do modelo de previsão de produtividade baseou-se no método de regressão linear múltipla (Chatterjee e Hadi, 2015), utilizando-se diferentes combinações dessas variáveis meteorológicas transformadas para criar diferentes modelos de previsão.

**Tabela 1.** Variáveis meteorológicas transformadas selecionadas para construção do modelo preditivo de produção da soja.

Variável transformada <sup>1</sup>	R <sup>2</sup> parcial	R <sup>2</sup> do modelo	<i>p</i>
(MHRAD28EM) <sup>3</sup>	0,3914	0,3914	<0,0001
(TMIN21EM) <sup>3</sup>	0,1267	0,5180	<0,0001
(1/ TMED28FL)	0,1052	0,6233	<0,0001
TMIN21EM	0,0425	0,6658	<0,0001
(SRAIN21FL) <sup>2</sup>	0,0103	0,6761	<0,0001
(1/ SSRAD14FL)	0,0093	0,6854	0,0002
(1/ MHRAD28EM)	0,0078	0,6932	0,0006
(1/ TMIN21EM)	0,0050	0,6982	0,0050
(SRAIN21FL) <sup>3</sup>	0,0046	0,7028	0,0067

<sup>1</sup>: MHRAD28EM - média do fotoperíodo diário no período de 28 dias antecedente a data de emergência; TMIN21EM - média das temperaturas mínimas no período de 21 dias antecedente a data de emergência; TMED28FL - média das temperaturas médias no período de 28 dias antecedente a data de florescimento; SRAIN21FL - somatório da precipitação diária no período de 21 dias antecedente a data de florescimento; SSRAD14FL - somatório da radiação solar diária no período de 14 dias antecedente a data de florescimento.

Maior valor de R<sup>2</sup> parcial evidencia que a variável meteorológica possui mais influência nos resultados finais do modelo e a chance de sucesso aumenta com a combinação dessas variáveis, enquanto que valores menores do R<sup>2</sup> parcial indicam que a variável pouco contribui nos resultados do modelo, tornando-o desnecessariamente complexo e aumento seu erro (Sas, 2011; Chatterjee e Hadi, 2015).

O modelo que apresentou o menor valor de REQM (639,07 Kg) e maior R<sup>2</sup> (0,64) para a previsão da produtividade utilizou as variáveis (SHRAD28EM) <sup>3</sup>, (TMIN21EM) <sup>3</sup>, (1/ TMED28FL) e (SRAIN21FL) <sup>2</sup>, e está descrito na Equação 1.

$$PRODS = 35957 - 4,57785 \times (MHRAD28EM)^3 - 0,74484 \times (TMIN21EM)^3 - 356850 \times \left(\frac{1}{TMED28FL}\right) - 0,01114 \times (SRAIN21FL)^2 \quad (1)$$

Na equação acima se observa que a variável transformada TMIN21EM (Tabela 1), mesmo apresentando valor de R<sup>2</sup> maior (0,0425) do que a da variável seguinte (SRAIN21FL) <sup>2</sup> (0,0103), não compôs o modelo. Isso se deve ao fato da mesma ser redundante à variável (TMIN21EM) <sup>3</sup>, o que reduziria a precisão do modelo.

A Tabela 2 mostra o resumo dos resultados do modelo de regressão linear através da análise de variância, mostrando que o modelo é altamente significativo e apresenta um bom ajuste aos dados observados.

As estimativas dos parâmetros do modelo estão descritas na Tabela 3 e se observa que as quatro variáveis meteorológicas selecionadas apresentam alta significância estatística para o mesmo.



**Tabela 2.** Resumo da análise de variâncias, mostrando a soma dos quadrados (SQ), os quadrados médios (QM), a raiz do erro quadrático médio (REQM), o coeficiente de determinação  $R^2$  do modelo.

Varição	Gl <sup>1</sup>	SQ	QM	F	<i>p</i>	REQM	$R^2$
Modelo	4	349599657	87399914	214,00	<0,0001	636,43	0,9886
Erro	481	196447360	408414				
Total	485	546047016					

<sup>1</sup>: Grau de liberdade.

**Tabela 3.** Estimativa dos parâmetros das variáveis meteorológicas do modelo.

Variável	Estimativa do parâmetro	Erro padrão	t	<i>p</i>
Intercepto	35957,0	1843,55558	19,50	<0,0001
(MHRAD28EM <sup>3</sup> )	-4,57785	0,25072	-18,26	<0,0001
(TMIN21EM <sup>3</sup> )	-0,74484	0,04375	-17,03	<0,0001
(1/ TMED28FL)	-356850	28453	-12,54	<0,0001
(SRRAIN21FL <sup>2</sup> )	-0,01114	0,00234	-4,76	<0,0001

### 3.3.2. Avaliação do modelo estatístico preditivo

A Tabela 4 mostra os resultados reais e simulados obtidos a partir do modelo, bem como os resultados do coeficiente  $R^2$ , o índice *d* de Willmott e o REQM. Observa-se que os melhores ajustes ocorreram nos mesmos anos a partir dos quais o modelo foi desenvolvido, 2015/16 e 2016/17. Esse resultado é esperado para modelos estatísticos pois a acurácia do modelo é aumentada a partir da variabilidade existente na base de dados original utilizada no desenvolvimento do mesmo.

O valor de  $R^2$  indica a porcentagem da variação explicada pelo modelo, enquanto que o REQM e o índice *d* são ferramentas estatísticas utilizadas para aferir a qualidade de ajuste dos modelos matemáticos. O valor de  $R^2$  varia de (0) a (1), sendo que quanto mais próximo de “1” maior parcela da variabilidade encontrada é explicada pelo modelo. O segundo, como o nome sugere, se constitui da raiz do erro quadrático médio entre o valor predito e o real e quanto menor o seu valor mais acurado é o modelo. Sua unidade de medida é a mesma da característica simulada (Willmott, 1982; Sas, 2011). Já o índice *d* é usado para determinar o grau relativo de concordância entre medidas simuladas e reais, com alta sensibilidade para valores extremos, sendo indicado para grandes conjuntos de dados. Assim como o  $R^2$ , não possui unidade de medida por se tratar de um índice e seu valor varia entre (0) e (1), em que “0” significa não haver concordância entre os dados e “1” há ajuste perfeito entre os valores reais e simulados (Willmott, 1982; Willmott *et al.*, 1985).

**Tabela 4.** Comparativo entre produtividade de soja real e estimada através do modelo matemático, o coeficiente de determinação ( $R^2$ ), a raiz do erro quadrático médio (REQM) e o índice de concordância de Willmott ( $d$ ), no Distrito de Entre Rios-Guarapuava-PR.

	Produtividade real	Produtividade estimada	$R^2$	REQM (kg ha <sup>-1</sup> )	$d$
Geral	5.342,19	5.784,34	0,96	1.026,46	0,99
Ano					
2012/13	5.104,17	5.703,81	0,72	1.264,78	0,98
2013/14	4.918,05	5.993,69	0,14	786,88	0,92
2014/15	5.184,40	5.869,70	0,45	820,50	0,97
2015/16	5.345,22	5.335,93	0,98	637,26	1,00
2016/17	6.159,11	6.018,56	0,98	751,55	1,00
Época					
Época 1	6.039,71	7.257,67	0,96	1.190,76	0,90
Época 2	5.466,74	5.702,32	0,98	581,80	0,99
Época 3	4.520,11	4.393,03	0,97	826,62	1,00
Ano x Época					
2012/13					
Época 1	6.088,66	8.735,63	0,53	551,44	0,53
Época 2	5.170,08	5.184,90	0,99	499,16	1,00
Época 3	4.053,76	3.190,88	0,13	435,61	0,95
2013/14					
Época 1	5.176,75	7.309,12	0,12	647,73	0,70
Época 2	4.847,41	5.772,40	0,39	375,64	0,94
Época 3	4.729,98	4.899,56	0,99	364,42	1,00
2014/15					
Época 1	5.784,63	7.052,20	0,71	922,21	0,89
Época 2	5.804,35	5.981,01	0,99	333,10	1,00
Época 3	3.964,22	4.575,90	0,57	767,46	0,97
2015/16					
Época 1	6.876,47	6.503,66	0,99	485,71	0,99
Época 2	4.970,40	5.106,11	0,98	554,46	1,00
Época 3	4.188,77	4.398,03	0,97	705,23	1,00
2016/17					
Época 1	6.272,05	6.687,73	0,98	645,04	0,99
Época 2	6.541,45	6.467,20	0,99	531,37	1,00
Época 3	5.663,82	4.900,75	0,99	526,14	0,96

Os valores do índice  $d$  e de REQM evidenciam que o modelo foi coerente nas previsões de produtividade entre as épocas de semeadura e ao longo dos anos do estudo, mostrando que o conjunto de variáveis meteorológicas escolhido consegue explicar as variações que ocorrem na produtividade da soja para a região de estudo.

Tanto para o  $R^2$ , quanto para o índice  $d$  e REQM não há critérios de interpretação para seus valores, entretanto, no caso dos dois primeiros ainda há um intervalo definido de possibilidades que auxilia em sua interpretação, porém, para o REQM esse intervalo não existe.

Para facilitar a interpretação, alguns autores propõem divisões ou intervalos para criar categorias de concordância entre os resultados simulados e os dados reais. Mercau *et al.* (2007) sugerem que os valores de REQM passem a ser expressos em percentuais dos valores

observados e Liu *et al.* (2013), nessa mesma sugestão, propõem que valores de REQM menores que 15% dos dados reais indicam um bom ajuste do modelo, e que valores entre 15 e 30% sejam considerados ajustes moderados e valores superiores a 30% indicam uma baixa concordância entre dados reais e simulados.

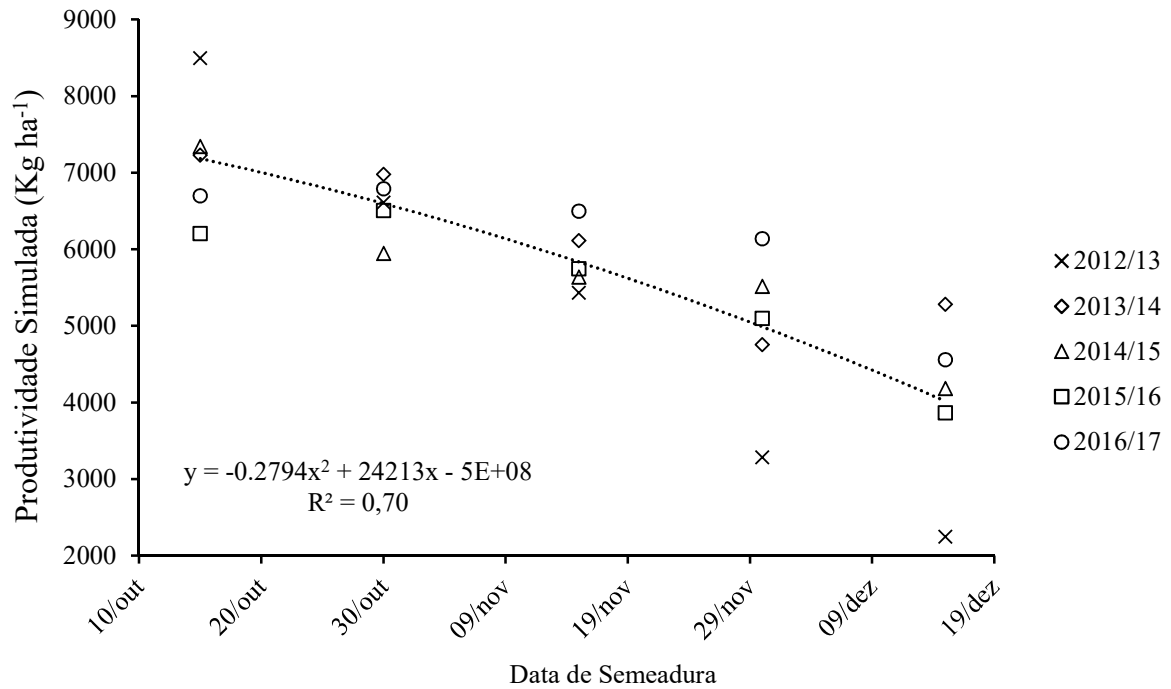
A aplicação dessa proposição aos resultados de produtividade estimados pelo modelo permite a observação de que todos os valores de REQM estão abaixo de 30% de seus respectivos valores reais e que de modo geral o modelo apresenta bom ajuste aos dados reais.

