**Universidade de São Paulo
Escola Superior de Agricultura 'Luiz de Queiroz'**

Modelos de simulação da cultura do milho: uso na determinação das quebras de produtividade (*Yield Gaps*) e na previsão de safra da cultura no Brasil

Yury Catalani Nepomuceno Duarte

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

**Piracicaba
2018**

Yury Catalani Nepomuceno Duarte
Engenheiro Agrônomo

**Modelos de simulação da cultura do milho – uso na determinação das quebras de
produtividade (*Yield Gaps*) e na previsão de safra da cultura no Brasil**
versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof Dor **PAULO CESAR SENTELHAS**

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

Piracicaba
2018

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

Duarte, Yury Catalani Nepomuceno

Modelos de simulação da cultura do milho – uso na determinação das quebras de produtividade (*Yield Gaps*) e na previsão de safra da cultura no Brasil / Yury Catalani Nepomuceno Duarte - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2018.

197 p.

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

1. Milho 2. Modelos de simulação de cultura 3. Multi-modelos 4. Previsão de safra 5. *Yield gap* I. Título

AGRADECIMENTOS

Em meio a essa mistura de euforia e alívio, digna de um ciclista que acaba de completar o último dia de prova no *Tour de France*, escrevo aqui minhas palavras de gratidão a todo esse período de estudo e desenvolvimento do presente projeto de mestrado.

Dentre todos os tropeços, dificuldades e vacilos, os frutos colhidos são de aprendizado, amadurecimento pessoal e novas amizades. Não posso deixar de agradecer aos meus pais, Eliete e Alex, e a minha irmã Nathalia, por toda a confiança e apoio incondicional. Espero um dia poder servir de exemplo e contribuir com alguém assim como vocês fizeram por mim.

Agradeço ao professor, orientador e amigo Paulão, sempre presente e dando apoio não apenas nas questões acadêmicas, mas em diversas outras esferas da vida. Agradeço também a CAPES, pelo apoio financeiro, essencial para o desenvolvimento do projeto, a Ana, pela companhia e apoio, principalmente durante esses meses finais e, como não poderia deixar de ser, agradeço a todos os amigos que de alguma forma contribuíram ao longo dessa jornada: Galiña; Nãr-c; Édiño; Tchê; Fernandão; Pino; Fabi; Gustavo; Battisti; Cristiam (e a todo o pessoal da cúpula); Lucão; Qñé; K-pa; Rep. Kazinsky e também a família Xapadão, que me proporcionou experiências únicas e muito contribuiu para meu desenvolvimento pessoal,

Agradeço.

Sumário

RESUMO.....	7
ABSTRACT	9
1. INTRODUÇÃO GERAL	11
1.1. INTRODUÇÃO E JUSTIFICATIVA	11
1.2. OBJETIVOS	12
1.3. REVISÃO DE LITERATURA	13
1.3.1. <i>A cultura do milho</i>	13
1.3.1.1. Fenologia e desenvolvimento	13
1.3.1.2. Exigências climáticas	15
1.3.1.3. Produção brasileira e mundial	21
1.3.2. <i>Modelos de simulação de culturas</i>	24
1.3.2.1. Uso de modelos de simulação na cultura do milho e estimação da produtividade.....	25
1.3.2.1.1. Modelo da Zona Agroecológica – FAO (MZA-FAO).....	25
1.3.2.1.2. <i>Decision Support System for Agrotechnology Transfer</i> (DSSAT).....	27
1.3.2.1.3. <i>Agricultural Production Systems sIMulator</i> (APSIM)	31
1.3.2.2. Determinação da produtividade potencial e atingível	33
1.3.2.3. Aplicação dos modelos de simulação de culturas na determinação das quebras de produtividade (<i>Yield Gaps</i>)	34
1.3.2.4. Aplicação dos modelos de simulação de culturas para a projeção e a previsão de safra.....	36
REFERÊNCIAS.....	37
2. AVALIAÇÃO DE DADOS METEOROLÓGICOS EM PONTO DE GRADE E SEUS IMPACTOS NA ESTIMAÇÃO DA PRODUTIVIDADE POTENCIAL DA CULTURA DO MILHO.....	49
RESUMO.....	49
ABSTRACT	49
2.1. INTRODUÇÃO	50
2.2. MATERIAL E MÉTODOS	53
2.3. RESULTADOS E DISCUSSÃO.....	57
2.3.1. <i>Variáveis meteorológicas</i>	57
2.3.2. <i>NASA/POWER x INMET</i>	57
2.3.3. <i>INMET x DailyGridded</i>	62
2.4. IMPACTO DOS DADOS METEOROLÓGICOS EM PONTO DE GRADE NA ESTIMAÇÃO DA PRODUTIVIDADE POTENCIAL DA CULTURA DO MILHO	66
2.4.1. <i>INMET x NASA/POWER</i>	66
2.4.2. <i>INMET x DailyGridded</i>	69
2.5. CONCLUSÕES	71

REFERÊNCIAS.....	72
3. CALIBRAÇÃO E AVALIAÇÃO DE TRÊS MODELOS DE SIMULAÇÃO DA CULTURA DO MILHO E SUAS COMBINAÇÕES PARA ESTIMAÇÃO DA PRODUTIVIDADE.....	75
RESUMO.....	75
ABSTRACT	75
3.1. INTRODUÇÃO	76
3.2. MATERIAL E MÉTODOS	78
3.2.1. <i>Dados climáticos.....</i>	78
3.2.2. <i>Dados de solo.....</i>	79
3.2.3. <i>Dados de produtividade.....</i>	81
3.2.4. <i>Modelos de simulação da cultura do milho.....</i>	82
3.2.4.1. <i>Modelo da zona agroecológica da FAO (MZA-FAO)</i>	82
3.2.4.2. <i>Modelo DSSAT CERES-Maize</i>	85
3.2.4.3. <i>Modelo APSIM-Maize</i>	87
3.2.5. <i>Calibração, avaliação e combinação dos modelos (ensemble).....</i>	89
3.3. RESULTADOS E DISCUSSÃO	90
3.3.1. <i>Calibração dos modelos.....</i>	90
3.3.2. <i>Avaliação dos modelos</i>	92
3.4. CONCLUSÕES	98
REFERÊNCIAS.....	99
4. DEFINIÇÃO DA ÉPOCA PREFERENCIAL DE SEMEADURA E PREVISÃO DE PRODUTIVIDADE DA CULTURA DO MILHO EM DIFERENTES LOCALIDADES BRASILEIRAS, COM BASE NO USO DE MODELOS DE SIMULAÇÃO.....	107
RESUMO.....	107
ABSTRACT	108
4.1. INTRODUÇÃO	108
4.2. MATERIAL E MÉTODOS	112
4.2.1. <i>Localidades do estudo</i>	112
4.2.2. <i>Dados meteorológicos.....</i>	113
4.2.3. <i>Dados de solo.....</i>	113
4.2.4. <i>Avaliação da influência das épocas de semeadura na produtividade da cultura do milho em diferentes localidades brasileiras</i>	114
4.2.5. <i>Previsão da produtividade do milho safra e safrinha para diferentes localidades do Brasil</i>	114
4.3. RESULTADOS E DISCUSSÃO	116
4.3.1. <i>Influência das épocas de semeadura na produtividade da cultura do milho em diferentes localidades do Brasil.....</i>	116
4.3.2. <i>Previsão da produtividade da cultura do milho safra e safrinha para diferentes localidades do Brasil</i>	123
4.4. CONCLUSÕES	133
REFERÊNCIAS.....	135
5. PRODUTIVIDADE E YIELD GAP DA CULTURA DO MILHO DA SAFRA E DA SAFRINHA NO BRASIL.....	141

RESUMO.....	141
ABSTRACT	141
5.1. INTRODUÇÃO.....	142
5.2. MATERIAL E MÉTODOS	145
5.2.1. <i>Locais Estudados</i>	145
5.2.2. <i>Dados Meteorológicos</i>	146
5.2.3. <i>Dados de Solo</i>	147
5.2.4. <i>Dados de Produtividade Real (PR)</i>	147
5.2.5. <i>Estimação das produtividades potencial e atingível para a cultura do milho no Brasil</i>	147
5.2.6. <i>Interpolação e mapeamento das produtividades potencial e atingível da cultura do milho no Brasil</i>	148
5.2.7. <i>Determinação e mapeamento dos níveis dos diferentes Yield Gaps (YG) para a cultura do milho no Brasil</i>	149
5.3. RESULTADOS E DISCUSSÃO.....	149
5.3.1. <i>Mapeamento das produtividades potencial (PP), atingível (PA), real (PR) e do yield gap (YG) da cultura do milho no Brasil</i>	149
5.3.1.1. <i>Desempenho dos métodos de interpolação das produtividades potencial e atingível</i>	149
5.3.1.2. <i>Produtividades potencial (PP) e atingível (PA) do milho no Brasil</i>	150
5.3.1.3. <i>Yield gaps (YG) da cultura do milho no Brasil</i>	158
5.4. CONCLUSÕES	171
REFERÊNCIAS.....	173
ANEXO A. PERFIS DOS SOLOS UTILIZADOS NAS SIMULAÇÕES	176
ANEXO B. INFLUÊNCIA DAS ÉPOCAS DE SEMEADURA NA PRODUTIVIDADE DA CULTURA DO MILHO EM DIFERENTES LOCALIDADES DO BRASIL	178
ANEXO C. PREVISÃO DA PRODUTIVIDADE DA CULTURA DO MILHO SAFRA E SAFRINHA PARA DIFERENTES LOCALIDADES DO BRASIL	188

RESUMO

MODELOS DE SIMULAÇÃO DA CULTURA DO MILHO – USO NA DETERMINAÇÃO DAS QUEBRAS DE PRODUTIVIDADE (*YIELD GAPS*) E NA PREVISÃO DE SAFRA DA CULTURA NO BRASIL

Sendo o cereal mais produzido no mundo e em larga expansão, os sistemas de produção de milho são altamente complexos e sua produção é diretamente dependente de fatores ligados tanto ao clima local quanto ao manejo da cultura. Para auxiliar na determinação tanto dos patamares produtivos de milho quanto quantificar o impacto causado por condições adversas tanto de clima quanto de manejo, pode-se lançar mão do uso de modelos de simulação de culturas. Para que os modelos possam ser devidamente aplicados, uma base sólida de dados meteorológicos deve ser consistida, a fim de alimentar esses modelos. Nesse sentido, o presente estudo teve como objetivos: i) avaliar dois sistemas de obtenção de dados meteorológicos, o NASA-POWER e o *DailyGridded*, comparando-os com dados medidos em estações de solo; ii) calibrar, testar e combinar os modelos de simulação MZA-FAO, CSM DSSAT Ceres-Maize e APSIM-Maize, a fim de estimar as produtividades potenciais e atingíveis do milho no Brasil; iii) avaliar o impacto na produtividade causado pelo posicionamento da semeadura em diferentes tipos de solo; iv) desenvolver e avaliar um sistema de previsão de safra baseado em modelos de simulação; v) mapear as produtividades potencial, atingível e real do milho no Brasil, identificando regiões mais aptas ao cultivo e vi) determinar e mapear as quebras de produtividade, ou *yield gaps* (YG) da cultura do milho no Brasil. Comparando os dados climáticos dos sistemas em ponto de grade com os dados de estações meteorológicas de superfície, na escala diária, encontrou-se boa correlação entre as variáveis meteorológicas, inclusive para a chuva, com R^2 da ordem de 0,58 e índice $d = 0,85$. O desempenho da combinação dos modelos ao final da calibração e ajuste se mostrou superior ao desempenho dos modelos individuais, com erros absolutos médios relativamente baixos ($EAM = 627 \text{ kg ha}^{-1}$) e com boa precisão ($R^2 = 0,62$) e ótima acurácia ($d = 1,00$). Durante a avaliação da influência das épocas de semeadura e do tipo de solo no patamar produtivo do milho, observou-se que esse varia de acordo com a região estudada e apresenta seus valores máximos e com menores riscos à produção quando a semeaduras coincidem com o início do período de chuvas do local. O sistema de previsão de safra, baseado em modelos de simulação de cultura teve seu melhor desempenho simulando produtividades de milho semeados no início da safra e no final da safrinha, sendo capaz de prever de forma satisfatória a produtividade com até 25 dias antes da colheita. Para o estudo dos YGs, 152 locais foram avaliados e suas produtividades potenciais e atingíveis foram comparadas às produtividades reais, obtidas junto ao IBGE. Os maiores YGs referentes ao déficit hídrico se deram em solos arenosos e durante os meses de outono e inverno, usualmente mais secos na maioria das regiões brasileiras, atingindo valores de quebra superiores a 12000 kg ha^{-1} . Quanto ao YG causado pelo manejo, esse foi maior nas regiões menos tecnificadas, como na região Norte e na Nordeste,

apresentando valores superiores a 6000 kg ha⁻¹. Já as regiões mais tecnificadas e tradicionais na produção de milho, como a região Sul e a Centro-Oeste, os YGs referentes ao manejo foram inferiores a 3500 kg ha⁻¹ na maioria dos casos.

Palavras-chave: Milho; Modelos de simulação de culturas; Multi-modelos; Previsão de safra; *Yield gap*

ABSTRACT

MAIZE SIMULATION MODELS - USE TO DETERMINE YIELD GAPS AND YIELD FORECASTING IN BRAZIL

Maize is the most important cereal cultivated in the world, being its production system very complex and its productivity directly affected by climatic and crop management factors. In order to quantify the impacts caused by water and crop management deficits on maize yield, the use of crop simulation models is very useful. For properly apply these models, a solid basis of meteorological data is required. In this sense, the present study had as objectives: i) to evaluate two meteorological gridded data, NASA-POWER and DailyGridded, by comparing them with measured data from surface stations; (ii) to calibrate, evaluate and combine the MZA-FAO, CSM DSSAT Ceres-Maize and APSIM-Maize simulation models to estimate the maize potential and attainable yields in Brazil; (iii) to evaluate the impact caused by the different sowing dates and soil types on maize yield; iv) to develop and evaluate a crop forecasting system based on crop simulation models and climatological data; v) to map the potential and the attainable maize yields in Brazil, identifying the most suitable regions for cultivation, and vi) to determine and map maize yields and yield gaps (YG) in Brazil. Comparing the gridded climatic data with observed ones, on a daily basis, a good agreement was found for all weather variables, including rainfall, with $R^2 = 0.58$ and $d = 0,85$. The performances of the combination of the models at the end of the calibration and evaluation phases were better than those obtained with the individual models, with relatively low mean absolute error (EAM = 627 kg ha⁻¹) and with good precision ($R^2 = 0.62$) and accuracy ($d = 1.00$). During the evaluation of different sowing dates and soil types on maize yield, it was observed that this variable depends on the region and presents the maximum values and, consequently, the minimum risk during the sowings in the beginning of the rainy season of each site. The crop forecasting system, based on crop simulation models, had its best performance for simulating maize yields when the sowings were performed at the beginning of the main season and at the end of the second season, when it was able to predict yield satisfactorily 25 days before harvest. For the YG analysis, 152 sites were assessed and their potential and attainable yields were compared to the actual yields reported by IBGE. The highest YGs caused by water deficit occurred for sandy soils and during the autumn and winter months, usually dry in most of Brazilian regions, reaching values above 12000 kg ha⁻¹. For YG caused by crop management, the values were higher in the less technified regions, such as in the North and Northeast regions, with values above 6000 kg ha⁻¹. In contrast, more traditional maize production regions, such as the South and Center-West, presented YG caused by crop management, lower than 3500 kg ha⁻¹ in most cases.