No presente trabalho, com um modelo estatístico menos complexo, os valores de REQM oscilaram entre 333,10 e 1.264,78 kg, enquanto que o índice  $d$  variou de 0,53 a 1,00. Num estudo comparando cinco diferentes modelos mecanísticos de simulação na cultura da soja, Battisti *et al.* (2017) encontraram valores de REQM oscilando entre 440 e 2.010 kg e do índice  $d$  entre 0,37 e 0,93. Para a melhoria da acurácia das previsões sugeriu o uso combinado desses modelos, reduzindo os valores do REQM para um intervalo entre 264 e 518 kg, e do índice  $d$  para 0,91 a 0,98. Tal fato reforça que as variáveis escolhidas para o modelo de fato possuem forte influência sobre a produtividade da soja na região do estudo.

Ao se analisar cada variável componente do modelo a primeira variável meteorológica explicativa (MHRAD28EM) é a que mais influencia os resultados do modelo (Tabela 1) e expressa matematicamente a resposta da soja ao fotoperíodo e, conseqüentemente, sua resposta à época de semeadura. Embora haja diferença entre as cultivares, o atraso na semeadura tende a reduzir o potencial produtivo em função do encurtamento da fase vegetativa, reduzindo o número de nós, vagens e grãos por planta, além de reduzir a massa dos grãos (Câmara *et al.*, 1997; Zhang *et al.*, 2001; Sinclair *et al.*, 2005; Pierozan Jr *et al.*, 2017).

Outro efeito significativo do atraso da semeadura da soja está no avanço da fase reprodutiva para um período no qual o fotoperíodo está diminuindo, reduzindo a disponibilidade de radiação solar para a produção de fotoassimilados durante o período de maior demanda energética da cultura (Bastidas *et al.*, 2008; Alliprandini *et al.*, 2009; Bianculli *et al.*, 2016).

A Figura 1 mostra as produtividades da soja estimadas pelo modelo em função das diferentes épocas de semeadura nos diferentes anos e mostra que o modelo estatístico é uma ferramenta capaz de estimar os efeitos da variabilidade climática intra-anual (efeito das épocas de semeadura) e também interanual (efeito dos anos), auxiliando na compreensão desses efeitos sobre a produtividade da soja.



**Figura 1.** Produtividade de soja estimada em função da época de semeadura para o Distrito de Entre Rios-Guarapuava-PR.

Ao considerar as épocas de semeadura utilizadas nos ensaios (10 de outubro a 15 de dezembro) e que as análises estatísticas utilizadas para o desenvolvimento do modelo buscam entender a relação de causa-efeito entre essas épocas de semeadura com a produtividade, o modelo torna-se impossibilitado de gerar resultados para situações diferentes daquelas utilizadas na sua construção (Corrêa *et al.*, 2011; Chatterjee e Hadi, 2015).

Em função disso, os modelos estatísticos, diferentemente dos modelos mecânicos, possuem limitada capacidade de extrapolação de seus resultados para situações diferentes daquelas nas quais os mesmos foram desenvolvidos. Porém, se bem entendidos os processos no desenvolvimento do sistema e baseado no conhecimento de suas respostas, um modelo estatístico pode ser considerado mais interessante do que um modelo mais complexo (Boote *et al.*, 1996; Dourado Neto *et al.*, 1998; Corrêa *et al.*, 2011).

### 3.4. Conclusões

As variáveis meteorológicas que mais influenciaram na produtividade na cultura da soja foram o fotoperíodo, as temperaturas e a precipitação durante a fase vegetativa da cultura.

A equação do modelo obtida foi a seguinte:

$$PRODS = 35957 - 4,57785 \times (MHRAD28EM)^3 - 0,74484 \times (TMIN21EM)^3 - 356850 \times \left(\frac{1}{TMED28FL}\right) - 0,01114 \times (SRAIN21FL)^2 \quad (1)$$

O modelo foi capaz de simular os efeitos das diferentes épocas de semeadura da soja nos diferentes anos e seus impactos na produtividade da cultura.

A partir dos resultados obtidos no presente trabalho foi possível concluir que houve sucesso no desenvolvimento do modelo estatístico de produtividade da cultura da soja para a região de Centro-Sul do Paraná.

### 3.5. Referências bibliográficas

- ALLIPRANDINI, L. F.; ABATTI, C.; BERTAGNOLLI, P. F.; CAVASSIM, J. E.; GABE, H. L.; KUREK, A.; MATSUMOTO, M. N.; DE OLIVEIRA, M. A. R.; PITOL, C.; PRADO, L. C.; STECKLING, C. Understanding Soybean Maturity Groups in Brazil: Environment, Cultivar Classification, and Stability. **Crop Science**, v. 49, n. 3, p. 801-808, 2009.
- ANHOLETO, C. D.; MASSUQUETTI, A. A soja brasileira e gaúcha no período de 1994-2010: uma análise da produção, exportação, renda e emprego. **Revista Economia e Desenvolvimento**, v. 13, n. 2, 2015.
- BAIER, W. Note on the terminology of crop-weather models. **Agricultural Meteorology**, v. 20, n. 2, p. 137-145, 1979.
- BASTIDAS, A. M.; SETIYONO, T. D.; DOBERMANN, A.; CASSMAN, K. G.; ELMORE, R. W.; GRAEF, G. L.; SPECHT, J. E. Soybean Sowing Date: The Vegetative, Reproductive, and Agronomic Impacts. **Crop Science**, v. 48, n. 2, p. 727-740, 2008.
- BATTISTI, R.; SENTELHAS, P. C.; BOOTE, K. J. Inter-comparison of performance of soybean crop simulation models and their ensemble in southern Brazil. **Field Crops Research**, v. 200, p. 28-37, 2017.
- BIANCULLI, M. L.; AGUIRREZÁBAL, L. A. N.; PEREYRA IRUJO, G. A.; ECHARTE, M. M. Contribution of incident solar radiation on leaves and pods to soybean seed weight and composition. **European Journal of Agronomy**, v. 77, p. 1-9, 2016.
- BOOTE, K. J.; JONES, J. W.; PICKERING, N. B. Potential uses and limitations of crop models. **Agronomy Journal**, v. 88, n. 5, p. 704-716, 1996.
- CÂMARA, G. M. S.; SEDIYAMA, T.; DOURADO-NETO, D.; BERNARDES, M. S. Influence of photoperiod and air temperature on the growth, flowering and maturation of soybean (*Glycine max* (L.) Merrill). **Scientia Agricola**, v. 54, p. 149-154, 1997.
- CASAROLI, D.; FAGAN, E. B.; SIMON, J.; MEDEIROS, S. P.; MANFRON, P. A.; DOURADO NETO, D.; VAN LIER, Q. J.; MÜLLER, L.; MARTIN, T. N. Radiação solar e aspectos fisiológicos na cultura da soja. **Revista da FZVA**, v. 14, n. 2, 2007.
- CHATTERJEE, S.; HADI, A. S. **Regression Analysis by Example**. ed. 5. Hoboken: John Wiley & Sons, Inc., 2015.
- CHOI, D.-H.; BAN, H.-Y.; SEO, B.-S.; LEE, K.-J.; LEE, B.-W. Phenology and Seed Yield Performance of Determinate Soybean Cultivars Grown at Elevated Temperatures in a Temperate Region. **PLoS ONE**, v. 11, n. 11, p. e0165977, 2016.
- CONAB. Companhia Nacional de Abastecimento. **Acompanhamento da Safra Brasileira - Grãos**, 2017. Disponível em: <[http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17\\_09\\_12\\_10\\_14\\_36\\_boletim\\_graos\\_s\\_tembre\\_2017.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17_09_12_10_14_36_boletim_graos_s_tembre_2017.pdf)>. Acesso em: 05 Dez. 2017.
- CORRÊA, S. T. R.; DOURADO NETO, D.; LORENÇONI, R.; SCARPARE, F. V.; VIVIAN,

R.; RUIZ, E. T. Aplicações e limitações da modelagem em agricultura: Revisão. **Revista de Agricultura**, v. 86, n. 1, p. 1-13, 2011.

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.

DOURADO NETO, D.; TERUEL, D. A.; REICHARDT, K.; NIELSEN, D. R.; FRIZZONE, J. A.; BACCHI, O. O. S. Principles of crop modelling and simulation: the implications of the objective in model development. **Scientia Agricola**, v. 55, n. SPE, p. 51-57, 1998.

EMBRAPA. **Sistema brasileiro de classificação de solos**. 3 ed. Rio de Janeiro: Centro Nacional de Pesquisa de Solos, 2013a.

\_\_\_\_\_. **Tecnologias de produção de soja: Região Central do Brasil 2014**. Londrina: Embrapa Soja, 2013b.

FAO. Food And Agriculture Organization of the United Nations. **FAOSTAT Production Crops**, 2017. Disponível em: < <http://www.fao.org/faostat/en/#data/QC> >. Acesso em: 28 Dez. 2017.

FEHR, W. R.; CAVINESS, C. E. Stages of soybean development. **Iowa State University. Agricultural and Home Economics Experiment Station**, v. Special Edition 87, p. 1-12, 1977.

KANTOLIC, A. G.; SLAFER, G. A. Photoperiod sensitivity after flowering and seed number determination in indeterminate soybean cultivars. **Field Crops Research**, v. 72, n. 2, p. 109-118, 2001.

KIIHL, R. D. S. **Influence of photoperiod upon certain growth and reproductive characteristics of soybean varieties and segregation of characters in the F2 generation**. Mississippi State University, 1982.

KOTTEK, M.; GRIESER, J.; BECK, C.; RUDOLF, B.; RUBEL, F. World Map of the Köppen-Geiger climate classification updated. **Meteorologische Zeitschrift**, v. 15, n. 3, p. 259-263, 2006.

KUMAGAI, E.; SAMESHIMA, R. Genotypic differences in soybean yield responses to increasing temperature in a cool climate are related to maturity group. **Agricultural and Forest Meteorology**, v. 198, n. Supplement C, p. 265-272, 2014.

LIU, S.; YANG, J. Y.; ZHANG, X. Y.; DRURY, C. F.; REYNOLDS, W. D.; HOOGENBOOM, G. Modelling crop yield, soil water content and soil temperature for a soybean-maize rotation under conventional and conservation tillage systems in Northeast China. **Agricultural Water Management**, v. 123, p. 32-44, 2013.

LOOMIS, R. S.; RABBINGE, R.; NG, E. Explanatory models in crop physiology. **Annual Review of Plant Physiology**, v. 30, n. 1, p. 339-367, 1979.

MAEHLER, A. R.; PIRES, J. L. F.; COSTA, J. A.; FERREIRA, F. G. Potencial de rendimento da soja durante a ontogenia em razão da irrigação e arranjo de plantas. **Pesquisa Agropecuária Brasileira**, v. 38, n. 2, p. 225-231, 2003.

MERCAU, J. L.; DARDANELLI, J. L.; COLLINO, D. J.; ANDRIANI, J. M.; IRIGOYEN, A.; SATORRE, E. H. Predicting on-farm soybean yields in the pampas using CROPGRO-soybean. **Field Crops Research**, v. 100, n. 2, p. 200-209, 2007.

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

MUNDSTOCK, C. M. T., A. L. **Soja: Fatores que afetam o crescimento e o rendimento de grãos**. Porto Alegre: Ed. Evangraf, 2005.

NASA. Prediction of Worldwide Energy Resource (POWER). **Climatology Resource for Agroclimatology**, 2017. Disponível em: < <https://power.larc.nasa.gov/cgi-bin/agro.cgi?email=agroclim@larc.nasa.gov> >. Acesso em: 20 Abr. 2017.

NICO, M.; MIRALLES, D. J.; KANTOLIC, A. G. Post-flowering photoperiod and radiation interaction in soybean yield determination: Direct and indirect photoperiodic effects. **Field Crops Research**, v. 176, p. 45-55, 2015.

OECD/FAO. **OECD-FAO Agricultural Outlook 2017-2026**. Paris: OECD Publishing, 2017. Disponível em: < [http://dx.doi.org/10.1787/agr\\_outlook-2017-en](http://dx.doi.org/10.1787/agr_outlook-2017-en) >.

PIEROZAN JR, C.; KAWAKAMI, J.; SCHWARZ, K.; UMBURANAS, R. C.; DEL CONTE, M. V.; MÜLLER, M. M. L. Sowing Dates and Soybean Cultivars Influence Seed Yield, Oil and Protein Contents in Subtropical Environment. **Journal of Agricultural Science**, v. 9, n. 6, p. 188-198, 2017.

SAS. **Base SAS® 9.3 Procedures Guide: Statistical Procedures**. Segunda Edição. Cary, NC: SAS Institute Inc, 2011.

SETIYONO, T. D.; WEISS, A.; SPECHT, J.; BASTIDAS, A. M.; CASSMAN, K. G.; DOBERMANN, A. Understanding and modeling the effect of temperature and daylength on soybean phenology under high-yield conditions. **Field Crops Research**, v. 100, n. 2, p. 257-271, 2007.

SHIBLES, R.; WEBER, C. Leaf area, solar radiation interception and dry matter production by soybeans. **Crop Science**, v. 5, n. 6, p. 575-577, 1965.

SINCLAIR, T.; NEUMAIER, N.; FARIAS, J.; NEPOMUCENO, A. Comparison of vegetative development in soybean cultivars for low-latitude environments. **Field Crops Research**, v. 92, n. 1, p. 53-59, 2005.

SINCLAIR, T. R. Water and nitrogen limitations in soybean grain production I. Model development. **Field Crops Research**, v. 15, n. 2, p. 125-141, 1986.

SIONIT, N.; KRAMER, P. J. Effect of water stress during different stages of growth of soybean. **Agronomy Journal**, v. 69, n. 2, p. 274-278, 1977.

SIONIT, N.; STRAIN, B. R.; FLINT, E. P. Interaction of temperature and CO<sub>2</sub> enrichment on soybean: photosynthesis and seed yield. **Canadian Journal of Plant Science**, v. 67, n. 3, p.



629-636, 1987.

TACARINDUA, C. R. P.; SHIRAIWA, T.; HOMMA, K.; KUMAGAI, E.; SAMESHIMA, R. The effects of increased temperature on crop growth and yield of soybean grown in a temperature gradient chamber. **Field Crops Research**, v. 154, n. Supplement C, p. 74-81, 2013.

TAO, F.; YOKOZAWA, M.; XU, Y.; HAYASHI, Y.; ZHANG, Z. Climate changes and trends in phenology and yields of field crops in China, 1981–2000. **Agricultural and Forest Meteorology**, v. 138, n. 1–4, p. 82-92, 2006.

THORNLEY, J. H. **Mathematical models in plant physiology**. London: Academic Press Inc., 1976. ISBN 0126905509.

WALLACH, D.; GOFFINET, B. Mean Squared Error of Prediction in Models for Studying Ecological and Agronomic Systems. **Biometrics**, v. 43, n. 3, p. 561-573, 1987.

WILLMOTT, C. J. Some Comments on the Evaluation of Model Performance. **Bulletin of the American Meteorological Society**, v. 63, n. 11, p. 1309-1313, 1982.

WILLMOTT, C. J.; ACKLESON, S. G.; DAVIS, R. E.; FEDDEMA, J. J.; KLINK, K. M.; LEGATES, D. R.; O'DONNELL, J.; ROWE, C. M. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, v. 90, n. C5, 1985.

ZHANG, J.; LIU, J.; YANG, C.; DU, S.; YANG, W. Photosynthetic performance of soybean plants to water deficit under high and low light intensity. **South African Journal of Botany**, v. 105, p. 279-287, 2016.

ZHANG, L.; R., W.; D., H. J. Effects of photoperiod on growth and development of soybean floral bud in different maturity. **Agronomy Journal**, v. 93, n. 4, p. 944-948, 2001.

ZHANG, L.; ZHU, L.; YU, M.; ZHONG, M. Warming decreases photosynthates and yield of soybean [*Glycine max* (L.) Merrill] in the North China Plain. **The Crop Journal**, v. 4, n. 2, p. 139-146, 2016.

#### 4. CAPÍTULO II - CSM-CROPGRO-Soybean: PREVISÃO DA PRODUTIVIDADE DA SOJA NA REGIÃO CENTRO-SUL DO ESTADO DO PARANÁ

##### RESUMO

Os modelos podem ser descritos como um conjunto de representações matemáticas que buscam expressar as interações que ocorrem num sistema real e inúmeros processos podem ser simulados através dessas equações, fornecendo ferramentas confiáveis para a predição de eventos físicos, químicos e biológicos e suas interações com o meio em que estão inseridos. Esse estudo teve por objetivo calibrar o modelo CSM-CROPGRO-Soybean e avaliar sua capacidade em prever o comportamento do desenvolvimento e da produtividade de soja nas condições da região Centro-Sul do Estado do Paraná. Para a calibração do modelo foram utilizadas as informações referentes as cultivares de soja BMX APOLO RR, PRODUZA IPRO e TMG7262 RR, obtidas dos ensaios conduzidos pela Fundação Agraria de Pesquisa Agropecuária (FAPA) no Distrito de Entre Rios-Guarapuava-PR, nos anos 2012/13 a 2015/16. Após a calibração, a avaliação do modelo foi realizada utilizando os dados de ensaios em Cândói-PR, Pinhão-PR e também no Distrito de Entre Rios-Guarapuava-PR, na safra 2016/17, avaliando-se o desenvolvimento e produtividade das cultivares de soja. Os resultados deste estudo indicaram que os coeficientes genéticos das três cultivares de soja foram bem ajustados, resultando em características de desenvolvimento simuladas em concordância com os valores observados. Para o período entre a semeadura e R1 os valores de REQM variaram entre 0,25 a 2,00 dias e o índice  $d$  variou entre 0,97 e 0,99. Para o período entre a semeadura e R8 esses valores oscilaram entre 0,35 e 2,99 dias para o REQM e entre 0,99 e 1,00 para o índice  $d$ . A avaliação do modelo também mostrou correto ajuste entre dados simulados e observados para produtividade da soja, com uma variação no índice  $d$  entre 0,80 e 1,00, e do REQM entre 12,50 e 330,57 kg ha<sup>-1</sup>. Esses resultados demonstram o potencial do modelo CSM-CROPGRO-Soybean para simular crescimento e rendimento da soja para a região Centro-Sul do Estado do Paraná.

**Palavras-chave:** CSM-CROPGRO-Soybean, modelagem, simulação, soja.

## CHAPTER II - CSM-CROPGRO-Soybean: PREDICTION OF SOYBEAN YIELD IN THE CENTRAL REGION OF THE PARANÁ STATE

### ABSTRACT

Models can be described as a set of mathematical representations able to express interactions that occur in a real system and a large number of processes can be simulated through these equations, providing reliable tools for the prediction of physical, chemical and biological events and their interactions with the environment to which they belong. The objective of this study was to calibrate the CSM-CROPGRO-Soybean model and evaluate its capacity to predict the soybean development and yield in the conditions in the center region of the Paraná State. For the calibration of the model, it was used information of the soybean cultivars BMX APOLO RR, PRODUZA IPRO and TMG7262 RR, obtained from experiments conducted by the Agraria Foundation for Agricultural Research (FAPA) in Entre Rios-Guarapuava-PR, in the years 2012/13 to 2015/16. After the calibration, the model evaluation was performed using data sets from three experiments that were conducted at Candói-PR, Pinhão-PR and Entre Rios, in 2016/17, evaluating the development and yield of soybean cultivars. The results of this study indicated that the genetic coefficients of the three soybean cultivars were well adjusted, resulting in simulated developmental characteristics in agreement with the observed values. For the period between sowing and R1 the root mean square error (RMSE) values ranged from 0.25 to 2.00 days and the index of agreement of Willmott ( $d$ ) ranged from 0.97 to 0.99. For the period between sowing and R8 these values ranged between 0.35 and 2.99 days for the RMSE and between 0.99 and 1.00 for the index  $d$ . Evaluation of the model also showed a good agreement between simulated and observed data for soybean yield, with a variation in the index  $d$  between 0.80 and 1.00 and RMSE between 12.50 and 330.57 kg ha<sup>-1</sup>. These results demonstrate the potential of the CSM-CROPGRO-Soybean model to simulate soybean growth and yield for the center region of the Paraná State.

**Keywords:** CSM-CROPGRO-Soybean, modeling, simulation, soybean.

#### 4.1. Introdução

O Brasil é um país de destaque no cenário agrícola internacional e isso se deve em grande parte ao papel da soja na produção nacional de grãos, colocando o país como um dos principais fornecedores da oleaginosa (FAO, 2017; OECD/FAO, 2017). A constante evolução no melhoramento genético e nas práticas de manejo da cultura da produtividade, associadas a expansão das áreas de cultivo constantemente trazem novos desafios à produtividade da cultura.

Diante da complexidade das interações entre os cultivos e o ambiente em que estão inseridos, a modelagem vem como a ciência baseada na representação simplificada de um sistema que pode ser composta por um conjunto de símbolos e relações matemáticas ordenadas logicamente (modelos) capazes de expressar essas interações (Corrêa *et al.*, 2011). De forma geral os modelos podem ser descritos como um conjunto de representações matemáticas ou de equações que buscam expressar as interações que ocorrem num sistema real. Um grande número de processos e um alto grau de complexidade entre seus componentes podem ser descritos e simulados através dessas equações, fornecendo ferramentas confiáveis para a predição de eventos físicos, químicos e biológicos e suas interações com o meio em que estão inseridos.

Os modelos de simulação de culturas são considerados ferramentas importantes nos estudos das interações e mudanças no clima e os seus efeitos sobre os diversos cultivos e os possíveis impactos dessas mudanças nas condições ambientais sobre a produtividade (Karl e Trenberth, 2003; Lobell *et al.*, 2008; Challinor *et al.*, 2009; Asseng *et al.*, 2014; Asseng *et al.*, 2015).

Uma vez que esses modelos conseguem fazer inferência sobre sistemas reais, a aplicação dos mesmos em sistemas agrícolas atualmente representa um poderoso recurso para a avaliação de cenários, opções de manejo e extrapolações de resultados experimentais no espaço e no tempo, outrossim, para atividades acadêmicas e de ensino, auxílio na pesquisa, sistemas de suporte e gerenciamento de decisões de manejo e também análise de planejamento estratégico e políticas de gestão (Loomis *et al.*, 1979; Boote *et al.*, 1996; Sinclair e Seligman, 1996; Jones *et al.*, 2003).

Inicialmente desenvolvido pelo projeto *International Benchmark Sites Network for Agrotechnology Transfer* (IBSNAT) a partir de 1974 conjuntamente com a *University of Hawaii*, o *Decision Support System for Agrotechnology Transfer* (DSSAT) é o resultado de aproximadamente 10 anos de trabalho, e que hoje é mantido pelo *International Consortium for Agricultural Systems Applications* (ICASA), suportado de forma coletiva por um grande

número de cientistas e pesquisadores ao redor do mundo. Em termos gerais, o DSSAT consiste numa plataforma que reúne vários programas de computador independentes e que interagem entre si, tendo como centrais os modelos de simulação e crescimento, suportados pelas bases de dados que fornecem as descrições genotípicas, climáticas, de solo e de manejo, englobando mais de 40 culturas (Bouma e Jones, 2001; Jones *et al.*, 2003; Hoogenboom, 2015).

Componente integrante da plataforma DSSAT, o CSM-CROPGRO-Soybean é um modelo mecanístico de simulação para a cultura da soja e está inserido na série de modelos CSM-CROPGRO, dedicado às leguminosas, incluindo feijão, feijão-caupi, feijão-fava, amendoim e grão-de-bico, e algumas não leguminosas como o tomate. É subdividido nos módulos primários planta, solo e manejo, permitindo ainda o acoplamento de outros modelos que simulam os efeitos de pragas, doenças, técnicas de preparo e correção de solo, estresse por déficit ou mesmo excedente hídrico, atuando de forma integrada tornando os resultados das simulações mais precisos (Jones *et al.*, 2003; Thorp *et al.*, 2008; Rodrigues *et al.*, 2012; Hoogenboom, 2015).