Keywords: Maize; Crop simulation models; Ensemble; Yield forecasting; Yield gap

1. INTRODUÇÃO GERAL

1.1. Introdução e justificativa

Visto o crescente aumento da população mundial e, conseqüentemente, o aumento da demanda dessa por alimentos, se faz necessário também o aumento das produções agropecuárias, dentre essas a do milho. Entretanto, existem entraves quanto à expansão das áreas agrícolas, devido à limitação de terras amplamente aptas e também às questões ambientais e sociais. Assim, a principal forma de se suprir a necessidade de mais alimentos é aumentar os patamares das produtividades agrícolas, por meio do aumento da eficiência dos sistemas de produção, reduzindo seus custos e os impactos ambientais gerados pela abertura de novas áreas.

Considerando o que foi exposto e também os baixos níveis de produtividade obtidos pela cultura do milho nos polos produtores do Brasil, torna-se importante avaliar os potenciais produtivos e identificar as principais causas das baixas eficiências agrícolas, climáticas ou por manejo. Para isso, os modelos de simulação da cultura do milho podem ser empregados de modo a auxiliar na identificação desses potenciais produtivos, visando a otimização da produção agrícola.

Dessa forma, o presente estudo tem como hipótese principal que os modelos de simulação de culturas, quando bem calibrados, podem auxiliar na identificação dos principais fatores limitantes e redutores da produtividade agrícola, permitindo traçar estratégias para minimização das perdas de produtividade da cultura do milho e, uma vez disponíveis e calibrados, esses modelos possam auxiliar na previsão de safra, por meio da combinação de dados meteorológicos observados e históricos.

1.2. Objetivos

Sendo assim, os objetivos deste projeto são:

- a) Comparar diferentes fontes de dados meteorológicos com dados medidos a fim de validá-los para então criar estações meteorológicas 'virtuais';
- b) Calibrar e testar 3 modelos de simulação da cultura do milho: Agroecological Zone-FAO, CSM-Ceres-*Maize* e APSIM-*Maize*, para poder estimar as produtividades potencial e atingível dessa cultura;
- c) Determinar as produtividades potencial e atingível da cultura do milho nas diferentes regiões produtoras no Brasil, por meio do uso de modelos de simulação, a fim de elaborar mapas que permitem expressar suas variabilidades espaciais;
- d) Avaliar um sistema de previsão de safra da cultura do milho para algumas regiões produtoras do Brasil, com base em modelos de simulação da cultura e do uso de dados meteorológicos históricos, a fim de definir com quanto tempo de antecedência seria possível prever a produtividade atingível da cultura e
- e) Determinar as perdas de produtividade (*yield gaps*) da cultura do milho no Brasil, decorrentes do déficit hídrico e do manejo agrícola.

1.3. Revisão de literatura

1.3.1. A cultura do milho

1.3.1.1. Fenologia e desenvolvimento

O milho pertence a ordem *Gramineae*, família *Poaceae*, gênero *Zea* e espécie *Zea mays* L. Sua semente é do tipo cariopse, característico das gramíneas, e é dividida em: Pericarpo - oriundo da parede do ovário, pode assumir diversas cores e apresenta alta resistência; Endosperma - representa a maior parte do volume do grão de milho, é triploide (dois núcleos femininos e um masculino) e constituído basicamente de amido; e Embrião – não armazenam reservas e possui o primórdio de todos os órgãos da planta (Magalhães e Souza, 2011 e Barros e Calado, 2014).

Seu sistema radicular é do tipo fasciculado, podendo atingir mais de um metro de profundidade e acumular massa superior a 40 Mg ha⁻¹. A radícula da origem a raiz primária, que se aprofunda verticalmente até o aparecimento das raízes secundárias, com grande potencial de ramificação. Num estágio mais avançado do desenvolvimento da planta de milho, essa apresenta raízes adventícias, de suma importância para a estruturação da planta adulta, que partem dos primeiros nós do colmo e se ramificam com intensidade quando atingem o solo. Seu colmo é ereto, podendo ultrapassar os 2 m de altura, dificilmente sofre ramificação e tem função de acumular reservas em forma de sacarose (Barros e Calado, 2014).

As folhas do milho são classificadas como completas, possuindo limbo piloso, pecíolo e bainha e são dispostas de forma alternada. Seu comprimento é muito superior à sua largura, num formato de lança (lanceolado). Tem a inflorescência masculina separada da feminina (monoica). A inflorescência masculina é agrupada em panícula, situada no topo do colmo. Por aparecer antes da inflorescência feminina, o milho é classificado como uma planta protândrica. Cada flor masculina é composta por três estames que podem produzir pólen por até oito dias. Já a inflorescência feminina é designada de espiga, constituída por um eixo aonde se dispõe os alvéolos e as espiguetas aos pares. Cada espiguetas é formada por duas flores, uma fértil e uma estéril e cada flor possui um estilo-estigma, que é de extrema importância para que a fecundação tenha sucesso (Barros e Calado, 2014).

Para facilitar o estudo da cultura, Hanway (1963) fez uma descrição da fenologia do milho que se tornou a mais utilizada no mundo. Ele elaborou uma sequência de acontecimentos no desenvolvimento da planta, numerados em ordem crescente, de forma simples e clara. Em 1986, Fancelli fez alterações na clássica descrição de Hanway, acrescentando uma duração média de dias para os eventos descritos por Hanway e uma representação gráfica do desenvolvimento da cultura ao longo do tempo. A Tabela 1.1 apresenta a escala fenológica de Hanway (1963), adaptada por Fancelli (1986), e a Figura 1.1 ilustra sua representação esquemática.

Tabela 1.1. Estádios fenológicos do milho descrita por Hanway (1963) e adaptada por Fancelli (1986)

Estádio fenológico	Descrição do evento	Tempo decorrido
0	Germinação	0 dias
1	Emergência	0 dias
2	Quatro folhas abertas	2 semanas após emergência
3	Oito folhas abertas	4 semanas após emergência
4	Doze folhas abertas	6 semanas após emergência
5	Pendoamento	8 semanas após emergência
6	Florescimento (espigamento)	9-10 semanas após emergência
7	Grãos leitosos	12 dias após polinização
8	Grãos pastosos	24 dias após polinização
9	Grãos farináceos	36 dias após polinização
10	Grãos duros	48 dias após polinização
11	Maturidade fisiológica	55 dias após polinização

No início dos anos 90, uma nova escala fenológica foi apresentada, com maior detalhamento, principalmente da fase vegetativa, além de uma representação dos eventos por letras e números, facilitando a identificação de cada etapa. A Tabela 1.2 apresenta a descrição feita por Ritchie et al. (1993).

Figura 1.1. Estádios fenológicos de uma planta de milho, com suas respectivas durações. Fonte: Fancelli, 1986

Tabela 1.2. Escala fenológica do milho descrita por Ritchie et al. (1993) e Hanway (1963)

Fase	Ritchie et al. (1993)	Hanway (1963)
Vegetativa	VE – Emergência	0
	V1- uma folha aberta	-
	V4 – quatro folhas abertas	1
	V12 – doze folhas abertas	3
	Vn – n folhas abertas	-
	VT – pendoamento	4
Reprodutiva	R1 – espigamento	5
	R2 – grão em bolha	-
	R3 – grão leitoso	6
	R4 – grão pastoso	7
	R5 – grão dentado	-
	R6 – maturidade fisiológica	10

1.3.1.2. Exigências climáticas

Por ser uma planta de metabolismo C4, o milho tem uma grande eficiência em realizar fotossíntese e converter essa em biomassa, o que possibilita à cultura atingir patamares de produtividade superiores a 10 Mg ha⁻¹ (Bergamaschi, 2004; Liu et al., 2012pe).

Esse tipo de metabolismo é caracterizado por um sistema de captura de CO_2 e concentração de malato nas células do mesofilo. O malato passa através da barreira de difusão até as células da bainha vascular, onde ocorre a sua descarboxilação, liberando CO_2 no sítio ativo da rubisco, de modo a eliminar a atividade oxigenase da enzima. Só então se inicia o ciclo de Calvin & Benson (Ehleringer et al., 1997, Taiz e Zeiger, 2013). Durante esse processo de captura prévia do CO_2 pela PEP-carboxilase, as plantas de metabolismo C_4 acabam consumindo 2 moléculas de ATP a mais do que as plantas de metabolismo C_3 para capturar uma molécula de CO_2 , porém, esse gasto superior é compensado pela ausência de fotorrespiração (Castro, 2005). Dentre os subgrupos das plantas C_4 , determinados pela enzima descarboxilativa das células da bainha vascular, o milho se encaixa no grupo que apresenta a maior eficiência fotossintética e no uso da radiação solar, podendo ser até 20% mais eficiente do que as plantas de outros grupos. Essa maior eficiência é devida à anatomia das plantas de milho, que possuem mecanismos de prevenção de perda de CO_2 (Hattersley, 1984). Diversas respostas das plantas de milho às condições ambientais decorrem do seu tipo de metabolismo, principalmente quanto à radiação solar, temperatura, concentração de CO_2 na atmosfera e disponibilidade de água e nitrogênio no solo.

A resposta da planta de milho em relação à sua taxa fotossintética está ligada não apenas à concentração de CO_2 na atmosfera, mas também à radiação solar incidente no local. Plantas de metabolismo C_3 e C_4 respondem de maneiras diferentes a esses estímulos, sendo que plantas C_4 possuem um ponto de saturação de fotossíntese por radiação superior ao limite das plantas C_3 , fazendo com que a fotossíntese líquida (fotossíntese bruta – respiração de manutenção) também seja maior. Outro ponto que confere às plantas C_4 ainda mais eficiência no processo fotossintético está relacionado à ausência de fotorrespiração, o que faz com que o ponto de compensação luminosa seja próximo de zero (Bergonci e Bergamaschi, 2002; Taiz & Zeiger, 2013). As Figuras 1.2 e 1.3 apresentam a fotossíntese líquida e a assimilação de CO_2 por plantas C_3 e C_4 em função da temperatura foliar e da concentração de CO_2 intracelular.

Figura 1.2. Variação da fotossíntese em função da temperatura do ar, em condição de CO₂ atmosférico normal, para plantas C3 e C4 em seus respectivos habitats naturais. Fonte: Adaptado de Berry e Bjorkman (1980)

Figura 1.3. Variação da fotossíntese em função da pressão parcial de CO₂ intracelular em espécies C3 e C4. A pressão parcial onde a assimilação é zero representa o ponto de compensação desse gás. Fonte: Adaptado de Berry e Downton (1982)

A irradiância solar interfere não apenas na taxa de fotossíntese da planta de milho, mas também na abertura e fechamento de estômatos, na temperatura dentro da planta e no seu balanço de energia. Diminuições na intensidade da irradiância solar diminui a intensidade desses processos, podendo atingir fotossíntese líquida nula. Por outro lado, excesso de irradiância solar pode causar a saturação da fotossíntese bruta (Andrade, 1992). A produtividade do milho é diretamente relacionada à quantidade de radiação fotossinteticamente ativa (RFA) captada por suas folhas e também à eficiência dessas folhas em transformar a energia luminosa em energia química por meio da fotossíntese, da mesma forma que a quantidade de RFA absorvida é diretamente relacionada à eficiência com que

ela é interceptada pelas folhas da planta de milho. Essa eficiência de interceptação sofre influência de fatores como índice de área foliar (IAF), arquitetura das folhas, densidade de plantio, genótipo, época do ano e local de plantio (Varlet-Grancher et al., 1989; Muller e Bergamaschi, 2005; Sangoi e Silva, 2006; Kunz et al., 2007; Yang et al., 2017).

Em particular, a arquitetura, o tamanho e a geometria das folhas, que variam entre diferentes genótipos, afetam diretamente o coeficiente de extinção, fazendo com que a eficiência de interceptação da radiação possa ser diferente em campos com mesmo IAF. Genótipos modernos são aqueles capazes de aumentar a população de plantas sem interferir no auto-sombreamento, aumentando a eficiência de interceptação da radiação solar. Pode-se, assim, definir a eficiência do uso da radiação como sendo a razão entre a energia utilizada para transformação de biomassa e a energia total incidente no dossel da cultura. Em experimento realizado em 2005, Muller e Bergamaschi apontam diferentes eficiências no uso da radiação por um mesmo genótipo de milho em situação de sequeiro e irrigado, reforçando a ideia de que o coeficiente de extinção não está ligado apenas as características genéticas da planta, mas à sua área foliar, conforme apresentado na Figura 4.

Figura 1.4. Relação entre matéria seca acumulada e RFA interceptada pelo milho em condições irrigadas e de sequeiro. Fonte: Adaptado de Muller e Bergamaschi (2005)

O desenvolvimento da planta de milho também é altamente influenciado pela temperatura do ar, tanto diurna quanto noturna (Coelho e Dale, 1980; Fortin e Pierce, 1990; Costa, 1994; Cruz et al., 2008, Caron et al., 2017). A temperatura do ar afeta diretamente o desenvolvimento da cultura do milho (Gadioli et al., 2000), no crescimento de raiz, absorção

de nutrientes e água, afetando também a duração das fases fenológicas da planta (Pascale, 1953; Coelho e Dale, 1980; Caron et al., 2017). Tollernar et al. (1979) e Lozada e Angelocci (1999) apontam uma relação linear entre o desenvolvimento das plantas de milho e a temperatura do ar, mostrando que essa é a variável meteorológica que melhor explica a duração das fases fenológicas dessa cultura. Segundo a literatura, encontramos diversos relatos de temperaturas consideradas como limite inferior para o desenvolvimento do milho, podendo os valores variar entre 4,5 e 14,1°C (Berlato e Sutili (1976); Fancelli e Dourado Neto (2000); Streck et al. (2009)). Da mesma forma, limites superiores de temperatura também limitam o desenvolvimento da cultura do milho. Kiniry (1991) determinou esse patamar superior para o desenvolvimento do milho em 44°C, sugerindo uma faixa ótima de desenvolvimento entre 26 e 34°C. Birch et al. (1998), também considerou a temperatura basal superior do milho em 44°C e uma temperatura ótima para desenvolvimento de 30°C. Fancelli e Dourado Neto (2000) apontam que essa temperatura basal superior está em torno dos 42°C. Em meio a essas diferentes faixas de temperatura favorecendo ou desfavorecendo o desenvolvimento do milho, ainda podemos encontrar relatos de que temperaturas em torno de 25°C favorecem tanto o florescimento quanto a maturação dos grãos de milho (Pascale, 1953), enquanto que temperaturas superiores a 32°C podem inviabilizar a germinação dos grãos de pólen da planta (Herrero e Jhonson, 1980). A Figura 5 apresenta essa relação entre o desenvolvimento de uma cultura hipotética e a temperatura do ar, o que se aplica perfeitamente à cultura do milho.