Como os modelos dessa série detalham os processos biológicos em cada estágio da cultura não apresentam restrições quanto a locais, condições climáticas, genótipos ou sistemas de manejo, eles são capazes de simular e captar a variabilidade presente nos mais importantes processos fisiológicos e prever os resultados de produtividade de forma significativa para os ambientes para os quais foram devidamente calibrados (Boote *et al.*, 1997; Mavromatis *et al.*, 2001; Verhagen *et al.*, 2001; Jones *et al.*, 2003; Sarkar, 2009).

Nesse contexto, o presente trabalho tem por objetivo calibrar o modelo CSM-CROPGRO-Soybean e testar sua capacidade em prever o comportamento do desenvolvimento e da produtividade de soja nas condições da região Centro-Sul do Estado do Paraná.

## **4.2. Material e métodos**

### **4.2.1. CSM-CROPGRO-Soybean**

Para o funcionamento do modelo CSM-CROPGRO-Soybean são necessárias algumas informações básicas, como dados de localização (latitude, longitude e elevação), dados meteorológicos durante o período em que se deseja obter as simulações (temperaturas máxima e mínima, precipitação pluvial e radiação solar total), caracterização básica das camadas de solo (densidade, capacidade de armazenamento de água, textura, teor de carbono orgânico, pH) e informações referentes ao manejo (cultivar, densidade, espaçamento e data de semeadura).

#### 4.2.2. Descrição dos experimentos e coleta de dados

Os dados necessários para a elaboração dos arquivos de entrada e calibração do modelo foram obtidos dos ensaios em rede conduzidos pela Fundação Agraria de Pesquisa Agropecuária (FAPA) no Distrito de Entre Rios-Guarapuava-PR, nas safras agrícolas de 2012/13 a 2015/16. Os dados para o teste do modelo foram obtidos dos ensaios em rede conduzidos pela FAPA em mais dois locais além do Distrito de Entre Rios (Tabela 5), na safra 2016/17. Em cada ensaio foram utilizadas as cultivares de soja BMX APOLO RR, PRODUZA IPRO e TMG7262 RR, dos grupos de maturação 5,5, 6,0 e 6,2, respectivamente, semeadas nos períodos de 10 a 15 de outubro (E1), 10 a 15 de novembro (E2) e 10 a 15 de dezembro (E3), nas densidades de 250, 350 e 450 mil plantas ha<sup>-1</sup>, nos ensaios conduzidos nas safras 2012/2013 a 2015/2016. Nos ensaios de 2016/2017 as densidades foram ajustadas para 150, 250 e 350 mil plantas ha<sup>-1</sup>.

O delineamento experimental utilizado foi o de blocos casualizados, em esquema de parcela sub-subdividida com três repetições. Os tratamentos nas parcelas compunham-se das épocas de semeadura, nas subparcelas distribuíram-se as diferentes densidades de semeadura e as cultivares de soja foram os tratamentos nas sub-subparcelas. Cada parcela compunha-se de quatro linhas de 5 m de comprimento, espaçadas em 0,4 m e os experimentos foram conduzidos sob condições ótimas de desenvolvimento, porém, sem irrigação.

**Tabela 5.** Descrição dos locais dos experimentos.

Local	Candói	Entre Rios	Pinhão
Latitude	25°34' S	25°32' S	25°42' S
Longitude	52°00' O	51°29' O	51°55' O
Altitude (m)	936	1100	830
Clima <sup>1</sup>	Cfb	Cfb	Cfb
Temperatura média (°C)	18.6	16.7	18.5
Precipitação (mm)	1.986	2.017	2.170
Período (anos)	34	41	34
Solo <sup>2</sup>	Latossolo Vermelho Distrófico típico	Latossolo Bruno Alumínico típico	Latossolo Vermelho Distrófico típico

<sup>1</sup>: (Kottek *et al.*, 2006).

<sup>2</sup>: (EMBRAPA, 2013).

Os dados de crescimento da cultura foram obtidos a partir das datas de semeadura, emergência (VE), início de florescimento (R1) e maturação fisiológica (R8), conforme escala proposta por Fehr e Caviness (1977), além das informações de produtividade (kg ha<sup>-1</sup>), ajustada para 13% de umidade.

As informações das características físico-químicas de solo no Distrito de Entre Rios (Tabela 6) foram obtidas de amostras coletadas em três trincheiras, com 1,2 m de profundidade, divididas em sete camadas, com três repetições em cada profundidade. Para os municípios de Candói e Pinhão foram obtidas de amostras coletadas em quatro trincheiras, com 0,4 m de profundidade, divididas em três camadas, com três repetições em cada profundidade. As informações de volume de água em ponto de murcha permanente (VAMP) dos municípios de Candói e Pinhão foram obtidas da base de dados internacional SOILGrids (Iri-Msu-Ifpri, 2015).


**Tabela 6.** Densidade do solo, volume de água em solo saturado (VASS), volume de água na capacidade de campo (VACC), volume de água em ponto de murcha permanente (VAMP), teores de argila, silte e carbono orgânico (CO) e pH do solo em água para os três locais do estudo.

<b>Entre Rios</b>								
Profundidade (cm)	Densidade (g cm <sup>-3</sup> )	VASS (cm <sup>3</sup> cm <sup>-3</sup> )	VACC (cm <sup>3</sup> cm <sup>-3</sup> )	VAMP (cm <sup>3</sup> cm <sup>-3</sup> )	Argila (%)	Silte (%)	CO (%)	pH
0-10	1,19	0,559	0,487	0,156	58,40	35,50	2,83	5,3
10-20	1,10	0,567	0,484	0,195	60,10	32,60	2,44	5,1
20-40	1,03	0,593	0,442	0,215	65,00	23,33	1,74	5,3
40-60	0,94	0,629	0,330	0,211	70,67	20,00	1,47	5,2
60-80	0,90	0,644	0,315	0,195	68,33	20,00	1,34	5,2
80-100	0,90	0,653	0,287	0,198	70,33	18,67	0,95	5,4
100-120	0,91	0,654	0,298	0,201	69,67	18,00	0,60	5,5
<b>Candói</b>								
0-10	0,97	0,567	0,550	0,148 <sup>1</sup>	57,60	35,10	3,60	5,6
10-20	1,02	0,501	0,490	0,203	60,40	33,00	3,20	5,0
20-40	0,92	0,575	0,553	0,218	73,10	22,60	1,98	5,3
<b>Pinhão</b>								
0-10	0,97	0,501	0,481	0,134 <sup>1</sup>	57,60	36,30	3,49	5,3
10-20	0,96	0,489	0,468	0,168	59,80	34,30	2,85	5,2
20-40	0,85	0,582	0,549	0,194	75,30	20,90	1,80	5,1

<sup>1</sup>: (IRI-MSU-IFPRI, 2015).

Quanto as informações meteorológicas, estas foram obtidas de estações automáticas instaladas pela FAPA nos locais dos ensaios e o conjunto de dados diário foi composto por temperaturas máximas e mínimas (°C), precipitação pluviométrica (mm) e radiação solar total (MJ m<sup>-2</sup> dia<sup>-1</sup>), como demonstrado na Figura 2.

Os dados dos ensaios, de solo e meteorológicos foram processados pelos softwares XBuild, SBuild e WeatherMan respectivamente, integrantes da plataforma DSSAT v.4.6.1.0, com a finalidade de organizar e padronizar os arquivos de entrada do modelo (Jones *et al.*, 2003).



**Figura 2.** Dados de temperatura do ar máximas e mínimas, precipitação pluviométrica e radiação solar de 2012 a 2017 no Distrito de Entre Rios, Guarapuava-PR.



#### 4.2.3. Calibração do modelo CSM-CROPGRO-Soybean

As informações dos ensaios conduzidos no Distrito de Entre Rios nas safras 2012/13, 2013/14, 2014/15 e 2015/2016 foram utilizadas para a calibração do modelo. Esse processo consistiu na manipulação dos coeficientes genéticos de cada cultivar (Tabela 7) e foi feito pelo processo de tentativa e erro, além do auxílio do software Genotype Coefficient Calculator (GENCALC v 2.0) (Hunt *et al.*, 1993) a partir do arquivo original de genótipos do DSSAT, para cultivares de soja dos grupos de maturação 5,0 e 6,0.

**Tabela 7.** Coeficientes genéticos do modelo CSM-CROPGRO-Soybean para sojas dos grupos de maturação 5,0 e 6,0 e os coeficientes modificados para as cultivares BMX Apolo RR, PRODUZA IPRO e TMG 7262 RR.

Coefficiente	Grupo 5,0	Grupo 6,0	BMX Apolo RR	PRODUZA IPRO	TMG 7262 RR
CSDL <sup>1</sup>	12,83	12,58	12,55	12,40	12,52
PPSEN	0,303	0,311	0,308	0,315	0,311
EM-FL	19,8	20,2	19,8	20,2	20,6
FL-SH	8,0	9,0	8,0	9,4	8,8
FL-SD	15,5	16,0	15,8	16,5	15,8
SD-PM	34,80	35,60	35,20	36,20	36,40
FL-LF	18,00	18,00	23,00	17,60	17,20
SFDUR	23,0	23,0	23,0	22,0	23,0
PODUR	10,0	10,0	10,0	9,5	10,0
LFMAX	1,030	1,030	1,030	1,055	1,070
SLAVAR	375,0	375,0	375,0	375,0	388,0
SIZLF	180,0	180,0	180,0	185,0	199,0
XFRT	1,00	1,00	1,00	1,00	1,00
WTPSD	0,18	0,18	0,208	0,240	0,230
SDPDV	2,05	2,05	2,25	2,25	2,25

<sup>1</sup>: CSDL - Comprimento crítico do dia, acima do qual o processo de desenvolvimento reprodutivo não é afetado (h); PPSSEN - Inclinação da resposta relativa do desenvolvimento para com o fotoperíodo (1/h); EM-FL - Período entre a emergência da planta e o aparecimento da primeira flor (dias fototermais); FL-SH - Período entre o aparecimento da primeira flor e o primeiro legume (dias fototermais); FL-SD - Período entre o aparecimento da primeira flor e o início da formação de grãos (dias fototermais); SD-PM - Período entre o início da formação de grãos e a maturidade fisiológica (dias fototermais); FL-LF - Período entre o aparecimento da primeira flor e o final da expansão foliar (dias fototermais); SFDUR - Duração do período de enchimento de grãos nas vagens em condições normais de desenvolvimento (dias fototermais); PODUR - Tempo necessário para a cultivar atingir condições ideais de legumes (dias fototermais); LFMAX - Taxa máxima de fotossíntese da folha em taxa ótima de temperatura (30 °C, 350 ppm CO<sub>2</sub>, alta luz) (mg CO<sub>2</sub> m<sup>-2</sup> s<sup>-1</sup>); SLAVAR - Área foliar específica sob condições de crescimento padrão (cm<sup>2</sup>); SIZLF - Tamanho máximo da folha completamente expandida (cm<sup>2</sup>); XFRT - Máxima fração do crescimento diário particionada para legume e grão; WTPSD - Peso máximo por grão (g); SDPDV - Número médio de grãos por vagem sob condições de crescimento padrão (unidade vagem<sup>-1</sup>).

Foram utilizados os valores iniciais do grupo de maturação 5,0 para calibração dos coeficientes genéticos da cultivar BMX APOLO RR e do grupo 6,0 para as cultivares PRODUZA IPRO e TMG7262 RR. O processo iniciou-se pelos coeficientes relacionados à

fenologia e desenvolvimento da cultura, seguido pelo ajuste dos coeficientes ligados à determinação da produtividade (Boote *et al.*, 2003; Mercau *et al.*, 2007), comparando-se os dados de desenvolvimento e produtividade observados com os resultados simulados pelo modelo.

#### 4.2.4. Avaliação do modelo CSM-CROPGRO-Soybean

Após ajustados os coeficientes genéticos das cultivares, a avaliação do modelo foi feita pela simulação do desenvolvimento da cultura, através dos períodos entre a data de semeadura e os estágios fenológicos de R1 (SR1) e maturação fisiológica R8 (SR8), e produtividade da soja, seguido pela comparação dos resultados simulados com os dados reais dos ensaios conduzidos na safra 2016/17 nos municípios de Cândói, Pinhão e no Distrito de Entre Rios-Guarapuava. Tanto para as informações de desenvolvimento quanto para a produtividade, para cada época de semeadura, foram utilizadas as médias das três densidades de semeadura, com três repetições em cada densidade, totalizando nove repetições.

A acurácia do modelo foi avaliada através da Raiz do Erro Quadrático Médio (REQM), conforme Wallach e Goffinet (1987) e também pela aplicação do índice de concordância  $d$  proposto por Willmott *et al.* (1985), cujas equações estão descritas abaixo.

$$REQM = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (2)$$

$$d = 1 - \left[ \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \right], 0 \leq d \leq 1 \quad (3)$$

Em que:  $REQM$  - raiz do erro quadrático médio;  $d$  - índice de concordância de Willmott;  $P_i$  - produtividade simulada para a  $i$ -ésima safra/local, em  $\text{kg ha}^{-1}$ ;  $O_i$  - produtividade observada na  $i$ -ésima safra/local, em  $\text{kg ha}^{-1}$ ;  $\bar{O}$  - média global das produtividades observadas, em  $\text{kg ha}^{-1}$ ;  $n$  - número de safras/local.

O REQM é a raiz do erro quadrático médio entre o valor predito e o real e quanto menor o seu valor mais acurado é o modelo. Sua unidade de medida é a mesma da característica simulada. Já o índice  $d$  é usado para determinar o grau relativo de concordância entre resultados simulados e observados e seu valor varia entre (0) e (1), em que “0” significa não haver concordância entre os dados e “1” há ajuste perfeito entre os valores reais e simulados (Willmott, 1982; Willmott *et al.*, 1985; Sas, 2011).

### 4.3. Resultados e discussão

#### 4.3.1. Calibração do modelo CSM-CROPGRO-Soybean

Os coeficientes genéticos ajustados para cada cultivar estão apresentados na Tabela 7. Esses coeficientes representam de forma numérica a constituição genotípica de cada cultivar, bem como sua expressão fenotípica em resposta aos diferentes ambientes, expressando todas as suas diferenças no que diz respeito ao ciclo de vida, distribuição e duração de cada estágio fenológico, índices de crescimento, distribuição de biomassa e processos reprodutivos (Boote *et al.*, 2003; Jones *et al.*, 2003).

Sua calibração tem por objetivo criar uma “cultivar *in silico*” que é capaz de responder as variações de clima, solo e manejo informadas ao modelo da mesma forma que a cultivar real responderia nas mesmas condições. Essas respostas são traduzidas nas informações de crescimento e desenvolvimento, taxa e partição de fotoassimilados, acúmulo de biomassa e produtividade.

Os dois primeiros coeficientes (CSDL e PPSN) traduzem a resposta da cultivar ao fotoperíodo do local de cultivo e seu ajuste afeta diretamente o resultado do ciclo total da cultura e também o momento do início da fase reprodutiva da cultura, interferindo drasticamente nos resultados das simulações, sendo de extrema importância que seu ajuste seja bem feito já nas etapas iniciais da calibração.

Para a cultivar BMX APOLO, apesar de pertencer ao grupo de maturação 5,0, conforme a descrição de seus obtentores (Brasmax, 2016), o coeficiente CSDL com melhor ajuste ficou no intervalo do grupo de maturação 6,0, em que simulou de maneira mais acurada o comportamento dessa cultivar nos diferentes ambientes de cultivo. Nas outras duas cultivares, o valor desse coeficiente ficou dentro do esperado para o grupo de maturação a que ambas pertencem.

Os cinco coeficientes que aparecem na sequência (EM-FL, FL-SH, FL-SD, SD-PM e FL-LF) trazem informações importantes quanto a duração de importantes fases do ciclo de vida da cultura e a obtenção do maior número possível dessas informações a partir dos ensaios é muito útil durante o processo de calibração do modelo. Para esses coeficientes, em todas as cultivares, os valores finais dos mesmos ficaram muito próximos aos originais fornecidos pelo modelo, evidenciando a solidez das informações já contidas na base de dados do programa.

Os coeficientes restantes, relacionados às taxas de crescimento e fotossíntese, bem como às estruturas reprodutivas, são os últimos a serem modificados, não afetando os valores

referentes ao ciclo de desenvolvimento, mas sendo essenciais para o ajuste fino da produtividade.


#### 4.3.2. Avaliação do modelo CSM-CROPGRO-Soybean

A avaliação do modelo CSM-CROPGRO-Soybean, após sua calibração, indica que o mesmo foi capaz de prever os resultados de desenvolvimento e produtividade com boa assertividade para as três cultivares de soja nos três locais de estudo.

A Figura 3 mostra o comparativo entre os resultados reais e simulados para o intervalo entre a semeadura e os estágios fenológicos de R1 (SR1) e R8 (SR8). Para o período SR1 os valores de REQM variaram entre 0,25 a 2,00 dias, enquanto que para SR8 esses valores oscilaram entre 0,35 e 2,99 dias. Já os valores do índice  $d$  variaram entre 0,97 e 0,99 para o período entre a semeadura e R1, e entre 0,99 e 1,00 para o intervalo entre a data de semeadura e R8. Esses valores indicam que os coeficientes genéticos relacionados ao desenvolvimento de cada cultivar foram bem ajustados, permitindo ao modelo simular com precisão o comportamento das três cultivares em todos os locais de estudo.

De acordo com Boote *et al.* (1996), o modelo CSM-CROPGRO-Soybean, por se tratar de um modelo mecanístico, tem alta capacidade de ler e traduzir as informações ambientais e relacioná-las com cada um de seus coeficientes genéticos, resultando em informações muito precisas no que diz respeito aos resultados de fenologia da cultura da soja. O extenso número de trabalhos científicos envolvidos em sua construção proporciona um ambiente consistente e estável para a realização de simulações de crescimento e desenvolvimento da soja e seus resultados, uma vez bem calibrado o modelo, podem ser utilizados de forma segura e confiável (Boote *et al.*, 1996; Boote *et al.*, 2003; Jones *et al.*, 2003; Hoogenboom *et al.*, 2010).

Para os resultados de produtividade, a performance do modelo CSM-CROPGRO-Soybean foi muito satisfatória, mostrando que o modelo possui alta capacidade em descrever os comportamentos das três cultivares nas diferentes épocas de semeadura em todos os locais do estudo, como se observa na Tabela 9. Os valores de REQM em Entre Rios variaram entre 18,26 e 284,94 kg ha<sup>-1</sup>, para as três cultivares, enquanto que para Candói e Pinhão esses valores ficaram entre 46,58 e 318,74 kg ha<sup>-1</sup> e 12,50 e 330,57 kg ha<sup>-1</sup>, respectivamente.



**Figura 3.** Número de dias observados e simulados entre as datas de semeadura e o estágio R1 (SR1) e R8 (SR8) para as três cultivares de soja, nos municípios de Pinhão, Candói e Distrito de Entre Rios-Guarapuava.

**Tabela 8.** Produtividade de soja observada e simulada pelo CSM-CROPGRO-Soybean na região Centro-Sul do Paraná, percentual de desvio (D), raiz do erro quadrático médio (REQM) e índice de concordância de Willmott ( $d$ ), em três épocas de semeadura (E1 - 10 a 15 de outubro, E2 - 10 a 15 de novembro, E3 - 10 a 15 de dezembro).

Entre Rios - Guarapuava-PR						
		Observada (kg ha <sup>-1</sup> )	Simulada (kg ha <sup>-1</sup> )	D (%) <sup>1</sup>	REQM (kg ha <sup>-1</sup> )	$d$
BMX APOLO	E1	5.672,7	5.976,3	5,35	18,26	0,90
	E2	6.232,3	5.802,0	-6,90	196,71	0,80
	E3	5.393,7	5.389,0	-0,09	21,63	1,00
PRODUZA IPRO	E1	6.717,3	6.597,0	-1,79	28,14	0,99
	E2	6.253,0	6.211,0	-0,67	42,13	1,00
	E3	5.888,0	5.720,0	-2,85	21,55	0,98
TMG7262 RR	E1	6.426,0	6.440,0	0,22	284,94	1,00
	E2	6.805,7	6.237,7	-8,35	93,56	0,84
	E3	5.710,0	5.654,3	-0,97	163,91	1,00
Candói-PR						
BMX APOLO	E1	6.314,3	6.172,5	-2,25	203,16	0,98
	E2	6.113,3	5.756,4	-5,84	67,72	0,90
	E3	5.542,7	5.500,2	-0,77	75,98	1,00
PRODUZA IPRO	E1	6.982,7	6.595,0	-5,55	318,74	0,94
	E2	6.503,0	6.285,2	-3,35	46,58	0,98
	E3	5.586,0	5.807,2	3,96	163,44	0,98
TMG7262 RR	E1	6.785,3	6.513,7	-4,00	151,94	0,96
	E2	6.517,0	6.387,5	-1,99	120,24	0,99
	E3	5.755,3	5.721,1	-0,59	123,10	1,00
Pinhão-PR						
BMX APOLO	E1	6.427,7	6.218,1	-3,26	132,02	0,96
	E2	6.288,7	5.962,0	-5,19	124,99	0,90
	E3	5.539,7	5.748,4	3,77	22,64	0,96
PRODUZA IPRO	E1	6.977,0	6.761,0	-3,10	12,50	0,97
	E2	6.830,0	6.577,6	-3,69	295,84	0,97
	E3	6.153,7	5.883,6	-4,39	150,41	0,96
TMG7262 RR	E1	6.529,7	6.672,9	2,19	330,57	0,99
	E2	6.826,0	6.512,7	-4,59	131,18	0,93
	E3	5.900,7	5.877,5	-0,39	13,80	1,00

Apesar de não haver critérios ou faixas de interpretação para o REQM, alguns autores propõem divisões ou intervalos para criar categorias de concordância entre os resultados simulados e os dados reais, como Mercau *et al.* (2007) e Liu *et al.* (2013), que propuseram a criação de faixas percentuais dos valores dos valores observados, sugerindo que valores de REQM menores que 15% dos dados reais indicam um bom ajuste do modelo, e que valores entre 15 e 30% sejam considerados ajustes moderados e valores superiores a 30% indicam uma baixa concordância entre dados reais e simulados. Considerando o maior valor de REQM para produtividade simulada (330,57 kg ha<sup>-1</sup>) e seu respectivo valor observado (6.529,7 kg ha<sup>-1</sup>), temos um valor percentual de 5,06%, indicando um excelente ajuste dos dados simulados pelo modelo.

Os valores do índice  $d$  também se mostram altos, variando entre 0,80 e 1,00, novamente evidenciando uma boa aderência entre os resultados simulados aos observados para as três cultivares nas diferentes épocas de semeadura e em todos os locais de estudo, estando de acordo com os resultados obtidos por outros autores que também utilizaram esse modelo, como Bhatia *et al.* (2008), Banterng *et al.* (2010) e Battisti *et al.* (2017).

O percentual de desvio (D), apresentado na Tabela 8, trata-se apenas de uma forma simplificada de visualização dos resultados, uma vez que mostra, em termos percentuais, a diferença entre o resultado simulado e observado e já foi utilizado por autores como Oliveira *et al.* (2012) e Rodrigues *et al.* (2012), para auxiliar na interpretação dos resultados. Valores negativos indicam que o modelo subestimou o resultado, enquanto que valores positivos tratam da superestimação dos mesmos. Esse índice mostra valores relativamente baixos para todas as simulações, oscilando entre 0,09 e 8,35 %, e em sua maioria negativos, evidenciando que o modelo, na maioria das previsões, subestimou os resultados em relação aos valores observados.

Considerando que todo o processo de calibração foi realizado utilizando os dados apenas de Entre Rios, com condições climáticas distintas dos outros dois locais de estudo, novamente o modelo se mostra muito capaz em realizar previsões de produtividade em condições diversas as do local original de calibração, reforçando sua consistência e versatilidade.

Tais condições climáticas podem ser observadas na Tabela 9, onde são comparadas às médias históricas do Distrito de Entre Rios, local onde os dados para a calibração foram coletados, mostrando as diferenças existentes entre as regiões de estudo.

Como todo o processo de calibração do modelo foi realizado utilizando as informações meteorológicas apenas do Distrito de Entre Rios e as simulações foram realizadas utilizando os dados de outras duas regiões distintas, essa variabilidade nas condições meteorológicas nas três localidades é um fator importante na avaliação do modelo, pois revela se de fato o mesmo é sensível a essas diferenças e se os coeficientes genéticos foram bem ajustados de modo que possam expressar em dados simulados o real comportamento das cultivares nesses ambientes.