Figura 1.5. Taxa dos diferentes processos de uma planta hipotética em função da temperatura do ar. Fonte: Bergonci e Bergamaschi (2002)

Gilmore e Rogers (1958) mostraram que o total de graus-dias necessários para as plantas de milho possam atingir o espigamento foi praticamente constante, considerando diferentes épocas de semeadura ao longo do ano, enquanto que o número de dias para que o espigamento ocorresse teve grande variação. Dessa forma, surge o conceito de 'tempo térmico', que substitui o tempo cronológico. Para completar suas diferentes fases de desenvolvimento, as plantas de milho necessitam acumular diferentes quantidades de energia térmica, sendo que essas quantidades variam de acordo com a fase fenológica e também com o genótipo empregado. Essa energia térmica acumulada é denominada de constante térmica, que representa o total de graus-dia requerido, o qual por sua vez é a diferença entre a temperatura média diária e a temperatura basal inferior (Cantele, 2009). Diversos trabalhos apresentam a constante térmica requerida pela cultura do milho para completar seu ciclo, mostrando que, embora a radiação solar e o regime hídrico também possam influenciar a fenologia do milho, o regime térmico é o principal controlador do desenvolvimento das plantas de milho (Coelho e Dale, 1980; Cantele 2009; Bergamaschi e Matzenauer, 2014; Guo et al., 2017; Shim et al., 2017). O tempo térmico pode prever diversos acontecimentos no desenvolvimento do milho, desde duração do período vegetativo, aparecimento de inflorescência e duração da maturação, que são eventos importantíssimos, principalmente quando há interesse no uso de modelos de simulação de crescimento e desenvolvimento das plantas. Esse conceito se aplica inclusive para determinar o tempo térmico necessário entre o surgimento de uma folha e outra, denominado de 'filocrono', variável importante para se determinar a duração do período vegetativo do milho (Soler et al., 2005; Schons et al., 2009; Streck et al., 2009).

Outro fator no desenvolvimento do milho é a disponibilidade de água no solo. Devido ao seu porte e área foliar, o milho consome uma grande quantidade de água, se tornando muito suscetível à sua limitação. Essa necessidade hídrica acompanha a oscilação da temperatura diária, que é mais intensa em momentos de temperatura elevada. A necessidade hídrica do milho também pode variar de acordo com a época e local da semeadura, e também com a área foliar e o genótipo utilizado, oscilando entre 250; e 800 mm durante seu ciclo (Doorenbos e Kassam, 1979; Cruz et al, 2008; Zhao et al., 2010; Sun et al., 2010; Abdraboo et al., 2016), entretanto, em locais onde a demanda evapotranspirativa da cultura é muito elevada, esse consumo pode ultrapassar os 900 mm (Doorenbos e Kassam, 1979; Abdraboo et al., 2016).

Segundo Sans et al. (2006), as variáveis climáticas que mais afetam o crescimento da cultura do milho são a temperatura, a radiação solar e a chuva, as quais definem tanto a produtividade potencial como a atingível. Inúmeras análises de produções agrícolas apontam o clima como sendo o principal responsável por suas oscilações, especialmente em anos atípicos (Gadioli et al., 2000; Sun et al., 2010; Bergamaschi e Matzenauer, 2014; Abdraboo et al., 2016; Caron et al., 2017; Guo et al., 2017; Shim et al., 2017; Yang et al., 2017). Sendo assim, é necessário se dispor de dados climáticos de qualidade para realizar estudos que permitam a estimativa dessas produtividades e a determinação dos principais responsáveis pelas quebras de produtividade da cultura.

1.3.1.3. Produção brasileira e mundial

O milho é o cereal mais produzido no mundo, como aponta o Departamento de Agricultura dos Estados Unidos (USDA), com produções superando 960 milhões de toneladas mundo afora numa área plantada de mais de 175 milhões de hectares (USDA, 2017). Hoje, os EUA são os maiores produtores e também os maiores consumidores desse cereal, como mostram as Tabelas 1.3 e 1.4, respectivamente.

Tabela 1.3. Produção (em milhões de toneladas) de milho e sua variação entre as safras 15/16 e 16/17

Países	Produção (Milhões de toneladas)			
	Safras		Variação	
	15/16	16/17	Absoluto	%
EUA	345,5	384,8	39,3	11,4
China	224,6	219,6	-5,1	-2,3
Brasil	67	93,5	26,5	39,6
U.E.	58,4	60,3	1,9	3,2
Demais	267,8	295,6	27,9	10,4
Mundo	963,3	1053,8	90,4	9,4

Fonte: Levantamento USDA (2017).

Tabela 1.4. Consumo (em milhões de toneladas) de milho e sua variação entre as safras 15/16 e 16/17

Países	Consumo (Milhões de toneladas)
--------	--------------------------------

	Safras		Variação	
	15/16	16/17	Absoluto	%
EUA	298,9	314,8	16	5,3
China	217,5	231	13,5	6,2
Brasil	57,5	60	2,5	4,3
U.E.	73,2	73	-0,2	-0,3
Demais	333,9	363,8	29,9	8,9
Mundo	981	1042,6	61,6	6,3

Fonte: Levantamento USDA, 2017.

O Brasil tem uma forte participação na produção mundial de milho. Dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2017), apresentados na Figura 1.6, apontam que de 1990 a 2015 houve um aumento superior a 30% na área plantada de milho no país, acompanhado por um aumento na produtividade média que ultrapassou os 190%. Isso mostra a importância do melhoramento genético e do desenvolvimento tecnológico, por meio de práticas de manejo agrícola mais adequadas para a cultura (Sangoi, 2000). Acompanhando as mudanças no aumento da área plantada e nas produtividades, o Brasil também passou por mudanças nos polos produtores de milho. No início dos anos 90, as regiões Sul e Sudeste representavam mais de 60% da área plantada de milho no país e contribuíam com mais de 75% da produção nacional do grão. Em 2015, a região Centro-Oeste passou a ser a mais importante para a cultura, plantando mais de 40% da área total de milho e contribuindo com cerca de 47% da produção nacional (IBGE, 2017).

Figura 1.6. Evolução da área plantada e da produtividade da cultura do milho no Brasil. Fonte: Adaptado de IBGE (2017)

Apesar do expressivo aumento na produtividade média do milho nas últimas décadas no Brasil, ainda existe potencial para aumento desta em várias regiões do país. Yamada (1997), através de simulações matemáticas, apontou que o potencial teórico de produtividade do milho cultivado no *corn belt* americano é da ordem de 31.400 kg ha⁻¹. Na Tabela 1.5 podemos observar alguns registros de recordes de produtividade de milho cultivado em condições de campo.

Tabela 1.5. Recordes de produtividade de milho nos Estados Unidos e no Brasil

Ano	Local	Produtor	Produtividade (kg ha ⁻¹)	Citado por
1908	Connecticut, EUA	Estação Experimental de Connecticut	12.600	Lowenberg-DeBoer (1998)
1985	Illinois, EUA	Herman Warsaw	23.200	Vyn (2001)
1993	Minas Gerais, BR	Geraldo Lacerda	16.828	Emater MG (199X)
1999	Iowa, EUA	Francis Child	24.700	Vyn (2001)
2014	Geórgia, EUA	Randy Dowdy	31.500	NCGA (2014)

Fonte: Adaptado de Coelho et al. (2004) e National Corn Growers Association (NCGA, 2014).

Mesmo com um número expressivo de agricultores participando de concursos de produtividade de milho ao longo dos anos, representando uma diversidade enorme de condições edafoclimáticas e de manejo, o acompanhamento das condições do ambiente de produção e dos tratos culturais realizados permite entender melhor a variabilidade da produtividade do milho em cada região, determinando os elementos chave para a obtenção de altas produtividades (Coelho et al., 2004).

Devido a essa diversidade nas condições ambientais e de técnicas de cultivo, desde lavouras de subsistência até as lavouras que usam da mais alta tecnologia, diversos autores dividiram os ambientes de produção de milho em classes tecnológicas. Segundo Coelho et al. (2004), essas classes tecnológicas se dividem em: marginal; baixa; média; e alta tecnologia. Sangoi et al. (2002) propôs uma divisão em três níveis tecnológicos, de acordo com a produtividade da cultura: baixo nível (<3 t ha⁻¹); médio nível (de 3 a 6 t ha⁻¹); e alto nível (>6 t ha⁻¹). Com a classificação dos ambientes de produção em níveis tecnológicos torna-se mais prático adotar estratégias de cultivo que otimizem os investimentos e maximizem as produtividades (Padilha, 2014).

Os fatores tecnológicos dos sistemas de produção podem ser divididos em dois grupos: os responsáveis pela construção da produtividade e os responsáveis pela proteção da produtividade (Coelho et al., 2004). Os fatores que constroem a produtividade são de extrema importância para se alcançar altas produtividades e estão ligados ao melhoramento genético, ao posicionamento adequado da semente na janela de plantio e nutrição e adubação. Os fatores ligados à proteção são importantes para garantir que o potencial da planta no ambiente escolhido seja atingido, como controle de pragas, doenças, plantas invasoras (Coelho et al., 2004; Cruz et al., 2009).

1.3.2. Modelos de simulação de culturas

Para se simular o desempenho de uma cultura, em um determinado local e época de sementeira, são utilizados modelos de simulação, cujo objetivo é estimar o seu desenvolvimento, crescimento e produtividade (Martins, 2012). As interações planta-ambiente envolvem complexos processos biofísicos, bioquímicos e fisiológicos, entretanto, o uso dos modelos de simulação possibilita integrar a maioria desses aspectos de modo a estimar o desempenho de uma cultura em diferentes condições (Soler, 2004), auxiliando no entendimento dos mecanismos de resposta da cultura principalmente às condições do ambiente (Marin et al., 2011).

De acordo com Reynolds (1979) e Monteith (1996), modelos são conjuntos de equações que visam representar um determinado processo a partir de coeficientes e variáveis de entrada. Considerando-se a agricultura, esses modelos permitem uma melhor compreensão dos componentes da produção, fornecendo uma visão sistêmica do sistema produtivo, gerando resultados que possibilitam tanto ações de planejamento da cultura como seu monitoramento ao longo da safra de cultivo e em vários níveis, como escolha de genótipos, épocas de plantio, planejamento do uso de maquinário, entre outros (Gedanken, 1998).

No trabalho apresentado por Zhang et al. (2002), os modelos foram classificados quanto à sua complexidade, desde simples a muito complexos, caracterizados de acordo com a quantidade de informações necessárias para alimentá-los. Em função da classificação da complexidade dos modelos decorrem erros que são inerentes a cada uma delas: os erros sistemáticos, característicos de modelos mais simples e os erros de calibração, decorrentes de modelos mais complexos. O autor sugere ainda que a escolha do modelo seja baseada na

sua destinação, a fim de evitar inserir informações desnecessárias no processo de modelagem, ou de se obter informações desnecessárias. A Figura 1.7 ilustra a proporção que se deve buscar entre simplicidade e complexidade dos modelos de simulação de culturas no momento de sua escolha, a fim de evitar ao máximo os erros gerados pela modelagem.

Figura 1.7. Diagrama esquemático representando a relação entre erro sistemático e erro de calibração em função da complexidade do modelo de simulação utilizado. Fonte: Adaptado de Zhang et al. (2002)

1.3.2.1. Uso de modelos de simulação na cultura do milho e estimação da produtividade

1.3.2.1.1. Modelo da Zona Agroecológica – FAO (MZA-FAO)

Um dos modelos de simulação mais empregados em simulações de cultura, dado sua simplicidade, é o proposto por Doorenbos e Kassam (1979), o qual se baseia na estimativa da produtividade potencial (PP) e atingível (PA) por meio de equações matemáticas que simulam PP para uma cultura padrão, determinada pela relação entre a radiação solar, temperatura do ar, fotoperíodo e a fotossíntese bruta, que, posteriormente, é corrigida para a cultura de interesse. Na sequência, a PA é obtida por um modelo que considera a penalização da PP pelo déficit hídrico, sendo essa aplicada a cada fase fenológica e modulada por um coeficiente de sensibilidade da cultura à deficiência hídrica (Pereira et al., 2002; Martins, 2012). Esse modelo vem sendo empregado para diversas culturas, entre elas o próprio milho (Andriolli e Sentelhas, 2009), soja (Monteiro e Sentelhas, 2014; Battisti e

Sentelhas, 2014; Sentelhas et al., 2015), cana-de-açúcar (Gouvêa et al., 2009; dos Santos e Sentelhas, 2013; Monteiro e Sentelhas, 2017), entre outras.

O déficit hídrico relativo, utilizado na penalização desse modelo é obtido através da relação entre evapotranspiração real (ETr) e a evapotranspiração potencial da cultura de interesse (ETc). A ETr é obtida através do balanço hídrico de cultura, proposto por Thorthwaite e Mather (1955) e a ETc pode ser obtida aplicando-se um fator de consumo hídrico (inerente à cultura modelada e à sua fase fenológica) à evapotranspiração potencial de referencia (ET₀), descrita por diversos autores (Penman, 1948; Priestley e Taylor, 1972; Haregreaves e Samani, 1985; Allen et al., 1998).

O modelo teórico de acúmulo de massa, descrito por de Wit (1965), é usado na escala diária como base para o cálculo da PP nesse modelo e leva em consideração valores de radiação solar no topo da atmosfera (Q₀, MJ m⁻² dia⁻¹), temperatura média do ar (T_{med}, °C), insolação (n, horas) e fotoperíodo (N, horas). Como a disponibilidade energética no ambiente varia em dias limpos e dias nublados, há uma necessidade de considerar essa variável durante o cálculo do acúmulo de massa, separando a produtividade potencial bruta (PPB) em produtividade potencial bruta de dias claros (PPB_c) e dias nublados (PPB_n), segundo as equações:

Se T_{med} < 16,5 °C:

$$cT_c = -9,32 + 0,865 * T_{med} - 0,0145 * (T_{med})^2 \quad (1.1)$$

$$cT_n = -4,16 + 0,4325 * T_{med} - 0,00725 * (T_{med})^2 \quad (1.2)$$

Se T_{med} ≥ 16,5 °C:

$$cT_c = -4,16 + 0,4325 * T_{med} - 0,00725 * (T_{med})^2 \quad (1.3)$$

$$cT_n = -1,064 + 0,173 * T_{med} - 0,0029 * (T_{med})^2 \quad (1.4)$$

$$PPB_c = (107,2 + 8,604 * Q_0) * cT_c * \left(\frac{n}{N}\right) \quad (1.5)$$

$$PPB_n = (31,7 + 5,234 * Q_0) * cT_n * \left(1 - \frac{n}{N}\right) \quad (1.6)$$

em que cT_c e cT_n são coeficientes para correção do processo fotossintético correspondente a um metabolismo C₄.

Ao somarmos PPB_c e PPB_n obtemos a PPB e então podemos seguir com a estimação da PP, segundo a equação:

$$PP = \sum_i^{NDC} PPB_i * c_{resp} * c_{IAF} * c_{colh} * c_{um} \quad (1.7)$$

em que c_{resp} , c_{IAF} , c_{colh} e c_{um} são coeficientes de ajuste específicos da cultura simulada e se referem a respiração, índice de área foliar, colheita e umidade, respectivamente, enquanto que i é o dia corrente de cálculo e NDC nada mais é do que o número de dias do ciclo da cultura.