Os modelos mecanísticos de crescimento de culturas, como o CSM-CROPGRO-Soybean, consideram em suas rotinas as leis físicas, químicas e biológicas que regem o comportamento dos processos aos quais se propõe a prever e buscam elucidar as relações de causa e efeito entre seus componentes. Da mesma forma que os modelos estatísticos, também demandam um grande volume de dados para que possam ser desenvolvidos em virtude da necessidade de se entender como cada mecanismo atua na resposta, entretanto, apresentam baixa restrição quanto à extrapolação e espacialização de suas projeções, sendo considerados

os mais versáteis entre os modelos matemáticos (Baier, 1979; Thornley e Johnson, 1990; Paustian *et al.*, 1992; Dourado Neto *et al.*, 1998; Corrêa *et al.*, 2011).

**Tabela 9.** Condições meteorológicas do ano 2016/17 observadas nos três locais de ensaio e normal climatológica do Distrito de Entre Rios-Guarapuava-PR durante a estação de cultivo da soja.

Local	Out	Nov	Dez	Jan	Fev	Mar	Abr
Temperatura máxima média (°C)							
Entre Rios	23,9	25,9	25,8	27,1	27,7	26,0	23,2
Candói	25,2	27,2	26,4	27,6	29,1	28,1	24,7
Pinhão	25,3	27,7	26,4	27,8	28,5	27,8	24,8
Média 1986/2015 <sup>2</sup>	23,5	25,2	26,1	26,0	25,6	25,4	23,9
Temperatura mínima média (°C)							
Entre Rios	11,1	12,8	15,1	16,1	16,1	14,9	12,2
Candói	13,1	14,0	16,2	17,7	17,2	16,2	13,1
Pinhão	12,8	13,5	16,1	16,6	17,0	15,5	12,8
Média 1986/2015 <sup>2</sup>	12,5	13,8	15,3	16,1	15,8	15,0	13,2
Precipitação acumulada (mm)							
Entre Rios	127,0	137,4	197,8	191,2	98,2	80,4	83,4
Candói	152,4	145,8	205,8	102,4	158,2	152,8	107,2
Pinhão	150,6	113,6	304,6	199,0	176,4	129,0	85,0
Média 1986/2015 <sup>2</sup>	224,5	158,4	186,7	209,5	176,0	149,2	156,9
Radiação solar (MJ m <sup>-2</sup> dia <sup>-1</sup> )							
Entre Rios	18,6	22,2	19,2	21,6	20,4	17,6	14,8
Candói	17,7	21,5	18,7	21,5	15,1	15,9	14,3
Pinhão	18,3	22,0	18,4	21,7	20,4	17,0	14,6
Média 2002/2017 <sup>1</sup>	18,5	21,5	21,6	22,1	20,6	19,1	15,8

<sup>1</sup>: Normal climatológica parcial - Entre Rios - Guarapuava-PR.

<sup>2</sup>: Normal climatológica de 30 anos - Entre Rios - Guarapuava-PR.

Fonte: Estações meteorológicas FAPA/SIMEPAR (2017).

Quando se trata da descrição matemática pura e simples de um sistema extremamente complexo como é o caso dos aspectos da fisiologia e biologia de determinada espécie e também do ambiente de produção agrícola, se corre o risco de não considerar todos os elementos envolvidos dentro desse sistema. Uma das etapas mais importantes antes da utilização de determinado modelo de simulação é a sua calibração e teste para as condições em que será aplicado, e isso requer um profundo conhecimento sobre o problema que se deseja estudar, envolvendo várias etapas para a sua devida calibração, como a coleta de dados em campo, considerações sobre variações espaciais e temporais no local de estudo e a qualidade dos dados de entrada (Boote *et al.*, 1996; Dourado Neto *et al.*, 1998; Corrêa *et al.*, 2011; Holzworth *et al.*, 2015).

No caso específico do CSM-CROPGRO-Soybean, um componente essencial para que as simulações sejam realizadas com acurácia é o módulo de solos. Esse componente é



representado por um perfil horizontalmente homogêneo, porém, variando verticalmente em diversas camadas, com espessuras variáveis conforme a forma de coleta do usuário da plataforma (Jones *et al.*, 2003). Mesmo com as informações reais do perfil de solo, o software oferece as opções de reorganiza-las de acordo com as especificações do próprio modelo ou utiliza-las de forma inalterada.

Para locais onde não é possível obter as informações reais de solo a plataforma DSSAT disponibiliza, em seus arquivos de suporte, valores estimados para cada camada de solo através de bases de dados internacionais detalhadas, como SOILGrids e ISRIC-WISE (Batjes, 2012; Hoogenboom, 2015; Iri-Msu-Ifpri, 2015), fornecendo as informações necessárias para estudos exploratórios ou em amplas extensões territoriais, como Mercau *et al.* (2007) e Johnston *et al.* (2015) utilizaram.

Todavia, a utilização de dados de entrada estimados pode influenciar os resultados das simulações e para contornar essa limitação alguns autores, como Dallacort *et al.* (2005), Banterng *et al.* (2010), Dallacort *et al.* (2011), Rodrigues *et al.* (2012) e Kleinwechter *et al.* (2016), optaram por utilizar os dados de um menor número de camadas de solo, porém, com as informações reais do local de estudo, buscando dessa forma aumentar a acurácia dos resultados sem comprometer a capacidade de simulação do modelo. Baseando-se nessa abordagem, os dados referentes aos perfis de solo dos municípios de Candói-PR e Pinhão-PR foram coletados em apenas três camadas, conforme Tabela 7, e o detalhamento do perfil do solo foi realizado em maior profundidade apenas no Distrito de Entre Rios-PR, local onde foram obtidos os dados para a calibração do modelo.

Outro aspecto importante a ser considerado quando se trata da abordagem da simulação de culturas é o fato de que os modelos não consideram a variabilidade espacial através das áreas para as quais se propõe as predições, considerando todo o cenário como uma replicação simples de idênticas condições de clima, solo e manejo, logo, a simples extrapolação dos resultados de uma região para outra pode resultar em erros consideráveis.

Uma forma de contornar esse problema seria a utilização de um sistema de informação geográfica (*Geographic Information System - GIS*) integrada ao modelo de simulação de culturas como forma de contornar a limitação espacial e temporal. A integração entre os modelos de GIS, fornecendo a perspectiva espacial ao estudo, e os modelos de simulação de culturas, representando os processos temporais, fornece as ferramentas para melhorar a acurácia e precisão das análises preditivas (Boote *et al.*, 1996; Heinemann *et al.*, 2002; Thorp *et al.*, 2005; Hodson e White, 2010; Corrêa *et al.*, 2011; Booker *et al.*, 2015; Chimonyo *et al.*, 2015; Holzworth *et al.*, 2015; Kadiyala *et al.*, 2015).

#### **4.4. Conclusões**

Os resultados obtidos no presente trabalho permitem concluir que os coeficientes genéticos do modelo CSM-CROPGRO-Soybean foram bem calibrados para as BMX APOLO RR, PRODUZA IPRO e TMG7262 RR, simulando coerentemente o desenvolvimento e produtividade da soja nos três locais do estudo.

A calibração é o processo mais importante para que o modelo possa ser utilizado com confiabilidade em simulações do desenvolvimento e produtividade da soja. Exige informações confiáveis e detalhadas para que os ajustes possam ser feitos adequadamente.

O modelo CSM-CROPGRO-Soybean mostrou-se uma ferramenta consistente e confiável, podendo ser usado com sucesso para simular o crescimento e o rendimento da soja para a região Centro-Sul do Paraná.

#### 4.5. Referências bibliográficas

ASSENS, S.; EWERT, F.; MARTRE, P.; ROTTER, R. P.; LOBELL, D. B.; CAMMARANO, D.; KIMBALL, B. A.; OTTMAN, M. J.; WALL, G. W.; WHITE, J. W.; REYNOLDS, M. P.; ALDERMAN, P. D.; PRASAD, P. V. V.; AGGARWAL, P. K.; ANOTHAI, J.; BASSO, B.; BIERNATH, C.; CHALLINOR, A. J.; DE SANCTIS, G.; DOLTRA, J.; FERERES, E.; GARCIA-VILA, M.; GAYLER, S.; HOOGENBOOM, G.; HUNT, L. A.; IZAURRALDE, R. C.; JABLOUN, M.; JONES, C. D.; KERSEBAUM, K. C.; KOEHLER, A. K.; MULLER, C.; NARESH KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. E.; PALOSUO, T.; PRIESACK, E.; EYSHI REZAEI, E.; RUANE, A. C.; SEMENOV, M. A.; SHCHERBAK, I.; STOCKLE, C.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; THORBURN, P. J.; WAHA, K.; WANG, E.; WALLACH, D.; WOLF, J.; ZHAO, Z.; ZHU, Y. Rising temperatures reduce global wheat production. **Nature Climate Change**, v. 5, n. 2, p. 143-147, 2015.

ASSENS, S.; ZHU, Y.; WANG, E.; ZHANG, W. Crop modeling for climate change impact and adaptation. In: (Ed.). **Crop Physiology: Applications for Genetic Improvement and Agronomy: Second Edition**: Elsevier Inc., 2014. p.505-546.

BAIER, W. Note on the terminology of crop-weather models. **Agricultural Meteorology**, v. 20, n. 2, p. 137-145, 1979.

BANTERNG, P.; HOOGENBOOM, G.; PATANOTHAI, A.; SINGH, P.; WANI, S. P.; PATHAK, P.; TONGPOONPOL, S.; ATICHART, S.; SRIHABAN, P.; BURANAVIRIYAKUL, S.; JINTRAWET, A.; NGUYEN, T. C. Application of the cropping system model (csm)-croprogro-soybean for determining optimum management strategies for soybean in tropical environments. **Journal of Agronomy and Crop Science**, v. 196, n. 3, p. 231-242, 2010.

BATJES, N. H. **ISRIC-WISE derived soil properties on a 5 by 5 arc-minutes global grid (ver. 1.2)**. ISRIC-World Soil Information. 2012

BATTISTI, R.; SENTELHAS, P. C.; BOOTE, K. J. Inter-comparison of performance of soybean crop simulation models and their ensemble in southern Brazil. **Field Crops Research**, v. 200, p. 28-37, 2017.

BHATIA, V. S.; SINGH, P.; WANI, S. P.; CHAUHAN, G. S.; RAO, A. V. R. K.; MISHRA, A. K.; SRINIVAS, K. 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.

BOOKER, J. D.; LASCANO, R. J.; MOLLING, C. C.; ZARTMAN, R. E.; ACOSTA-MARTÍNEZ, V. Temporal and spatial simulation of production-scale irrigated cotton systems. **Precision Agriculture**, v. 16, n. 6, p. 630-653, 2015.

BOOTE, K. J.; JONES, J. W.; BATCHELOR, W. D.; NAFZIGER, E. D.; MYERS, O. Genetic Coefficients in the CROPGRO-Soybean Model. **Agronomy Journal**, v. 95, n. 1, p. 32-51, 2003.

BOOTE, K. J.; JONES, J. W.; HOOGENBOOM, G. Simulation of crop growth: CROPGRO model. In: PEART, R. M. e CURRY, R. B. (Ed.). **Agricultural Systems Modeling and Simulation**. Boca Raton: CRC Press, 1997. p.651-692.

BOOTE, K. J.; JONES, J. W.; PICKERING, N. B. Potential uses and limitations of crop models. **Agronomy Journal**, v. 88, n. 5, p. 704-716, 1996.

BOUMA, J.; JONES, J. W. An international collaborative network for agricultural systems applications (ICASA). **Agricultural Systems**, v. 70, n. 2-3, p. 355-368, 2001.

BRASMAX. Genética. **Soja - Produto - BMX Apolo RR**, 2016. Disponível em: < <http://brasmaxgenetic.wpengine.com/cultivar-regiao-cerrado/?produto=970> >. Acesso em: 22 Abr. 2016.