Com a PP em mãos, é possível calcular a PA , aplicando o déficit hídrico relativo, anteriormente comentado, em função das fases fenológicas da cultura simulada, conforme recomenda o método de Doorenbos e Kassam (1979):

$$PA_n = \prod_{i=1}^n \left\{ 1 - \left[k_{yi} * \left(1 - \frac{ETr_i}{ETC_i} \right) \right] \right\} * PA_{i-1} \quad (1.8)$$

em que PA_n é a produtividade atingível final da cultura, em $t \text{ ha}^{-1}$, n é o número de fases fenológicas da cultura simulada e i é a fase fenológica corrente, sendo que, quando $i = 1$, $PA_{i-1} = PP$ e k_y é o coeficiente de sensibilidade ao déficit da cultura no estágio fenológico correspondente a i .

1.3.2.1.2. Decision Support System for Agrotechnology Transfer (DSSAT)

Outro modelo que vem sendo muito utilizado para estudos com a cultura do milho ao redor do mundo é o CSM-Ceres-Maize, que faz parte da plataforma *Decision Support System for Agrotechnology Transfer* (DSSAT). Esse modelo é de natureza mecanística, ou seja, explica os vários mecanismos/processos associados ao desenvolvimento, crescimento e produtividade da cultura do milho em função da interação entre o genótipo, o clima, o solo e algumas características de manejo agrícola. Suas variáveis de entrada são mais complexas e o modelo exige a calibração de diversos coeficientes relacionados ao solo, à espécie e ao genótipo (Kiniry et al., 1997). Esse modelo vem sendo utilizado para simular o crescimento e o desenvolvimento da cultura do milho (Lima, 1995; Soler, 2004; Andrade et al., 2009; Soler et al., 2009; Santana et al., 2010; Liu et al., 2011; Jabeen et al., 2017), do arroz (Xiong et al., 2008; Singh et al., 2017), da cana-de-açúcar (Nassif et al., 2012; Morgan e Royce, 2014;

Pagani et al., 2017), da soja (Justino et al., 2013), da cultura do sorgo (Lopez et al., 2017) e também de sistemas consorciados e de rotação de culturas (Negm et al., 2017; Yin et al., 2017).

A plataforma DSSAT traz algumas opções para o usuário quanto os cálculos da evapotranspiração, como o método de Penman-Monteith (Allen et al., 1998); o método de Penman-original (Penman, 1948); a metodologia de Priestley-Taylor (1972) e também o método horário de balanço de energia. A infiltração de água no solo e sua evaporação é calculada com base no método proposto por Ritchie (1972), descrito por Probert et al. (1998). O modelo também simula o crescimento e desenvolvimento das folhas da planta baseado no tempo térmico e no filocrono. A resposta da fotossíntese é dada numa escala horária, baseada na eficiência do uso da radiação (RUE) e, ao final do dia, a massa acumulada pela planta é integrada. Na Figura 1.8 podemos ver a representação esquemática da abordagem modular da plataforma DSSAT, onde o programa principal controla o início da simulação; início do desenvolvimento da cultura; cálculos das taxas de crescimento e de integração de valores; resultados diários e um sumario com os resultados.

Figura 1.8. Visão geral da estrutura modular da plataforma DSSAT

O modelo também traz parâmetros que são inerentes à espécie e ao genótipo, de forma separada, sendo sugerido pelos desenvolvedores da plataforma a alteração apenas dos parâmetros relacionados ao genótipo, nos casos de necessidade de calibração. Esses parâmetros foram descritos por Hoogenboon et al. (1994), alguns influenciando mais nos parâmetros de crescimento/desenvolvimento e outros nos parâmetros de produção, conforme mostra a Tabela 1.6.

Tabela 1.6. Parâmetros para calibração de um genótipo de milho do modelo Ceres-Maize

Coeficiente	Relacionado à:	Descrição
P1	Crescimento/Desenvolvimento	Tempo térmico necessário desde a emergência até o final do período juvenil (temperatura basal considerada em 8°C). Nessa fase não se considera resposta fotoperiódica da planta.
P2	Crescimento/Desenvolvimento	Representa o atraso do desenvolvimento da planta (em dias) para cada hora a mais em relação ao fotoperíodo crítico, considerado de 12,5 horas.
P5	Crescimento/Desenvolvimento	Duração da fase reprodutiva, baseada na soma térmica (temperatura basal considerada em 8°C). Tem início na emissão do estiloestigma da planta de milho até sua maturidade fisiológica.
PHINT	Crescimento/Desenvolvimento/Produção	Corresponde ao filocrono, tempo térmico necessário entre a aparição de folhas subsequentes.
G2	Produção	Representa o número máximo de grãos de uma espiga.
G3	Produção	Representa a taxa de acumulo de massa (mg d^{-1}) em condições ótimas de desenvolvimento.

No capítulo 4 do livro *Modeling plant and soil system*, Kiniry (1991) mostra o mecanismo de funcionamento/interpretação do modelo quanto ao desenvolvimento fenológico da planta de milho ao longo do seu ciclo, conforme podemos ver nos itens a seguir:

- Temperatura basal considerada em 8°C para todas as fases do desenvolvimento, exceto no intervalo entre a germinação e a emergência, onde essa é considerada em 10°C;
- Taxa do desenvolvimento da planta aumenta linearmente com a temperatura até atingir a temperatura basal superior, correspondente à 34°C. Após essa temperatura basal superior, a taxa de desenvolvimento decresce linearmente até atingir taxa 0 na temperatura de 44°C em diante;
- Durante a fase juvenil, todos os processos na planta são dependentes apenas da temperatura;

- Após alcançar a soma térmica exigida em P1, o desenvolvimento da planta é independente da temperatura e começa a ser sensível ao fotoperíodo crítico de 12,5 horas. Para dias com fotoperíodo superior, a data prevista para a emissão da flor masculina é atrasada, em dias, conforme o coeficiente P2, para cada hora acima do fotoperíodo crítico. Dessa forma, a data da floração masculina é dependente tanto da soma térmica quanto do fotoperíodo;
- A fase reprodutiva é tratada no modelo em 3 etapas, sendo a primeira denominada de 'lag', com duração de 170°C dia; a segunda fase é caracterizada por um crescimento linear até a planta acumular 95% do total de graus dia exigidos em P3 e a última fase representa o final do desenvolvimento da planta durante o acúmulo dos 5% restantes de P3.

1.3.2.1.3. *Agricultural Production Systems sIMulator (APSIM)*

Seguindo a linha de modelos mecanísticos, um outro modelo muito utilizado recentemente é o APSIM. Esse modelo também considerando características como: local e época de semeadura; clima; solo; rotação e consórcio de culturas; palhada sobre o solo e sistema de plantio direto e a possibilidade de trabalhar com balanço de fósforo, nitrogênio e matéria orgânica no solo (Mccown & Williams, 1989). O modelo já foi utilizado para a simulação da cana-de-açúcar (Keating et al., 1999; Pinto et al., 2012; Costa et al., 2014; Marin et al., 2013; Skocaj et al., 2013), da cultura do milho (Peak et al., 2008; Liu et al., 2012; Chauhan et al., 2013; Deixa, 2014), do arroz (Lourençoni, 2009) e também de sistemas consorciados (Heinemann et al., 2008; Chen et al., 2010; Wang et al., 2012).

O balanço da água no solo no APSIM (SoilWat) é feito pelo mesmo método abordado no DSSAT, o das camadas em cascata de Ritchie, trabalhado numa escala temporal diária que, apesar da complexidade, o método considera apenas o movimento unidimensional da água no solo (Costa, 2012). O APSIM calcula o *runoff* com base no modelo modificado da USDA, o *curve number* (CN), segundo a equação 9 e, diferentemente do DSSAT, que oferece algumas opções para estimar a ETo, o APSIM conta apenas com o método de Priestley-Taylor (1972). O acúmulo de massa potencial do modelo é uma função da radiação, da cobertura do terreno pela cultura, com base na lei de Beer-Lambert (1870), e

da RUE. Esse acúmulo potencial é penalizado de acordo com os índices de água no solo, nitrogênio, fósforo, temperatura e CO₂ (APSIM-Plants, 2014).

$$Q = \frac{(P - 0,2 * S)^2}{P + 0,8 * S} \quad (1.9)$$

em que P é a precipitação; S é o parâmetro de retenção e Q é o runoff.

Por ter sido desenvolvido com base nos mesmos modelos utilizados para desenvolver o *Ceres-Maize*, muitas das rotinas de cálculos dos dois modelos são semelhantes, sendo que uma das grandes diferenças entre eles está nas rotinas dos cálculos responsáveis por ‘matar’ a planta, principalmente em situações de déficit hídrico severo nas fases iniciais do ciclo vegetativo (Carberry e Abrecht, 1991). O APSIM ainda possibilita ao usuário uma gestão mais dinâmica do solo, considerando também os resíduos gerados, o uso do solo perante às diversas condições de clima, as perdas e incrementos de matéria orgânica no sistema e também erosão, degradação e acidificação do solo, características essas não previstas por outros modelos (Keating et al., 2003). A Figura 1.9 apresenta um fluxograma da estrutura do modelo APSIM-*Maize*.

Figura 1.9. Fluxograma da estrutura do modelo APSIM-*Maize*. Adaptado de APSIM-Crop Model Documentation-*Maize*

O modelo ainda conta com mais de 10 parâmetros para calibração de aspectos de crescimento e desenvolvimento e da produção da planta de milho, além de uma divisão entre as fases fenológicas da cultura em 11 estádios. A rotina diária de cálculos do modelo estima uma evolução da temperatura diária para uma escala de três em três horas a partir das temperaturas máximas e mínimas informadas, para só então realizar a média da temperatura do dia e dar sequência aos cálculos da soma térmica, responsável pela mudança de fase fenológica. Maiores detalhes do modelo são descritos em *APSIM – Crop Model Documentation – Maize*.

1.3.2.2. Determinação da produtividade potencial e atingível

Podemos observar diferentes patamares produtivos quando comparamos a produtividade de agricultores médios, a produtividade de agricultores com alta tecnologia e a produtividade (Ranbbinge, 1993; Waclawovsky, 2010), sendo que todas essas podem sofrer influência tanto de fatores bióticos como abióticos (Moore, 2009). A produtividade potencial pode ser definida como a máxima produtividade de um genótipo sob condições onde não existem limites para o suprimento de água e nutrientes, além de ser isenta de ataques por pragas e doenças (Lobell et al., 2009; van Ittersum et al., 2013).

Observado isso, diversos autores classificaram essas produtividades, como Lobell et al. (2009), que mostrou diferenças entre a produtividade experimental; produtividade de agricultores altamente tecnificados e de agricultores médios. Essa diferença foi atribuída, principalmente, as características de manejo ao longo do cultivo. Podemos ainda definir o potencial produtivo, ou produtividade potencial (PP), como função apenas de características do ambiente (dependente apenas da radiação solar e temperatura), sem limitação de água e nutrientes e sem sofrer ação de pragas e doenças. Também podemos classificar a produtividade potencial em sistemas de sequeiro, chamada de produtividade potencial limitada pela água, ou produtividade atingível (PA), limitada pela radiação solar, temperatura e também pela disponibilidade hídrica (Lobell et al., 2009; Battisti et al., 2012; van Ittersum et al., 2013; Sentelhas et al., 2015).

Conforme variam os dados meteorológicos ao longo do ano, também irão variar PP e PA, de acordo com a data de implantação da lavoura, fazendo com que essas produtividades também sejam dependentes do local e data de plantio (van Ittersum et al., 2013). Além disso, a população de plantas escolhidas também afeta diretamente em seus

patamares produtivos, devido a sua relação com o acúmulo de matéria seca por área. Esse acúmulo de massa e a produtividade serão máximos quando a população for capaz de cobrir o terreno de forma a interceptar o máximo de radiação solar possível num menor intervalo de tempo (Lobell et al., 2009). Ainda podemos subdividir a produtividade real (PR), sujeita a todos os fatores ambientais, em produtividade de agricultores irrigados e produtividade de agricultores de sequeiro (Battisti et al., 2012; van Ittersum et al., 2013; Sentelhas et al., 2015). A Figura 1.10 exemplifica essa relação entre os diferentes tipos de produtividade.

Figura 1.10. Tipos de produtividade e seus fatores de influência. Adaptado de: Lobell et al. (2009); van Ittersum et al. (2013) e Sentelhas et al. (2015)

1.3.2.3. Aplicação dos modelos de simulação de culturas na determinação das quebras de produtividade (*Yield Gaps*)

Considerando a possibilidade da modelagem de culturas agrícolas nos diferentes cenários de plantio, com distintas condições de clima e solo, e tendo valores de produtividades reais obtidas *in loco*, pode-se aplicar o conceito de quebra de produtividade, denominado internacionalmente de *yield gap* (YG), que consiste em determinar as diferenças nos patamares produtivos entre as classificações dos tipos de produtividade,

apresentadas na Figura 10. Dentro desse contexto, a diferença entre as produtividades potencial (PP) e atingível (PA) é denominada de YG devido ao déficit hídrico, enquanto que a diferença entre a produtividade atingível e real é denominada de YG devido ao manejo agrícola.

Segundo Lobell et al. (2009); van Ittersum et al. (2013); Sentelhas et al. (2015) e Monteiro e Sentelhas (2017); é possível se estimar a PP e PA baseando-se em 4 abordagens: experimentos controlados em campo; observação das máximas produtividades entre os melhores agricultores; campeonatos de produtividade e através de modelos matemáticos. Vale ressaltar que cada abordagem escolhida para determinar PP e PA terá sua limitação, como a aquisição de dados meteorológicos e calibração, no caso da escolha pelo método dos modelos, ou limitações de local, no caso dos outros métodos, por exemplo. Em regiões tropicais, a determinação dessas produtividades e dos YGs se torna um desafio ainda maior, devido à grande variabilidade climática interanual, principalmente no que diz respeito à precipitação (Affholder et al., 2013). Segundo van Ittersum et al. (2013), o conceito de YG pode ser aplicado em qualquer local, desde que se tenha uma boa base de dados meteorológicas assim como uma ampla base de dados agronômicos para comparação. Segundo esses autores, a determinação do YG deve obedecer às seguintes etapas:

1. Usar um modelo de simulação bem calibrado e adaptado às condições locais;
2. Usar dados meteorológicos medidos;
3. Simular de acordo com o solo e sistema de plantio predominante na região;
4. Usar informações agronômicas e de produtividade do local;
5. Comparar o YG local ao YG obtido com a experimentação;
6. Extrapolar os resultados para escalas maiores por meio do uso de sistemas de informações geográficas.

Dada a grande importância da cultura do milho a nível nacional, a identificação dos potenciais produtivos das principais regiões produtoras da cultura no Brasil e dos YGs oriundos do déficit hídrico e do manejo agrícola se torna de extrema importância para o planejamento estratégico da produção, auxiliando na identificação de locais carentes em tecnologia, assim como para a orientação de projetos que visem à minimização dos YGs.

1.3.2.4. Aplicação dos modelos de simulação de culturas para a projeção e a previsão de safra

Além das possibilidades expostas acima, os modelos de simulação, apropriadamente calibrados, permitem a projeção futura da produtividade (Duchon, 1986; Thorton et al., 1997), auxiliando na previsão de safras e no planejamento da colheita, transporte e armazenamento, a nível regional e nacional, assim como a projeção de ganhos pelo produtor a nível local.

Para realizar essa previsão, Duchon, (1986), Chipanshi et al. (1997) e Bannayan et al. (2003) substituíram dados climáticos futuros por dados diários de uma série histórica (normal climatológica), com o intuito de representar o que pode ocorrer no ano de cultivo em questão. Thornton et al. (1997) e Soler, (2004) apontam que quanto mais nos aproximamos da fase final de desenvolvimento da cultura, mais precisas são as estimativas de produtividade (variâncias muito próximas a zero). Isso ocorre devido ao número de dias com incertezas climáticas se reduzir, ao passo que dados observados são incorporados nas estimativas. Pode-se, assim, predizer o total da safra com certa segurança antes mesmo de iniciar a colheita, o que faz desse sistema de previsão uma ferramenta importante para questões estratégicas de comercialização e planejamento de escoamento da safra e de armazenamento.

REFERÊNCIAS

- ABDRABBO, M.A.A.; SALEH, S.M.; FARAG, A.A. Water requirements for maize under climate change. **Journal of Applied Sciences Research**, Islamabad, v. 12, p.19-28, 2016.
- AFFHOLDER, F.; POEYDEBAT, C.; CORBEELS, M.; SCOPEL, E.; TITTONELL, P. The yield gap of major food crops in family agriculture in the tropics: Assessment and analysis through field surveys and modeling. **Fields Crops Research**, v.143, p.106-118, 2013.
- ALLEN, R. G., PEREIRA, L. S., RAES, D., SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. FAO: **Irrigation Drainage and Paper**, 56, Roma, p.291, 1998.
- ANDRADE, C.L.T; AMARAL, T.A.; SILVA, D.F.; GARCIA, A.G,; HOOGENBOOM, G.; GUIMARÃES, D.P.; OLIVEIRA, A.C.; SANTANA, C.B. Utilização do modelo ceres-maize como ferramenta na definição de estratégias de semeadura de milho: 2 – sistema de produção irrigado. **Apresentado no XVI Congresso Brasileiro de Agrometeorologia**, Belo Horizonte-MG, 2009.
- ANDRADE, F. H., Radiación y temperatura determinan los rendimientos máximos de maíz. Balcare: **Instituto Nacional de Tecnologia Agropecuária**, Boletim técnico 106, p.34, 1992.
- ANDRIOLI K, G.; SENTELHAS. P. C. Brazilian maize genotypes sensitivity to water deficit estimated through a simple crop yield model. **Pesquisa Agropecuaria Brasileira**, v.44, n.7, p.653-660, 2009.
- BANNAYAN, M.; CROUT, N.M.J; HOOGENBOOM, G. Application of the Ceres-Wheat model for within season prediction of winter wheat yield in the United Kingdom. **Agronomy Journal**, Madison, v.95, p.114-125, 2003.
- BARROS J. F. C. e CALADO J. G., A cultura do milho. **Universidade de Évora**, Escola de Ciências e tecnologia, 2014.
- BATTISTI, R.; SENTELHAS, P.C. Eficiência climática para as culturas da soja e do trigo no estado do Rio Grande do Sul em diferentes datas de semeadura. **Ciência Rural**, Santa Maria, v. 43, p. 390-396, 2012.
- BATTISTI, R.; SENTELHAS, P. C. Drought tolerance of brazilian soybean cultivars simulated by a simple agrometeorological yield model. **Experimental Agriculture**, Combridge, v. 51, p. 285–298, 2014.

BERGAMASCHI, H. et al. Distribuição hídrica no período crítico do milho e produção de grãos.

Pesquisa Agropecuária Brasileira, Brasília, v. 39, p. 831-839, 2004.

BERGAMASCHI, H.; MATZENAUER, R. O milho e o clima. **Emater**, Porto Alegre, 2014.

BERGONCI, J.I.; BERGAMASCHI, H. Ecofisiologia do milho. **Congresso nacional de milho e sorgo**, Florianópolis. Anais ABMS/EMBRAPA/EPAGRI, 2002.

BERLATO, M.A., SUTILI, U.R. Determinação das temperaturas bases dos subperíodos emergência-germinação e emergência-espigamento de três cultivares de milho. **Reunião técnica de milho e sorgo**, Porto Alegre, 1976.

BERRY, J., BJORKMAN, O. Photosynthetic response and adaptation to temperature in higher plants. **Annual Review of Plant Physiology**, vol. 31, p. 491-543, 1980.

BERRY, J. e DOWNTON, J. S., Environmental regulation of photosynthesis. *Photosynthesis Vol.2: Development, Carbon Metabolism and Plant Productivity*, Nova York, p. 263-343, 1982.

BIRCH, C.J.; HAMMER, G.L; RICKERT, K. J. Temperature and photoperiod sensitivity in five cultivars of maize (*Zea mays*) until tasseling initiation. **Field Crops Research**, Amsterdam, v. 55, p. 93-107, 1998.

CANTELE, E. F. Desempenho da cultura de milho em diferentes épocas de cultivo no sudoeste paulista. **Dissertação apresentada para obtenção do título de Mestre em agronomia**. ESALQ/USP, Piracicaba, 2009.

CARON, B.O.; OLIVEIRA, D.M.; ELLI, E.F.; ELOY, E.; SCHWERZ, F.; SOUZA, V.Q. Elementos meteorológicos sobre características morfológicas e produtivas do milho em diferentes épocas de semeadura. *Científica*, Jaboticabal, v. 45, p.105-114, 2017.

CASTRO, P.R.C.; KLUGE, R.A.; PERES, L.E.P. Manual de Fisiologia Vegetal. **Editora Agronômica Ceres Ltda.**, São Paulo, p.654, 2005.

CHANG, J. H. Climate and agriculture: an ecological survey. Aldine Publishing Company, Chicago, v.3, p. 301, 1974.

CHAUHAN, Y.S; SOLOMON, K.F.; RODRIGUEZ, D. Characterization of north-eastern Australian environments using APSIM for increasing rainfed maize production. **Field Crop Research**, Amsterdam, v.144, p. 245-255, 2013.

CHEN, C.; WANG, E.; YU, Q. Modeling wheat and maize productivity as affected by climate variation and irrigation supply in north China Plain. **Agronomy Journal**, Madison, v. 102, p.1037-1049, 2010.

- CHIPANSHI, A.C.; RIPLEY, E.A.; LAWFORD, R.G. Early prediction of spring wheat yields in Saskatchewan from current and historical weather data using Ceres-Wheat model. **Agricultural and Forest Meteorology**, Amsterdam, v.84, p. 223-232, 1997.
- COELHO, A. M., Cruz, J. C. e PEREIRA-FILHO, I. A. Desafios para alta produtividade de milho. Comunicado técnico 112. **Embrapa Milho e Sorgo**, Sete Lagoas, 2004.
- COELHO, D.T., DALE, R.F. An energy-crop growth variable and temperature function for predicting corn growth and development: planting to silking. **Agronomy Journal**, Madison, v. 72, p. 503-510, 1980.
- COSTA, A. F. S. da. Influência das condições climáticas no crescimento e desenvolvimento de plantas de milho (*Zea mays* L.), avaliadas em diferentes épocas de plantio. **Tese apresentada para obtenção do título de Doutor em agronomia**. Viçosa: UFV, 1994.
- COSTA, L.G. Simulação do efeito de palhada e adubação nitrogenada na produtividade de cana-de-açúcar. **Tese apresentada para obtenção do título de Mestre em agricultura**, São Carlos: UFSCAR, 2012.
- COSTA, L. G.; MARIN, F. R.; NASSIF, D. S. P.; PINTO, H. M. S.; LOPES-ASSAD, M. L. R. C. Simulação do efeito do manejo da palha e do nitrogênio na produtividade da cana-de-açúcar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, p. 469-474, 2014.
- CRUZ, J.C.; FILHO, I.A.P; GARCIA, J.C.; DUARTE, J. DE. O. Cultivo do milho: cultivares. **Embrapa Milho e Sorgo**, Sete Lagoas, 2008. Disponível em: http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Milho/CultivodoMilho_4ed/manejomilho.htm.
- CRUZ, J. C., GARCIA, J. C. e FILHO, I. A. P. Caracterização dos sistemas de produção de milho para altas produtividades. **Embrapa Milho e Sorgo**, Sete Lagoas, 2009.
- DEIXA, S.V. Avaliação do rendimento e periodo de sementeira da cultura de milho sequeiro usando o modelo APSIM: Estudo de caso no distrito de Sussundenga. **Tese apresentada para obtenção do título de Mestre em agricultura**, Maputo, 2014.
- DOORENBOS, J.; KASSAM, A. H. Yield response to water. **FAO: Irrigation and Drainage paper**, 33, Roma, p. 212, 1979.
- DUCHON, C.E.; Corn yield prediction using climatology. **Journal of Climate and Apply Meteorology**, Boston, v.25, p. 581-585, 1986.

- EHLERINGER, J. R.; CERLING, E.T.; HELLIKER, B. R. C4 photosynthesis, atmospheric CO₂, and climate. **Oecologia**, Berlin, v.12, 112, p.285-299,1997.
- FANCELLI, A. L. Plantas Alimentícias: guia para aula, estudos e discussão. Piracicaba: ESALQ/USP, p. 131, 1986.
- FANCELLI, A. L., DOURADO-NETO, D. Produção de milho. **Livraria e Editora Agropecuária**, Guaíba, p. 360, 2000.
- FORTIN, M.C., PIERCE, F.J. Developmental and growth effects of crop residues on corn. **Agronomy Journal**, Madison, v. 82, p. 710-715, 1990.
- GADIOLI, J. L.; DOURADO-NETO, D.; GARCIA, A. G.; BASANTA, M. del V., Temperatura do ar, rendimento de grãos de milho e caracterização fenológica associada à soma calórica. **Scientia Agricola**, Piracicaba, v.57, p.377-383, 2000.
- GEDANKEN, A., Utilização do modelo CERES-Maize para avaliar estratégias de irrigação em duas regiões de Minas Gerais. **Tese apresentada para obtenção do título de Mestre em agricultura**, Viçosa: UFV, 1998.
- GOUVÊA, J. R. F.; SENTELHAS, P. C.; GAZZOLA, S. M.; SANTOS, M. C. Climate changes and technological advances: impacts on sugarcane productivity in tropical southern Brazil. **Scientia Agricola**, Piracicaba, v.66, p. 593-605, 2009.
- GILMORE, E. C.; ROGERS, J. S. Heat units as a method of measuring maturity in corn. **Agronomy Journal**, Madison, v. 50, p. 611-615, 1958.
- GUO, E.; ZHANG, J.; WANG, Y.; ALU, S.; WANG, R.; LI, D.; HA, S. Assessing non-linear variation of temperature and precipitation for different growth periods of maize and their impacts on phenology in the Midwest of Jim province, China. **Theoretical and Applied Climatology**, Berlim, v. 126, p.1-15, 2017.
- HALL, A. J., FEOLI, C., INGARAMO, J.&BALZARINI,M. Gaps between farmer and attainable yield across rainfed sunflower growing regions of Argentina. **Field Crops Research**, Amsterdam, v.143, p. 119–129, 2013.
- HANWAY, J. J. Growth stages of corn (Zea mays). **Agronomy Journal**, Madison, vol. 55, p. 487-492, 1963.
- HATTERSLEY, P.W. Characterization of C4 type leaf anatomy in grasses (Poaceae). Mesophyll: bundles sheath area ratios. **Annual of Botany**, Londres, v. 53, p. 163-179, 1984.

- HEINEMANN, A. B.; DINGKUHN, M.; LUQUET, D.; COMBRES, J. C.; CHAPMAN, S. Characterization of drought stress environments for upland rice and maize in central Brazil. **Euphytica**, Van Godewijckstraat, v.162, p. 395-410, 2008.
- HERRERO, M.P.; JOHNSON, R.R. High temperature stress and pollen viability of maize. **Crop Science, Madison**, v.20, p. 796-800, 1980.
- HOOGENBOON, G.; JONES, J.W.; WILKENS, P.W.; BATCHELOR, D.W.; BOWEN, W.T.; HUNT, L.A.; PIKERING, N.B.; SINGH, U.; GODWING, D.C.; BAER, B.; BOOTE, K.J.; RITCHIE, J.T.; WHITE, J.W. Crops models. In: TSUJI, G.Y.; UEHARA, G.; BALAS, S. DSSAT v3, support system for agrotechnology transfer. Honolulu: University of Hawaii, v. 2, p.95-244, 1994.
- JABEEN, F.; ASIF, M.; IFTIKHAR, A.; SALMAN, M. Temperature trends and its impacts on Zea Mays (Maize) crop in Faisalabad city through DSSAT-CERES-Maize model. **Scientia Agriculturae**, Faisalabad, v. 17, p.8-14, 2017.
- JUSTINO, F.; OLIVEIRA, E.C.; RODRIGUES, R.A.; GONÇALVES, P.H.L.; SOUZA, P.J.O.P; STORDAL, F.; MARENGO, J.; SILVA, T.G.; DELGADO, R.C.; LINDEMANN, D.S.; COSTA, L.C. Mean and interannual variability of maize and soybean in Brazil under global warming conditions. **American Journal of Climate Change**, Chicago, v. 2, p.237-253, 2013.
- KEATING, B.A.; ROBERTSON, M.J.; MUCHOW, R.C; HUTH, N.I. Modelling sugarcane production systems I. Development and performance of the sugarcane module. **Field Crops Research**, Amsterdam, v.61, p. 253-271, 1999.
- KEATING, B.A.; CARBERRY, G.L.; HAMMER, G.L.; PROBERT, M.E.; ROBERTSON, M.J.; HOLZWORTH, D.; HUTH, N.I.; HARGREAVES, J.N.G.; MEINKE, H.; HOCHMAN, Z.; MCLEAN, G.; VERBURG, K.; SNOW, V.; DIMES, J.P.; SILBURN, M.; WANG, E.; BROWN, S.; BRISTOW, K.L.; ASSENG, S.; CHAPMAN, S.; MCCOWN, R.L.; FREEBAIRN, D.M.; SMITH, C.J. An overview of APSIM, a model designed for farming systems simulation. **European Journal Agronomy**, Amsterdam, v. 18, p. 267-288, 2003.
- KINIRY, J. R. Maize physics development. In: ASA-CSSA-SSSA. Modeling Plant and Soil systems. **Agronomy Monographs**, Madison, v.31, p. 55-71, 1991.
- KINIRY, J.R.; WILLIAMS, J.R.; VANDERLIP, R.L.; ATWOOD, J.D.; REICOSKY, D.C.; MULLIKEN, J.; COX, W.J.; MASCANI JR., H.J.; HOLLINGER, S.E.; WIEBOLD, W. J. Evalution of two maize models for nine U. S. locations. **Agronomy Journal**, Madison, v.89, p.421-426, 1997.
- KUNZ, J.H.; BERGONCI, J.I.; BERGAMASCHI, H.; DALMAGO, G.A.; HECLER, B.M.M.; COMIRAN, F. Uso da radiação solar pelo milho sob diferentes preparos de solo, espaçamento e