CHALLINOR, A. J.; OSBORNE, T.; MORSE, A.; SHAFFREY, L.; WHEELER, T.; WELLER, H.; VIDALE, P. L. Methods and resources for climate impacts research. **Bulletin of the American Meteorological Society**, v. 90, n. 6, p. 836-848, 2009.

CHIMONYO, V. G. P.; MODI, A. T.; MABHAUDHI, T. Perspective on crop modelling in the management of intercropping systems. **Archives of Agronomy and Soil Science**, v. 61, n. 11, p. 1511-1529, 2015.

CORRÊA, S. T. R.; DOURADO NETO, D.; LORENÇONI, R.; SCARPARE, F. V.; VIVIAN, R.; RUIZ, E. T. Aplicações e limitações da modelagem em agricultura: Revisão. **Revista de Agricultura**, v. 86, n. 1, p. 1-13, 2011.

DALLACORT, R.; DE FREITAS, P. S. L.; FARIA, R. T.; GONCALVES, A. C. A.; REZENDE, R.; GUIMARÃES, R. M. L. Simulation of bean crop growth, evapotranspiration and yield in Paraná State by the CROPGRO-Drybean model. **Acta Scientiarum - Agronomy**, v. 33, n. 3, p. 429-436, 2011.

DALLACORT, R.; LOURENÇO DE FREITAS, P. S.; TEIXEIRA DE FARIA, R.; ANDRADE DE GONÇALVES, A. C.; REZENDE, R.; BERTONHA, A.; HELBEL JÚNIOR, C. Ajuste e teste dos coeficientes genéticos do modelo de simulação Cropgro-soybean, para a região Noroeste do Estado do Paraná. **Acta Scientiarum. Agronomy**, v. 27, n. 2, 2005.

DOURADO NETO, D.; TERUEL, D. A.; REICHARDT, K.; NIELSEN, D. R.; FRIZZONE, J. A.; BACCHI, O. O. S. Principles of crop modelling and simulation: the implications of the objective in model development. **Scientia Agricola**, v. 55, n. SPE, p. 51-57, 1998.

EMBRAPA. **Sistema brasileiro de classificação de solos**. 3 ed. Rio de Janeiro: Centro Nacional de Pesquisa de Solos, 2013.

FAO. Food And Agriculture Organization of the United Nations. **FAOSTAT Production Crops**, 2017. Disponível em: < <http://www.fao.org/faostat/en/#data/QC> >. Acesso em: 28 Dez. 2017.

FEHR, W. R.; CAVINESS, C. E. Stages of soybean development. **Iowa State University. Agricultural and Home Economics Experiment Station**, v. Special Edition 87, p. 1-12, 1977.

HEINEMANN, A. B.; HOOGENBOOM, G.; DE FARIA, R. T. Determination of spatial water requirements at county and regional levels using crop models and GIS: An example for the State of Parana, Brazil. **Agricultural Water Management**, v. 52, n. 3, p. 177-196, 2002.

HODSON, D.; WHITE, J. GIS and crop simulation modelling applications in climate change research. In: (Ed.). **Climate Change and Crop Production**: CABI Publishing, 2010. p.245-262. ISBN 9781845936334 (ISBN).

HOLZWORTH, D. P.; SNOW, V.; JANSSEN, S.; ATHANASIADIS, I. N.; DONATELLI, M.; HOOGENBOOM, G.; WHITE, J. W.; THORBURN, P. Agricultural production systems modelling and software: current status and future prospects. **Environmental Modelling and Software**, 2015.

HOOGENBOOM, G., J.W. JONES, P.W. WILKENS, C.H. PORTER, K.J. BOOTE, L.A. HUNT, U. SINGH, J.I. LIZASO, J.W. WHITE, O. URYASEV, R. OGOSHI, J. KOO, V. SHELIA, AND G.Y. TSUJI. **Decision Support System for Agrotechnology Transfer (DSSAT) Version 4.6 (<http://dssat.net>)**. DSSAT Foundation, Prosser, Washington. 2015.

HOOGENBOOM, G.; JONES, J. W.; PORTER, C. H.; WILKENS, P. W.; BOOTE, K. J.; HUNT, A. L.; TSUJI, G. Y. **DSSAT Version 4.5**. International Consortium for Agricultural Systems Applications: University of Hawaii, 2010.

HUNT, L. A.; PARARAJASINGHAM, S.; JONES, J. W.; HOOGENBOOM, G.; IMAMURA, D. T.; OGOSHI, R. M. GENCALC: Software to Facilitate the Use of Crop Models for Analyzing Field Experiments. **Agronomy Journal**, v. 85, n. 5, p. 1090-1094, 1993.

IRI-MSU-IFPRI. International Research Institute for Climate Society, Michigan State University, International Food Policy Research Institute-HarvestChoice. **Global High-Resolution Soil Profile Database for Crop Modeling Applications**, Harvard Dataverse, 2015.

JOHNSTON, R. Z.; SANDEFUR, H. N.; BANDEKAR, P.; MATLOCK, M. D.; HAGGARD, B. E.; THOMA, G. Predicting changes in yield and water use in the production of corn in the United States under climate change scenarios. **Ecological Engineering**, v. 82, p. 555-565, 2015.

JONES, J. W.; HOOGENBOOM, G.; PORTER, C. H.; BOOTE, K. J.; BATCHELOR, W. D.; HUNT, L. A.; WILKENS, P. W.; SINGH, U.; GIJSMAN, A. J.; RITCHIE, J. T. The DSSAT cropping system model. **European Journal of Agronomy**, v. 18, n. 3-4, p. 235-265, 2003.

KADIYALA, M. D. M.; NEDUMARAN, S.; SINGH, P.; S, C.; IRSHAD, M. A.; BANTILAN, M. C. S. An integrated crop model and GIS decision support system for assisting agronomic decision making under climate change. **Science of the Total Environment**, v. 521-522, p. 123-134, 2015.

KARL, T. R.; TRENBERTH, K. E. Modern global climate change. **Science**, v. 302, n. 5651, p. 1719-1723, 2003.

KLEINWECHTER, U.; GASTELO, M.; RITCHIE, J.; NELSON, G.; ASSENG, S. Simulating cultivar variations in potato yields for contrasting environments. **Agricultural Systems**, v. 145, p. 51-63, 2016.

KOTTEK, M.; GRIESER, J.; BECK, C.; RUDOLF, B.; RUBEL, F. World Map of the Köppen-Geiger climate classification updated. **Meteorologische Zeitschrift**, v. 15, n. 3, p. 259-263, 2006.

LIU, S.; YANG, J. Y.; ZHANG, X. Y.; DRURY, C. F.; REYNOLDS, W. D.; HOOGENBOOM, G. Modelling crop yield, soil water content and soil temperature for a soybean-maize rotation under conventional and conservation tillage systems in Northeast China. **Agricultural Water Management**, v. 123, p. 32-44, 2013.

LOBELL, D. B.; BURKE, M. B.; TEBALDI, C.; MASTRANDREA, M. D.; FALCON, W. P.; NAYLOR, R. L. Prioritizing climate change adaptation needs for food security in 2030. **Science**, v. 319, n. 5863, p. 607-610, 2008.

LOOMIS, R. S.; RABBINGE, R.; NG, E. Explanatory models in crop physiology. **Annual Review of Plant Physiology**, v. 30, n. 1, p. 339-367, 1979.

MAVROMATIS, T.; BOOTE, K. J.; JONES, J. W.; IRMAK, A.; SHINDE, D.; HOOGENBOOM, G. Developing genetic coefficients for crop simulation models with data from crop performance trials. **Crop Science**, v. 41, n. 1, p. 40-51, 2001.

MERCAU, J. L.; DARDANELLI, J. L.; COLLINO, D. J.; ANDRIANI, J. M.; IRIGOYEN, A.; SATORRE, E. H. Predicting on-farm soybean yields in the pampas using CROPGRO-soybean. **Field Crops Research**, v. 100, n. 2, p. 200-209, 2007.

OECD/FAO. **OECD-FAO Agricultural Outlook 2017-2026**. Paris: OECD Publishing, 2017. Disponível em: < [http://dx.doi.org/10.1787/agr\\_outlook-2017-en](http://dx.doi.org/10.1787/agr_outlook-2017-en) >.

OLIVEIRA, E. C. D.; COSTA, J. M. N. D.; JÚNIOR, P.; FERREIRA, W. P. M.; JUSTINO, F. B.; NEVES, L. D. O. The performance of the CROPGRO model for bean (*Phaseolus vulgaris* L.) yield simulation. **Acta Scientiarum. Agronomy**, v. 34, n. 3, p. 239-246, 2012.

PAUSTIAN, K.; PARTON, W. J.; PERSSON, J. Modeling soil organic matter in organic-amended and nitrogen-fertilized long-term plots. **Soil Science Society of America Journal**, v. 56, n. 2, p. 476-488, 1992.

RODRIGUES, R. D.; PEDRINI, J. E.; FRAISSE, C. W.; FERNANDES, J. M. C.; JUSTINO, F. B.; HEINEMANN, A. B.; COSTA, L. C.; DO VALE, F. X. R. Utilization of the cropgro-soybean model to estimate yield loss caused by Asian rust in cultivars with different cycle. **Bragantia**, v. 71, n. 2, p. 308-317, 2012.

SARKAR, R. Use of DSSAT to model cropping systems. **CAB Reviews: Perspectives in Agriculture, Veterinary Science, Nutrition and Natural Resources**, v. 4, p. 1-12, 2009.

SAS. **Base SAS® 9.3 Procedures Guide: Statistical Procedures**. Segunda Edição. Cary, NC: SAS Institute Inc, 2011.

SINCLAIR, T. R.; SELIGMAN, N. A. G. Crop modeling: from infancy to maturity. **Agronomy Journal**, v. 88, n. 5, p. 698-704, 1996.

THORNLEY, J. H.; JOHNSON, I. R. **A mathematical approach to plant and crop physiology**. Caldwell: The Blackburn Press, 1990.

THORP, K. R.; BATCHELOR, W. D.; PAZ, J. O. Programming ArcGIS to generate crop model input files for spatial simulations. 2005 ASAE Annual International Meeting, 2005, Tampa, FL. American Society of Agricultural and Biological Engineers.

THORP, K. R.; DEJONGE, K. C.; KALEITA, A. L.; BATCHELOR, W. D.; PAZ, J. O. Methodology for the use of DSSAT models for precision agriculture decision support. **Computers and Electronics in Agriculture**, v. 64, n. 2, p. 276-285, 2008.

VERHAGEN, A.; CONIJN, S.; SCHAPENDONK, A. **Quickscan of simulations models**. Wageningen: Wageningen UR, 2001.

WALLACH, D.; GOFFINET, B. Mean Squared Error of Prediction in Models for Studying Ecological and Agronomic Systems. **Biometrics**, v. 43, n. 3, p. 561-573, 1987.

WILLMOTT, C. J. Some Comments on the Evaluation of Model Performance. **Bulletin of the American Meteorological Society**, v. 63, n. 11, p. 1309-1313, 1982.

WILLMOTT, C. J.; ACKLESON, S. G.; DAVIS, R. E.; FEDDEMA, J. J.; KLINK, K. M.; LEGATES, D. R.; O'DONNELL, J.; ROWE, C. M. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, v. 90, n. C5, 1985.

## 5. CONSIDERAÇÕES FINAIS

O presente trabalho aborda duas formas distintas de simular o desenvolvimento e a produtividade da soja, o que possibilitou um aprendizado mais aprofundado sobre as técnicas empregadas na modelagem matemática de culturas.

Quando tratamos de modelos estatísticos, como o descrito no Capítulo I, o tamanho da base de dados inicial utilizada na construção do modelo é de fundamental importância. Nas primeiras etapas de seu desenvolvimento, a utilização de um grande número de variáveis, com a maior quantidade possível de observações para cada uma delas, é essencial para a escolha correta de quais componentes de fato tem influência sobre os resultados que se deseja simular.

Esse tipo de modelo utiliza uma abordagem que relaciona diretamente uma variável ou grupo de variáveis a um determinado resultado, nesse caso, a produtividade da soja em diferentes épocas de semeadura, e isso é possível devido ao grau de contribuição individual de cada variável para o modelo preditivo.