- disponibilidade hídrica. **Pesquisa Agropecuária Brasileira**, Brasília, v.42, p.1511-1520, 2007.
- LIMA, M.G. Calibração e validação do modelo CERES-Maize em condições tropicais do Brasil. **Tese apresentada para obtenção do título de Doutor em agronomia**, Piracicaba: ESALQ-USP, Tese Doutorado, 1995.
- LIU, Z.A.; YANG, X.; HUBBARD, K.G.; LIN, X. Maize potential yields and yield gaps in the changing climate of northeast China. **Global Change Biology**, Oxford, v.18, p.3441-3454, 2012.
- LOBELL, D.B.; CASSMAN, K.G.; FIELD, C.B. Crop yield gaps: their importance, magnitudes, and causes. **The Annual Review of Environment and Resources**, Palo Alto, v.34, 174–204, 2009.
- LOPEZ, J. R.; ERICKSON, J. E.; ASSENG, S.; BOBEDA, E. L. Modification of the CERES grain sorghum model to simulate optimum sweet sorghum rooting depth for rainfed production on coarse textured soils in a sub-tropical environment. **Agricultural Water Management**, Amsterdam, v.181, p. 47-55, 2017.
- LOURENÇONI, R. Calibração e validação do modelo Oryza-APSIM para o arroz de terras altas no Brasil. **Tese apresentada para obtenção do título de Mestre em agronomia**, Piracicaba-SP, 2009.
- LOZADA, B. I.; ANGELOCCI, L. R., Efeito da temperatura do ar e da disponibilidade hídrica do solo na duração de subperíodos e na produtividade de um híbrido de milho. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.7, p.37-43, 1999.
- MAGALHÃES P. C. e SOUZA T. C., Cultivo do milho – Ecofisiologia. **Embrapa Milho e Sorgo**, Sete Lagoas, v.8, 2011.
- MARIN, F.R.; JONES, J.W.; ROYCE, F.; SUGUITANI, C.; DONZELI, J.L.; PALLONE FILHO, W.J.; NASSIF, D.S.P., Parameterization and evaluation of predictions of DSSAT/CANEGRO for sugarcane Brazilian production systems. **Agronomy Journal**, Madison, v.103, p.100-110, 2011.
- MARIN, F.R.; THORBURN, P.J.; COSTA, L.G.; OTTO, R. Simulating long-term effects of trash management on sugarcane yield for Brazilian cropping systems. **Sugar Tech**, Stanford, v.16, p. 164-173, 2013.
- MARTINS M. A. Estimativa de Produtividade das Culturas Do milho e do sorgo a partir de modelos Agrometeorológicos em algumas Localidades da região nordeste do Brasil. **Tese**

- apresentada para obtenção do título de Mestre em meteorologia**, Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, 2012.
- MCCOWN, R. L.; WILLIAMS, J. AUSIM: A cropping system model for operational research. **Biennial Conference on Modeling and Simulation**, Canberra, Australian National University, 1989.
- MONTEIRO, L. A.; SENTELHAS, P. C. Calibration and testing of an agrometeorological model for the estimation of soybean yields in different Brazilian regions. **Acta Scientiarum Agronomy**, Maringá, v.36, p. 265-272, 2014.
- MONTEIRO, L. A.; SENTELHAS, P. C. Potential and actual sugarcane yields in southern Brazil as a function of climate conditions and crop management. **Sugar Tech**, Stanford, v.16, p. 264-276, 2013.
- MONTEITH, J., The quest balance in crop modeling. **Agronomy Journal**, Madison, v.88, p. 695-697, 1996.
- MOORE, P.H. Sugarcane Biology, Yield and Potential for Improvement. **Bioen Workshop on Sugarcane Improvement**, São Paulo: FAPESP, 2009.
- MORGAN, K.T.; ROYCE, F.S. Adaptation of CaneGro sugarcane model to the 2D soil-water option within the DSSAT cropping system model ver. 4.5.2.002. **South African Sugarcane Research Institute**, Mount Edgecombe, v. 87, p.303-313, 2014
- MÜLLER, A.G.; BERGAMASCHI, H. Eficiências de interceptação, absorção e de uso da radiação fotossinteticamente ativa pelo milho (*Zea mays* L.), em diferentes disponibilidades hídricas. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.13, p. 27-33, 2005.
- NASSIF, D.S.P.; MARIN, F.R.; FILHO, W.J.P.; RESENDE, R.S.; PELLEGRINO, G.P. Parametrização e avaliação do modelo DSSAT/CaneGro para variedades brasileiras de cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, p.311-318, 2012.
- NEGM, L. M.; YOUSSEF, M. A.; JAYNES, D. B. Evaluation of DRAINMOD-DSSAT simulated effects of controlled drainage on crop yield, water balance, and water quality for a corn-soybean cropping system in central Iowa. **Agricultural Water Management**, Amsterdam, v.187, p. 57-68, 2017.
- PADILHA, F.A. Desempenho de híbridos de milho em dois níveis de investimento tecnológico na região de Sete Lagoas – MG. **Dissertação apresentada para a obtenção do título de Mestre em Ciências Agrárias**, Sete Lagoas, 2014.

- PAGANI, V.; STELLA, T.; GUARNERI, T.; FINOTTO, G.; BERG, M.V.D.; MARIN, F.R.; ACUTIS, M.; CONFALONIERI, R. Forecasting sugarcane yields using agro-climatic indicators and CaneGro model: A case study in the main production region in Brazil. **Agricultural Systems**, Amsterdam, v. 154, p.45-52, 2017.
- PASCALE, A.J. Mapa fenológico do milho en la Republica Argentina. **Meteoros**, Buenos Aires, v.3, p. 383-394, 1953.
- PEAK, A. S.; ROBERTSON, M. J.; BIDSTRUP, R. J. Optimizing maize plant population and irrigation strategies on the Darling Downs using the APSIM crop simulation model. **Australian Journal of Experimental Agriculture**, Collingwood, v.48, p. 313-325, 2008.
- PEREIRA, A.R.; ANGELOCCI, L.R.; SENTELHAS, P.C. Agrometeorologia: fundamentos e aplicações práticas. **Livraria e Editora Agropecuária**, Guaíba, p.478, 2002.
- PINTO, H.M.; COSTA, L.G.; DAMAME, D.; MARIN, F.R. Efeitos das mudanças climáticas para a cana-de-açúcar com base no modelo APSIM-Sugarcane. **VI Congresso Interinstitucional de Iniciação Científica**, Jaguariúna, 2012.
- PRIESTLEY, C.H.B., TAYLOR, R.J. On the assessment of surface heat flux and evapotranspiration, using large scales parameters. **Monthly Weather Review**, New York, v.100, p. 81-92, 1972.
- PROBERT, M.E.; DIMES, J.P.; KEATING, B.A.; DALAL, R.C.; STRONG, W.M. APSIMs water and nitrogen modules and simulation of the dynamics of water and nitrogen in fallow systems. **Agricultural Systems**, Amsterdam, v.56, p. 1-28, 1998.
- RABBINGE, R. The ecological background of food production. Em: Chadwick, D.J., Marsh, J. Crop Protection and Sustainable Agriculture. **Ciba Foundation Symposium**, Chicester, v.177, p. 2-29, 1993.
- REYNOLDS, J.F. Some misconceptions of mathematical modeling. **Plant Physiology**, Nova York, v.10, p. 41-44, 1979.
- RITCHIE, J.T. Model for predicting evaporation from a row crop with incomplete cover. **Water resources research**, Colorado, v.8, p. 1204-1213, 1972.
- RITCHIE, S. W.; HANWAY, J. J.; BENSON, G. O. How a corn plant develops. **Special Bulletin**, Iowa, n. 48. 1993.
- SANGOI, L. Understanding plant density effects on maize growth and development: an importante issue to maximize grain yield. **Ciência Rural**, Santa Maria, v.31, p. 159-168. 2000.

- SANGOI, L.; GRACIETTI, M.A.; RAMPAZZO, C.; BIANCHETTI, P. Response of Brazilian maize hybrids from different eras to change in plant density. **Field Crops Research**, Amsterdam, v. 79, p.39-51, 2002.
- SANGOI, L.; SILVA, P. R. F. Densidade e arranjo populacional em milho. Em: **Seminário nacional de milho safrinha**, 2006. Disponível em: <http://www.riberkws.com/public/pdf/densidade.pdf>
- SANS, L. M. A.; MORAIS, A. V. C.; GUIMARÃES, D. P. Sistema de produção, zoneamento agrícola. **Embrapa Milho e Sorgo**, Sete Lagoas, 2006.
- SANTANA, C.B; ANDRADE, C.L.T.; AMARAL, T.A.; SILVA, D.F.; MOURA, B.F.; CASTRO, L.A. Parametrização do modelo Ceres-Maize para cultivares de milho. **Embrapa Milho e Sorgo**, Sete Lagoas, 2010.
- dos SANTOS, D. L.; SENTELHAS, P. C. Climate change scenarios and their impact on water balance and sugarcane yield in southern Brazil. **Sugar Tech**, Stanford, v.16. p.356-365, 2013.
- SCHONS, A.; STRECK, N.A.; STORK, L.; BURIOL, G.A.; ZANON, A.J. PINHEIRO, D.G.; KRAULICH, B. Arranjos de plantas de mandioca e milho em cultivo solteiro e consorciado: crescimento, desenvolvimento e produtividade. **Bragantia**, Campinas, v. 68, p.155-167, 2009.
- SENTELHAS, P. C.; BATISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A. C.; NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **Journal of Agricultural Science**, Cambridge, p.1-18, 2015.
- SHIM, D.; LEE, K.J.; LEE, B.W. Response of phenology – and yield-related traits of maize to elevated temperature in a temperate region. **The Crop Journal**, Amsterdam, v. 5, p.305-316, 2017.
- SINGH, P. K.; SINGH, K. K.; BHAN, S. C.; BAXLA, A. K.; SINGH, S.; RATHORE, L. S.; GUPTA, A. Impact of projected climat change on rice (*Oryza sativa* L.) yield using CERES-rice model in a diferente agroclimatic zones of India. **Current Science**, Bengaluru, v.112, p. 108-115, 2017.
- SKOCAJ, D.M., HURNEY, A.P., INMAN-BAMBER, N.G., SCHROEDER, B.L., EVERINGHAM, Y.L. Modelling sugarcane yield response to applied nitrogen fertiliser in a wet tropical environment. **Australian Society of Sugarcane Technologists**, Mackay, v.35, p. 1-9, 2013.

SOLER, C. M. T., Uso do Modelo Ceres-Maize para Previsão de Safra do Milho “Safrinha”.

Tese apresentada para obtenção do título de Doutor em agronomia, Piracicaba: ESALQ-USP, 2004.

SOLER, C. M. T.; SENTELHAS, P. C.; HOOGENBOOM, G. Thermal time for phonological development of four maize hybrids grown off-season in a subtropical environment. Cambridge. **Journal of Agricultural Science**, Cambridge, v.143, p. 169-182, 2005.

SOLER, C.M.T; SENTELHAS, P.C.; HOOGENBOOM, G. The impact of El niño southern oscillation phases on off-season maize yield for a subtropical region of Brazil. **International Journal of Climatology**, Oxford, v.30, p.1056-1066, 2009.

STRECK, N.A.; LAGO, I.; SAMBORANHA, F., K.; GRABRIEL, L.F.; SCHWANTES, A.P.; SCHONS, A. Temperatura base para aparecimento de folhas e filocromo na variedade de milho BRS Missões. **Ciência Rural**, Santa Maria, v.39. p.224-227, 2009.

SUN, H.; SHEN, Y.; YU, Q.; FLERCHINGER, G.N.; ZHANG, Y.; LIU, C.; ZHANG, X. Effect of precipitation change on water balance and WUE of the winter weat-summer maize rotation in the north China Plain. **Agricultural Water Management**, Amsterdam, v. 97, p.1139-1145, 2010.

TAIZ, L.; ZEIGER, E. Fisiologia Vegetal, 5ª Edição. **Artmed**, Porto Alegre, p. 954, 2013.

THORNTON, P.K.; BOWEN, W.T.; RAVELO, A.C.; WILKENS, P.W.; FARMER, G.; BROK, J.; BRINK, J.E. Estimating millet production for famine early warning: an application of crop simulation modeling using satellite and ground-based data in Burkina Faso. **Agricultural and Forest Meteorology**, Amsterdam, v.83, p.95-112, 1997.

TOLLERNAR, M., DAYNARD, T.B., HUNTER, R.B. Effect of temperature on rate of leaf appearance and flowering date in maize. **Crop Science**, Madison, v. 19. p.363-366, 1979.

VAN ITTERSUM, M.K. & RABBINGE, R. Concepts in production ecology for analysis and qualification of agricultural input-output combinations. **Field Crops Research**, Amsterdam, v.52, p.197–208, 1997.

VAN ITTERSUM, M.K., CASSMAN, K.G., GRASSINI, P., WOLF, J., TITTONELL, P., HOCHMAN, Z., Yield gap analysis with local to global relevance—a review. **Field Crops Research**, Amsterdam, v.143, p.4–17, 2013.

VARLET-GRANCHER, C. et al. Mise au point: rayonnement solaire absorbé ou intercepté par un couvert végétal. **Agronomie**, Paris, v.9, p. 419-439, 1989.

- WACLAWOVSKY, A.J.; SATO, P.M.; LEMBKE, C.G.; MOORE, P.H.; SOUZA, G.M. Sugarcane for bioenergy production: an assessment of yield and regulation of sucrose content. **Plant Biotechnology Journal**, Oxford, v.8, p.263-276, 2010.
- WANG, J.; WANG, E.; YANG, X.; ZHANG, F.; YIN, H. Increased yield potential of wheat-maize cropping system in the north China plain by climate change adaptation. **Climatic Change**, Van Godewijckstraat, v.113, p. 825-840, 2012.
- XIONG, W.; HOLMAN, I.; CONWAY, D.; LIN, E.; LI, Y. A crop model cross calibration for use in regional climate impacts studies. **Ecological Modeling**, Amsterdam, v. 2013, p.365-380, 2008.
- YAMADA, T. O nitrogênio e o potássio na adubação da cultura do milho. **Informações Agronômicas**, Piracicaba, n. 78, p. 1-4, jun. 1997.
- YANG, H.; GRASSINI, P.; CASSMAN, K.G.; AIKEN, R.M. Improvements to the Hybrid-Maize model for simulating maize yields in harsh rainfed environments. **Field Crops Research**, Amsterdam, v. 204, p.180-190, 2017.
- YIN, X.; KERSEBAUM, K. C.; KOLLAS, C.; MANEVSKIA, K.; BABY, S.; BEAUDOIN, N.; ÖZTÜRK, I.; GAISER, T.; WU, L.; HOFFMANN, M.; CHARFEDDINE, M.; CONRADT, T.; CONSTANTIN, J.; EWERT, F.; CORTAZAR-ATAURI, N. G.; GIGLIO, L.; HLAVINKA, P.; HOFFMANN, H.; LAUNAY, M.; LOUARN, G.; MANDERSCHIED, R.; MARY, B.; MIRSCHEL, W.; NENDEL, C.; PACHOLSKI, A.; PALOSUO, T.; RIPOCHE-WACHTER, D.; RÖTTER, R. P.; RUGET, F.; SHARIF, B.; TRNKA, M.; VENTRELLA, D.; WEIGEL, H.; OLESEN, J. E. Performance of process-based models for simulation of grain N in crop rotation across Europe. **Agricultural Systems**, Amsterdam, v.154, p. 63-77, 2017.
- ZHAO, W.; LIU, B.; ZHANG, Z. Water requirements of maize in the middle Heihe River basin, China. **Agricultural Water Management**, Amsterdam, v. 97, p.215-223, 2010.
- ZHANG, L., G.R. WALKER, AND W.R. DAWES. Water balance modeling: Concepts and applications. In: MEVICAR, T.R.; RUI, L.; WALKER, J.; FITZPATRICK R.W.; CHANGMING, L. Regional Water and Soil Assessment for Managing Sustainable Agriculture in China and Australia. **ACIAR**, Canberra, p.31-47, 2002.

2. AVALIAÇÃO DE DADOS METEOROLÓGICOS EM PONTO DE GRADE E SEUS IMPACTOS NA ESTIMAÇÃO DA PRODUTIVIDADE POTENCIAL DA CULTURA DO MILHO

Resumo

A grande quantidade de falhas e a baixa disponibilidade de dados meteorológicos de qualidade fazem com que, cada vez mais, novos sistemas de geração de dados meteorológicos sejam testados. Dentre as diversas fontes alternativas de informações meteorológicas, temos os dados oferecidos em sistemas de ponto de grade, tanto via sistemas de interpolação quanto sistemas de obtenção de dados remotamente. Dentre esses tipos de fonte de dados em pontos de grade, o NASA-POWER e o *DailyGridded* vêm ganhando destaque em sua aplicação nos trabalhos de modelagem de culturas agrícolas. Dessa forma, o presente estudo teve por objetivos: i) avaliar o desempenho de dois sistemas de obtenção de dados meteorológicos via ponto de grade: NASA-POWER e *DailyGridded*, em diferentes escalas temporais (anual, mensal, decendial e diária), a fim de validar a criação de estações meteorológicas virtuais; ii) avaliar o impacto do uso dos dados provenientes desses sistemas na estimativa da produtividade potencial do milho, por meio do modelo MZA-FAO, devidamente calibrado. Para tal, dados de estações meteorológicas de superfície, em escala diária, de 11 localidades brasileiras foram coletados e comparados aos dados extraídos dos sistemas NASA-POWER e *DailyGridded* e posteriormente aplicados na estimativa da produtividade potencial do milho. Dos sistemas em ponto de grade testados o *DailyGridded* mostrou desempenho superior, até mesmo para variáveis como chuva e vento, apontando índices de confiança (C) superiores a 0,65 e 0,50, respectivamente. Durante a simulação da produtividade potencial do milho por meio do modelo MZA-FAO, comparando-se os resultados das simulações feitas com dados meteorológicos medidos com os resultados das simulações feitas com dados meteorológicos em ponto de grade, também se observou superioridade do sistema *DailyGridded*, que apresentou erros absolutos médios inferiores a 300 kg ha⁻¹ e índice C = 0,97.

Palavras-chave: Dados meteorológicos; NASA-POWER; *DailyGridded*; Modelagem e simulação de culturas

Abstract

The large number of failures and low availability of high quality meteorological data have requiring, more and more, the test and use of meteorological data generation systems. Among the sources of alternative weather information, there is the gridded data, which are generated by

interpolation systems and/or remotely data retrieval systems. Among these different data sources, NASA-POWER and DailyGridded have been applied in crop simulations. The objective of this study was to evaluate the performance of two weather data systems: NASA-POWER and DailyGridded, in different time scales (annual, monthly, decennial and daily), in order to validate the use of virtual weather stations; ii) to evaluate the impact of these gridded data to estimate maize potential yield, through the AEZ-FAO crop simulation model, properly calibrated. For that, daily weather data from 11 Brazilian locations were collected and compared to the data extracted from NASA-POWER and DailyGridded systems and later applied to estimate the maize potential yield. DailyGridded data showed a better performance, even for variables such as rainfall and wind speed, indicating confidence indexes (C) higher than 0.65 and 0.50, respectively. When gridded data were used as input for maize potential yield simulation, the results showed that DailyGridded system was better to replace observed data, with lower mean absolute errors ($< 300 \text{ kg ha}^{-1}$) and higher confidence index ($C = 0.97$).

Keywords: Weather data; NASA-POWER; DailyGridded; Crop simulation models

2.1. Introdução

Dados meteorológicos de qualidade, usualmente na escala diária, são essenciais para o emprego de modelos de simulação de culturas, visando a estimação da produtividade. A qualidade e a confiabilidade desses dados dependem da sua origem, podendo ser mais uma fonte de incertezas dentre as demais que acompanham a simulação da produtividade das culturas agrícolas (Aggarwal, 1995; Rivington et al., 2006 e Bai et al., 2010). Quando o objetivo é a simulação da produtividade de culturas em grandes áreas, além da variabilidade temporal dos dados meteorológicos deve-se considerar a variabilidade espacial, a qual pode trazer ainda mais incertezas às simulações (de Wit e van Diepen, 2008).

Atualmente, existem diversas fontes com séries históricas de dados meteorológicos que são passíveis de serem utilizadas em estudos com modelos de simulação de culturas, dentre as quais se têm: 1) séries oriundas das estações meteorológicas de superfície, que disponibilizam dados medidos com alta precisão, porém, normalmente em densidade insuficiente e muitas vezes com falhas que limitam seu uso; 2) séries provenientes da interpolação de dados meteorológicos de diversas redes de estações meteorológicas, gerando séries históricas por ponto de grade, com resolução espacial podendo variar de $0,25^\circ$ a 1° . Essas séries apresentam como limitação o fato de não serem atualizadas em

tempo real, já que dependem da obtenção de dados de outras fontes; 3) séries geradas a partir de modelos numéricos (NWP), as quais normalmente apresentam baixa resolução da grade de simulação dos dados, da ordem de 2° , o que acaba gerando baixa correlação desses dados modelados com aqueles medidos em superfície. Isso torna trabalhoso o tratamento desse tipo de banco dados para que possam ser usados como dados meteorológicos válidos (Bates et al., 1998 e Charles et al., 2004); 4) séries com base em dados de satélites, como o NOAA-AVHRR, o MeteoSat e o NASA *Prediction of Worldwide Energy Resources* (NASA/POWER), com alta capacidade de atualização no banco de dados (alguns satélites tem um intervalo de atualização de 30 minutos) e fornecendo dados diários de todas as variáveis meteorológicas exigidas como dados de entrada em modelos de simulação de culturas. O uso de séries de dados meteorológicos obtidos por satélite ainda não é amplamente utilizado em estudos agroclimáticos, tanto no exterior como no Brasil, porém isso vem se difundindo cada vez mais rapidamente, como vemos nos estudos realizados por de Wit e van Diepen (2008), Bai et al. (2010), van Wart et al. (2013) e Monteiro e Sentelhas (2017).

No Brasil, a maioria dos dados de estações meteorológicas de superfície são provenientes do Instituto Nacional de Meteorologia (INMET), o qual fornece dados de temperatura máxima, mínima e média, radiação solar ou insolação, chuva, umidade relativa e velocidade do vento. O INMET oferece por meio do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) o acesso aos dados de todas as variáveis meteorológicas a partir de 1961. Esses dados são provenientes de estações meteorológicas convencionais distribuídas em 265 localidades. A partir dos anos 2000, o INMET também começou a operar uma rede de estações meteorológicas automáticas, fornecendo dados horários e diários para mais de 530 locais do Brasil. Apesar de parecer um número satisfatório de estações meteorológicas, essa rede pode ser considerada de baixa densidade, já que esse número resulta em, aproximadamente, 0,001 estação para cada 100 km^2 . A Agência Nacional de Águas (ANA) também disponibiliza dados de chuva de estações pluviométricas instaladas em todo o país.

O sistema NASA/POWER (NP) fornece dados meteorológicos em ponto de grade para todo o globo terrestre, com uma cobertura de 1° de latitude por 1° de longitude e costumam ser atualizados num intervalo de uma a duas semanas, sendo que a maioria das variáveis meteorológicas é oferecida desde julho de 1983. O sistema tem como objetivo sintetizar e analisar dados meteorológicos em escala global. Ele surgiu da união de diversos

outros projetos, como o *Nasa World Climate Reserch Program* (WCRP); o *Global Energy and Water Cycle Experiment* (GEWEX); o *Surface Radiation Budget* (SRB); o *Global Modeling and Assimilation Office* (GMAO) e o *Goddard Earth Observing System* (GEOS), disponibilizando dados mensais, diários e de três em três horas (Stackhouse et al., 2015). A Tabela 2.1 apresenta as variáveis meteorológicas e suas fontes no sistema NASA/POWER.

Tabela 2.1. Variáveis meteorológicas disponíveis em ponto de grade de $1^\circ \times 1^\circ$ no sistema NASA/POWER.

Variável	Fonte	Intervalo de Tempo	Atualização
Temp. °C (max; min; média)	GEOS4	Jan/1983 – Dez/2007	Diária
	GEOS5	Jan/2008 – presente	
Chuva	GPCP	Jan/1997 – presente	≤ 2 meses
Radiação Solar	GEWEX SRB	Jul/1983 – Dez/2007	Diária
	FLASHFlux	Jan/2008 – presente	
Temp. do ponto de orvalho	GEOS4	Jan/1983 – Dez/2007	Diária
	GEOS5	Jan/2008 – presente	
Vento	GEOS4	Jan/1983 – Dez/2007	Diária
	GEOS5	Jan/2008 – presente	

Fonte: Adaptado de White et al. (2011).

Além do sistema NASA/POWER, existem outras fontes de dados em ponto de grade como o sistema de dados interpolados para o Brasil, desenvolvido por Xavier et al. (2015) e denominado de *DailyGridded* (DG). Os autores disponibilizaram um banco de dados em ponto de grade com uma resolução de $0,25^\circ$, para o período de 1980 a 2013. Nesse trabalho foram utilizados 3625 pontos de coleta de chuva e 735 estações meteorológicas para gerar as interpolações. Diversos métodos de interpolação foram testados e utilizados para cada variável meteorológica, possibilitando a escolha do método que mais se ajustou para cada uma delas. Os autores empregaram um sistema de validação cruzada dos dados, dando ainda mais consistência aos resultados obtidos. A metodologia completa e maiores detalhes dos procedimentos aplicados podem ser encontradas em Xavier et al. (2015).

Considerando-se que a cobertura de estações meteorológicas de superfície no Brasil é ainda pouco densa e que as séries históricas dessas estações, na maioria das vezes, apresentam falhas que inviabilizam seu uso para simulação das produtividades agrícolas a partir de modelos de simulação, o presente estudo teve por objetivo avaliar o desempenho de duas bases de dados em ponto de grade (NASA/POWER e *DailyGridded*) no preenchimento de falhas e na criação de séries históricas de dados meteorológicos (virtuais) para fins de estudos agrometeorológicos, empregando-se, para tanto, a comparação entre os dados observados e estimados das variáveis meteorológicas. Além disso, avaliaram-se os

impactos dos desses dois sistemas na estimação da produtividade potencial da cultura do milho.

2.2. Material e métodos

Com a intenção de avaliar os dados meteorológicos de duas fontes em ponto de grade, NASA/POWER (Stackhouse et al., 2015) e *DailyGridded* (DG), para o preenchimento de falhas em séries de estações meteorológicas e também para a criação de estações meteorológicas virtuais, foram selecionadas 11 estações meteorológicas do INMET em diferentes estados (Tabela 2.2) para se proceder uma análise comparativa. As variáveis meteorológicas que foram objeto das comparações foram: Radiação Solar (Q_g , MJ m⁻¹ dia⁻¹); Temperatura máxima (T_{max} , °C); Temperatura mínima (T_{min} , °C); Chuva (P , mm dia⁻¹); Velocidade do vento a 2m (u_2 , m s⁻¹) e Umidade relativa (UR, %).

Tabela 2.2. Localidades para as quais se selecionou as estações meteorológicas do INMET para a análise comparativa entre dados observados e os provenientes de pontos de grade, fornecidos pelos sistemas NASA/POWER e *DailyGridded*.

Cidade	UF	Latitude Sul (graus e décimos)	Longitude Oeste (graus e décimos)	Altitude (metros)
Balsas	MA	08,24	46,34	283
Barreiras	BA	12,02	45,52	452
Catalão	GO	17,93	47,67	835
Correntina	BA	13,48	45,41	575
Diamantino	MT	14,10	56,81	269
Ipameri	GO	17,51	48,05	800
Jatai	GO	17,91	51,71	663
Londrina	PR	23,51	51,11	610
Pelotas	RS	31,78	52,41	013
Porto Nacional	TO	10,54	48,50	212
Rio Verde	GO	17,74	51,04	748

Os dados foram coletados na escala diária e agrupados também nas escalas decenal, mensal e anual. As comparações entre os bancos de dados foram feitas nessas quatro escalas de tempo. Para que fosse possível comparar a radiação solar entre os bancos de dados, a insolação, fornecida pelas estações do INMET, foi convertida em radiação solar global empregando-se o método de Angström-PreScott, descrito por Allen et al. (1998) e com os coeficientes sugeridos pelos mesmos autores ($a = 0,25$ e $b = 0,50$). Empregando-se sempre como referência os dados meteorológicos observados pelas estações do INMET, o desempenho dos dados de ponto de grade foi avaliado pelos seguintes erros e índices estatísticos: Erro médio (EM); Erro absoluto médio (EAM); Raiz quadrada do erro médio

(RMSE); Índice de concordância 'd' de Willmott (1981); Coeficiente de determinação (R^2) e Índice de confiança 'C' de Camargo e Sentelhas (1997).

A coleta dos dados foi feita para o período compreendido entre 1980 e 2013. Não necessariamente o mesmo período foi avaliado em todas as localidades, já que o propósito desta etapa foi validar os dados em grade quando comparados aos dados observados e não a variabilidade e homogeneidade do período em questão.

A fim de confirmar a validade dos dados meteorológicos de ponto de grade, fez-se uso do modelo de simulação de produtividade conhecido como Modelo da Zona Agroecológica (MZA), muitas vezes associado a FAO e proposto por Doorenbos e Kassam (1979), aonde os dados meteorológicos de entrada foram provenientes da base de dados do INMET e das bases de dados em grade (NASA/POWER e *DailyGridded*). Seguindo o mesmo protocolo de Monteiro (2015), a chuva não foi utilizada como dado de entrada nessa simulação, já que essa é uma das variáveis meteorológicas que mais tem influência nos resultados dos modelos de simulação de produtividade e a que mais tem variabilidade quando comparamos os dados medidos com dados em ponto grade. Dessa forma, foi calculada apenas a produtividade potencial (PP) para a cultura de milho. Os mesmos erros e índices estatísticos citados anteriormente também foram aplicados para avaliar essa etapa da análise.