Como a seleção das variáveis componentes do modelo depende do tamanho da base de dados utilizada para a escolha das mesmas, sua capacidade de previsão fica restrita aos parâmetros impostos por essa base original. Por exemplo, para a construção do modelo estatístico foram utilizadas datas de semeadura que iam de 10 de outubro a 15 de dezembro. Isso permite que o modelo realize previsões do efeito de épocas de semeadura com boa acurácia apenas para esse intervalo de datas. Qualquer outro período de semeadura resultaria em valores simulados com um maior grau de erro.

Esse efeito no modelo construído no presente estudo é perfeitamente visível quando olhamos para a variável TMIN21EM. Seu coeficiente (-0,74484) indica que a diminuição nas temperaturas no período que antecede a emergência da cultura se traduz num aumento na produtividade. A simulação de uma época de semeadura em 15 de setembro resultaria numa produtividade maior do que a obtida em 10 de outubro, pois a temperatura é menor nesse período. Todavia, no modelo não estão considerados os efeitos negativos de baixas temperaturas ao desenvolvimento da soja, pois durante a construção do modelo, em nenhum momento se utilizou qualquer informação que indicasse esse efeito.

Como em seu desenvolvimento o modelo nunca “viu” essa situação na base de dados, sua capacidade em prever esse cenário fica comprometida e essa é, com certeza, a maior limitação de qualquer modelo estatístico.

Por outro lado, devido a simplicidade de sua construção, sua atualização e correção é uma tarefa mais simples. Após sua construção, à medida que mais dados são incluídos à base



de dados original, suas variáveis podem ser revistas e principalmente seus coeficientes podem ser reajustados, mantendo-o atualizado e confiável. A inclusão de novos cenários e situações a base de dados original também é uma alternativa para realizar essas correções, porém, são necessários experimentos à campo que gerem essas novas informações.

Quando analisamos o modelo mecanístico CSM-CROPGRO-Soybean, temos uma abordagem mais ampla e completa do desenvolvimento e produtividade da soja. Seus arquivos primários, bem como toda a sua estrutura mecanística, estão assentados em centenas de submodelos estatísticos, relacionando um grande número de variáveis meteorológicas, de solo, de manejo e da própria biologia da planta com respostas bioquímicas, processos fisiológicos, até finalmente culminar na produção e acúmulo de biomassa, partição de fotoassimilados e produção.

Os arquivos e informações relacionadas à meteorologia são bem simples, com inclusão da leitura direta de estações meteorológicas e ajustes apenas no formato e padronização dessa informação. As informações de fotoperíodo são calculadas automaticamente pelo programa com base nos dados de localização da estação meteorológica, assim como o cálculo de temperaturas médias, fornecendo somente os dados de temperaturas diárias máximas e mínimas.

Uma das informações iniciais mais importantes para o modelo diz respeito ao perfil de solo do local estudado. O CSM-CROPGRO-Soybean se revelou altamente sensível aos dados de solo informados ao programa e a utilização de estimativas dessas informações, fornecidas através de base de dados como SOILGrids e ISRIC-WISE pode comprometer os resultados quando divergem das informações reais do local.

Durante a calibração do modelo, a utilização da informação de um menor número de camadas no perfil de solo do que o exigido pelo software mostrou-se mais eficiente do que a utilização do perfil completo com informações estimadas. Como o CSM-CROPGRO-Soybean não extrapola os resultados de suas simulações, para cada local que se deseja utilizar o modelo há a necessidade das informações reais do perfil de solo, mesmo que de um número menor de camadas que as exigidas pelo software.

Essa abordagem abre as portas para a utilização conjunta do modelo com informações advindas do monitoramento e utilização de ferramentas de agricultura de precisão, utilizando um sistema de informação geográfica (*Geographic Information System* - GIS) integrada ao modelo de simulação de culturas como forma de contornar a limitação espacial, aumentando potencialmente a capacidade de uso do modelo.

A fase mais crítica antes de utilizar esse modelo de simulação é a sua calibração. No

presente trabalho foram analisados e trabalhados 15 coeficientes para o modelo, de um total de 18 disponíveis no programa. Os três últimos tratam de características qualitativas do grão de soja, como teores de óleo e proteínas e que não foram objeto de estudo nesse momento.

Para realizar a calibração foram utilizadas informações bem específicas do desenvolvimento da soja (datas de semeadura, R1 e R8) para cada cultivar, em um único local (Entre Rios), analisadas durante quatro safras agrícolas (2012/13 a 2015/16). O maior número de anos de coleta de dados é interessante para o desenvolvimento de um modelo estatístico, que depende desse grande número de informações, porém, no caso do CSM-CROPGRO-Soybean, a variabilidade entre os anos traz mais dificuldades para calibrar o modelo.

A partir do trabalho envolvido em sua calibração é possível afirmar que as informações de um único local e ano são mais que suficientes para extrair os valores mais corretos para cada coeficiente genético, desde que se utilize um maior número de dados do desenvolvimento da soja, detalhando cada estágio fenológico e fornecendo informações do crescimento e arquitetura de plantas, como índice de área foliar e área foliar específica.

Uma vez bem calibrado, o CSM-CROPGRO-Soybean pode ser considerado uma ferramenta poderosa no estudo e entendimento do desenvolvimento da cultura da soja. Sua estrutura permite uma série de simulações que podem envolver diferentes práticas de manejo, como épocas e densidades de semeadura, práticas de adubação e irrigação, efeitos de pragas e doenças, alterações em padrões climáticos e adaptação a diferentes regiões de cultivo.

Apesar das abordagens distintas ambos os modelos apresentam usos práticos e aplicáveis à agricultura na região Centro-Sul do Estado do Paraná e, respeitadas as limitações de cada um, ambos podem ser considerados como ferramentas contribuintes para os avanços nas práticas agronômicas na cultura da soja.

## APÊNDICES

### APÊNDICE A - Variáveis meteorológicas modificadas selecionadas na primeira fase de seleção.

Variável	Descrição	$\rho$	$p$
MHRAD28EM	Média do fotoperíodo diário 28 dias antes de VE	-0,71483	<0,0001
MHRAD21EM	Média do fotoperíodo diário 21 dias antes de VE	-0,71322	<0,0001
MHRAD7EM	Média do fotoperíodo diário 7 dias antes de VE	-0,70041	<0,0001
MHRAD14EM	Média do fotoperíodo diário 14 dias antes de VE	-0,69961	<0,0001
TMIN21EM	Média das temperaturas mínimas 21 dias antes de VE	-0,66426	<0,0001
TMIN14EM	Média das temperaturas mínimas 14 dias antes de VE	-0,65222	<0,0001
TMIN28EM	Média das temperaturas mínimas 28 dias antes de VE	-0,64240	<0,0001
TMIN7EM	Média das temperaturas mínimas 7 dias antes de VE	-0,61114	<0,0001
TMED28EM	Média das temperaturas médias 28 dias antes de VE	-0,55175	<0,0001
SRAIN14EM	Somatório da precipitação 14 dias antes de VE	-0,54010	<0,0001
TMED7EM	Média das temperaturas médias 7 dias antes de VE	-0,45142	<0,0001
TMED21EM	Média das temperaturas médias 21 dias antes de VE	-0,44384	<0,0001
SRAIN21EM	Somatório da precipitação 21 dias antes de VE	-0,42779	<0,0001
TMAX28FL	Média das temperaturas máximas 28 dias antes de R2	-0,42425	<0,0001
TMED28FL	Média das temperaturas máximas 28 dias antes de R2	-0,42167	<0,0001
SSRAD7FL	Somatório da radiação solar 7 dias antes de R2	-0,40569	<0,0001
SSRAD14FL	Somatório da radiação solar 14 dias antes de R2	-0,40544	<0,0001
SRAIN28EM	Somatório da precipitação 28 dias antes de VE	-0,39549	<0,0001
TMAX21FL	Média das temperaturas máximas 21 dias antes de R2	-0,38580	<0,0001
TMIN28FL	Média das temperaturas mínimas 28 dias antes de R2	-0,38328	<0,0001
SSRAD21FL	Somatório da radiação solar 21 dias antes de R2	-0,37926	<0,0001
TMED14EM	Média das temperaturas médias 14 dias antes de VE	-0,36713	<0,0001
TMED21FL	Média das temperaturas médias 21 dias antes de R2	-0,31694	<0,0001
TMED7MA	Média das temperaturas médias 7 dias antes de R8	-0,30299	<0,0001
TMAX14FL	Média das temperaturas máximas 14 dias antes de R2	-0,29918	<0,0001
TMAX7MA	Média das temperaturas máximas 7 dias antes de R8	-0,27718	<0,0001
SSRAD28MA	Somatório da radiação solar 28 dias antes de R8	-0,21311	<0,0001
SSRAD28FL	Somatório da radiação solar 28 dias antes de R2	-0,21037	<0,0001
SRAIN7EM	Somatório da precipitação 7 dias antes de VE	-0,19755	<0,0001
TMIN7MA	Média das temperaturas mínimas 7 dias antes de R8	-0,18523	<0,0001
SRAIN7FL	Somatório da precipitação 7 dias antes de R2	0,17759	<0,0001
TMED28MA	Média das temperaturas médias 28 dias antes de R8	0,17819	<0,0001
TMAX28MA	Média das temperaturas máximas 28 dias antes de R8	0,17914	<0,0001
TMIN14FL	Média das temperaturas mínimas 14 dias antes de R2	0,27600	<0,0001
SRAIN7MA	Somatório da precipitação 7 dias antes de R8	0,29719	<0,0001
SRAIN14FL	Somatório da precipitação 14 dias antes de R2	0,30621	<0,0001
SSRAD28EM	Somatório da radiação solar 28 dias antes de VE	0,31576	<0,0001
SRAIN21FL	Somatório da precipitação 21 dias antes de R2	0,31952	<0,0001
SSRAD14EM	Somatório da radiação solar 14 dias antes de VE	0,32191	<0,0001
TMED7FL	Média das temperaturas médias 7 dias antes de R2	0,32398	<0,0001
TMIN28MA	Média das temperaturas mínimas 28 dias antes de R8	0,34313	<0,0001
SSRAD21EM	Somatório da radiação solar 21 dias antes de VE	0,35382	<0,0001
SRAIN28FL	Somatório da precipitação 28 dias antes de R2	0,35413	<0,0001
TMIN7FL	Média das temperaturas mínimas 7 dias antes de R2	0,43419	<0,0001
MHRAD28FL	Média do fotoperíodo diário 28 dias antes de R2	0,43788	<0,0001
SSRAD7EM	Somatório da radiação solar 7 dias antes de VE	0,47241	<0,0001
MHRAD7MA	Média do fotoperíodo diário 7 dias antes de R8	0,49589	<0,0001
MHRAD14MA	Média do fotoperíodo diário 14 dias antes de R8	0,49658	<0,0001
MHRAD21MA	Média do fotoperíodo diário 21 dias antes de R8	0,49658	<0,0001
MHRAD28MA	Média do fotoperíodo diário 28 dias antes de R8	0,49737	<0,0001
MHRAD21FL	Média do fotoperíodo diário 21 dias antes de R2	0,57712	<0,0001
MHRAD14FL	Média do fotoperíodo diário 14 dias antes de R2	0,64685	<0,0001
MHRAD7FL	Média do fotoperíodo diário 7 dias antes de R2	0,66538	<0,0001

**APÊNDICE B - Variáveis meteorológicas transformadas.**

<b>Linear</b>	<b>Quadrática</b>	<b>Cúbica</b>	<b>Logarítmica</b>	<b>Inversa</b>
MHRAD28EM	$(\text{MHRAD28EM})^2$	$(\text{MHRAD28EM})^3$	(Log MHRAD28EM)	$(1/\text{MHRAD28EM})$
TMIN21EM	$(\text{TMIN21EM})^2$	$(\text{TMIN21EM})^3$	(Log TMIN21EM)	$(1/\text{TMIN21EM})$
TMED28FL	$(\text{TMED28FL})^2$	$(\text{TMED28FL})^3$	(Log TMED28FL)	$(1/\text{TMED28FL})$
SSRAD14FL	$(\text{SSRAD14FL})^2$	$(\text{SSRAD14FL})^3$	(Log SSRAD14FL)	$(1/\text{SSRAD14FL})$
SRAIN21FL	$(\text{SRAIN21FL})^2$	$(\text{SRAIN21FL})^3$	(Log SRAIN21FL)	$(1/\text{SRAIN21FL})$