Para estimar a PP da cultura do milho pelo MZA-FAO, foram consideradas as seguintes variáveis meteorológicas de entrada: temperatura média do ar (T_{med}); irradiância solar extraterrestre (Q_0); insolação (n); e fotoperíodo (N). As variáveis N e Q_0 foram estimadas de acordo Allen et al. (1998), enquanto que os dados de n foram obtidos das séries históricas do INMET ou, quando ausentes, estimados a partir da integração das equações de estimação de Q_g de Angström-Prescott (Allen et al., 1998) e Hargreaves e Samani (1982).

O modelo de produtividade potencial (PP) foi programado em ambiente R na escala diária de acordo com a seguinte equação:

$$PP = \sum_{i=1}^m (PPBp_i \cdot c_{iaf} \cdot c_{resp} \cdot c_{colh} \cdot c_{um}) \quad (2.1)$$

em que: i varia de 1 a m ; m representa os dias do ciclo; PPBp é a produtividade potencial bruta padrão de matéria seca para uma cultura hipotética, com IAF = 5, em $\text{kg MS ha}^{-1} \text{dia}^{-1}$; PP é a produtividade potencial final da cultura, em kg ha^{-1} ; c_{iaf} é o coeficiente para correção do índice de área foliar (IAF); c_{resp} é o coeficiente de correção para respiração de manutenção da cultura; c_{colh} é o coeficiente relativo à parte colhida ou índice de colheita (no caso, grãos); c_{um} é o coeficiente que considera a umidade da parte colhida.

A duração do ciclo e o IAF das fases fenológicas utilizadas foram obtidos dos trabalhos de Doorenbos e Kassam (1979), Fancelli (1991) e Manfron et al. (2003). A Tabela 2.3 apresenta a duração de cada uma das fases fenológicas em função da idade da cultura do milho e seus respectivos valores de IAF.

Tabela 2.3. Duração das fases fenológicas da cultura do milho em função de sua idade e seus respectivos valores de índice de área foliar (IAF).

Fase Vegetativa	Dias após emergência	IAF
0 – Germinação/Emergência	7	0,00
1 – Plantas com 4 folhas abertas	14	0,01
2 – Plantas com 8 folhas abertas	28	1,00
3 – Plantas com 12 folhas abertas	42	3,00
4 – Emissão do pendão	54	4,50
5 – Florescimento e polinização	63-70	5,50
Fase Reprodutiva	Dias após polinização	IAF
6 – Grãos leitosos	12	5,50
7 – Grãos pastosos	24	5,00
8 – Grãos farináceos	36	2,50
9 – Grãos duros	48	2,00
10 – Maturação fisiológica	55	1,00
Total de dias do ciclo/ IAF médio (ponderado)	125	3,30

Fonte: Adaptado de: Doorenbos e Kassam (1979); Fancelli (1986); Manfron et al. (2003)

A produtividade potencial bruta padrão de uma cultura hipotética com IAF = 5 (PPBp), em $\text{kg MS ha}^{-1} \text{dia}^{-1}$, foi calculada por meio do somatório da produtividade potencial bruta sob ausência de nuvens, ou seja, céu limpo (PPBc), e quando o céu estava nublado (PPBn) no período considerado. PPBc e PPBn foram estimadas a partir das seguintes equações:

$$PPBc = (107,2 + 8,604 \cdot Q_o) \cdot \frac{n}{N} \cdot cTc \quad (2.2)$$

$$PPBn = (31,7 + 5,234 \cdot Q_o) \cdot (1 - n/N) \cdot cTn \quad (2.3)$$

em que: n é o número de horas efetivas com brilho solar, em $h \text{ dia}^{-1}$; N é o fotoperíodo diário, em $h \text{ dia}^{-1}$; Q_o é a irradiância solar extraterrestre, em $MJ \text{ m}^{-2} \text{ dia}^{-1}$; cTc e cTn representam os fatores de correção para a T_{med} e metabolismo de espécie C4 nos dias de céu limpo e céu nublado, respectivamente, como apresentado por Barbieri e Tuon (1992):

Se $T_{med} \geq 16,5^\circ\text{C}$:

$$cTc = -4,16 + 0,4325 \cdot T_{med} - 0,00725 \cdot T_{med}^2 \quad (2.4)$$

$$cTn = -1,064 + 0,173 \cdot T_{med} - 0,0029 \cdot T_{med}^2 \quad (2.5)$$

Se $T_{med} < 16,5^\circ\text{C}$:

$$cTc = -9,32 + 0,865 \cdot T_{med} - 0,0145 \cdot T_{med}^2 \quad (2.6)$$

$$cTn = -4,16 + 0,4325 \cdot T_{med} - 0,00725 \cdot T_{med}^2 \quad (2.7)$$

em que: T_{med} é a temperatura média do ar, em $^\circ\text{C}$.

A área foliar de uma cultura varia ao longo do seu ciclo, para tanto, o coeficiente de correção da PPBp relativo ao IAF da cultura (c_{iaf}) foi calculado empregando-se a seguinte equação:

$$c_{iaf} = 0,0093 + 0,185 \cdot IAF_{max} - 0,0175 \cdot IAF_{max}^2 \quad (IAF_{max} \geq 5; c_{iaf} = 0,5) \quad (2.8)$$

em que: c_{iaf} é o coeficiente de correção para o índice de área foliar; IAF_{max} representa o valor máximo de IAF durante ciclo considerado.

Já o coeficiente utilizado para correção da respiração de manutenção de cultura (c_{resp}) é uma função da T_{med} , em que duas condições são consideradas:

Para $T_{med} \geq 20^\circ\text{C}$, admite-se $c_{resp} = 0,5$

Para $T_{med} < 20^\circ\text{C}$, admite-se $c_{resp} = 0,6$

O coeficiente de colheita (c_{colh}) é responsável pela conversão da matéria seca total em matéria seca útil ou colhida. No presente estudo, como o produto de interesse são os grãos, este foi considerado como sendo 50% da massa total da planta de milho (Doorenbos e Kassam, 1979; Monteiro et al., 1998; Durães et al., 2002).

Como a PPBp é estimada na base de matéria seca, foi necessário considerar no modelo um coeficiente com o intuito de simular a umidade dos grãos a serem colhidos. A equação relativa ao coeficiente para contabilizar a teor de água presente nos grãos (c_{um}) é:

$$c_{um} = [1 - 0,01 \cdot U(\%)]^{-1} \quad (2.9)$$

em que: U (%) representa a umidade dos grãos em porcentagem. Foi empregado um U (%) de 13%, conforme Doorenbos e Kassam (1979) e EMBRAPA (2010). Foram simuladas uma semeadura por dia ao longo dos anos estudados de cada localidade analisada, considerando um ciclo de 140 dias para cada uma delas.

2.3. Resultados e discussão

2.3.1. Variáveis meteorológicas

As tabelas 2.4 e 2.5 apresentam os resultados das comparações feitas entre o banco de dados do INMET e das duas fontes de dados em ponto de grade, NASA/POWER e *DailyGridded*, respectivamente.

2.3.2. NASA/POWER x INMET

A tabela 2.4 apresenta os índices estatísticos referentes à comparação das variáveis meteorológicas do banco de dados do INMET e do NASA/POWER, nas diferentes escalas de tempo.

Tabela 2.4. Comparação entre os dados meteorológicos observados (INMET) e em ponto de grade, obtidos do sistema NASA/POWER, nas escalas diária, decendial, mensal e anual, e seus respectivos erros e índices de desempenho.

Variável	Escala	EM	EAM	REMQ	d	r	R ²	C
Q _g (MJ m ⁻² d ⁻¹)	Diário	0,55	2,25	3,15	0,90	0,82	0,68	0,74
	Decendial	-0,07	0,47	0,57	1,00	1,00	0,99	0,99
	Mensal	1,24	1,76	3,26	0,77	0,67	0,45	0,51
	Anual	1,86	2,17	4,03	0,67	0,51	0,26	0,34
Chuva (mm)	Diário	1,21	9,38	15,05	0,55	0,32	0,10	0,18
	Decendial	1,50	4,34	6,49	0,75	0,58	0,34	0,43
	Mensal	1,63	2,86	4,18	0,82	0,72	0,52	0,59
	Anual	1,30	1,58	2,12	0,57	0,53	0,28	0,30
T _{min} (°C)	Diário	0,92	1,98	2,67	0,86	0,77	0,59	0,66
	Decendial	0,86	1,49	2,01	0,94	0,84	0,71	0,79
	Mensal	0,86	1,39	1,87	0,94	0,86	0,73	0,80
	Anual	0,81	1,03	1,23	0,94	0,93	0,87	0,88

Variável	Escala	EM	EAM	REMQ	d	r	R ²	C
Tmax (°C)	Diário	-1,28	2,30	2,85	0,86	0,79	0,62	0,68
	Decendial	-1,52	1,97	2,37	0,88	0,86	0,73	0,75
	Mensal	-1,51	1,87	2,24	0,87	0,87	0,75	0,76
	Anual	-1,42	1,64	1,84	0,89	0,93	0,87	0,83
UR (%)	Diário	-7,81	12,81	16,37	0,77	0,68	0,47	0,53
	Decendial	-1,26	4,55	7,54	0,99	0,94	0,89	0,94
	Mensal	0,69	2,43	4,02	1,00	0,94	0,89	0,94
	Anual	-9,91	10,28	12,35	0,68	0,47	0,22	0,32
u2 (m s ⁻¹)	Diário	1,16	1,36	1,65	0,52	0,35	0,12	0,18
	Decendial	0,43	0,74	0,98	0,54	0,33	0,11	0,18
	Mensal	0,43	0,72	0,95	0,50	0,30	0,09	0,15
	Anual	0,44	0,69	0,93	0,37	0,25	0,06	0,09

EM = erro médio; EAM = erro absoluto médio; REMQ = raiz quadrada do erro médio quadrático; d = coeficiente de concordância; R² = coeficiente de determinação e C = índice de confiança.

Na escala diária (a mesma escala que será empregada nos modelos de simulação da PP), a comparação dos dados resultou em razoável precisão (R²) para as variáveis Qg (0,68), Tmax (0,62) e Tmin (0,59) e uma boa acurácia (d) para essas mesmas variáveis (0,90, 0,86 e 0,86, respectivamente). Para Qg, o coeficiente de determinação (R²) variou de 0,41 (Diamantino, MT) até 0,88 (Pelotas, RS); para Tmax, o R² variou de 0,39 (Balsas, MA) até 0,80 (Pelotas, RS) e a Tmin teve variação do coeficiente de determinação entre 0,05 (Balsas, MA e Porto Nacional, TO) até 0,88 (Pelotas, RS). White et al. (2008), comparando dados de 2.500 estações meteorológicas de superfície com os dados do NASA/POWER na escala diária, apontaram que os erros médios encontrados para Tmax e Tmin foram -2,4°C e 1,1°C, respectivamente, valores bem próximos dos obtidos nesse estudo (Tmax = -1,3°C, Tmin = 0,9°C). Na escala decendial, Monteiro (2015) encontrou um coeficiente de determinação de 0,68 quando analisou a temperatura média do ar para seu conjunto de locais, corroborando com os resultados obtidos neste trabalho para Tmax (0,73°C) e Tmin (0,71°C), para a mesma escala. Esses resultados também concordam com os obtidos por White et al. (2008), mostrando que o sistema NASA/POWER tem capacidade de estimar com mais precisão e acurácia os dados de temperatura quando esses são agrupados em escalas de tempo maiores, como a semanal, decendial ou quinzenal.

White et al. (2011) comparou a Qg na escala diária para 295 estações meteorológicas e observou que o sistema NASA/POWER proporcionou resultados bastante satisfatórios, chegando num coeficiente de determinação de 0,86 e um RMSE variando entre

2 e 3 MJ m⁻² dia⁻¹, resultados um pouco melhores dos obtidos neste estudo ($R^2 = 0,68$ e RMSE = 3,15 MJ m⁻² dia⁻¹). Monteiro (2015), trabalhando na escala decendial, encontrou um coeficiente de determinação de 0,70, quando comparou a Qg estimada a partir da insolação com os dados do sistema NASA/POWER. As variáveis chuva, UR e u2 foram as que apresentaram o pior desempenho no sistema NASA/POWER, provavelmente por serem altamente variáveis no espaço e dependerem de fatores relacionados à circulação da atmosfera. Van Wart et al. (2015), ao validar os dados diários de chuva e UR do sistema NASA/POWER comparando esses com dados coletados de estações meteorológicas em 18 localidades espalhadas em quatro continentes, encontrou um coeficiente de determinação que variou, entre 0 até 0,2 para chuva e entre 0,1 e 0,6 para UR, concordando com os resultados obtidos neste estudo.

De um modo geral, vemos que a correlação dos dados aumenta conforme a diminuição da latitude, chegando, em alguns casos, a valores de R^2 na escala diária da ordem de 0,80 para algumas das variáveis meteorológicas avaliadas, conforme apresentado na Figura 2.1. Uma possível explicação para esses resultados é que a área compreendida pela grade de 1° x 1°, no sistema NASA/POWER, diminua nas latitudes mais ao sul, conferindo uma maior precisão por unidade de área. Entretanto, para a UR essa tendência se mostrou invertida. As variáveis que mostraram a maior taxa de melhora com a diminuição da latitude foram a Tmin, seguida da Tmax, apresentando valores de R^2 da ordem de 0,82 e 0,77, respectivamente. Também vemos uma tendência de melhora interessante quando analisamos u2, entretanto, os valores do índice de confiança, mesmo em locais mais ao sul, ainda se mantém muito baixos, variando de 0,06 (Porto Nacional, TO) até 0,41 (Pelotas, RS). Observamos variação no índice de confiança da chuva (b) entre 0,11 (Balsas, MA) e 0,24 (Barreiras, BA) e para UR, o índice C variou de 0,37 (Londrina, PR) até 0,67 (Porto Nacional, TO). Fazendo uma análise similar nos dados apresentados por Monteiro (2015), podemos verificar um comportamento semelhante em seus dados ao descrito pela Figura 2.1. Na Figura 2.2 podemos ver a relação entre cada uma das variáveis meteorológicas observados (INMET) e as de ponto de grade, provenientes do NASA/POWER, em escala diária.

Figura 2.1. Relação entre o índice de confiança 'C' da comparação entre os dados meteorológicos observados e provenientes do NASA/POWER e a latitude das localidades analisadas

Figura 2.2. Relação entre as variáveis meteorológicas Qg (a), Chuva (b), Tmax (c), Tmin (d), UR (e) e u2 (f) obtidas de estações de superfície do INMET e do sistema NASA/POWER para diferentes localidades brasileiras e em escala diária.

Conforme esperado, após análise da Tabela 2.4, notamos grande dispersão nos dados de Chuva (b), UR (e) e u2 (f), sendo as variáveis que apresentaram os piores desempenhos dos índices d (0,55; 0,77 e 0,52, respectivamente) e C (0,18; 0,53 e 0,18, respectivamente). Enquanto que para as variáveis Qg (a), Tmax (c) e Tmin (d), os mesmos índices apresentaram valores mais significantes (d = 0,90(a), 0,86 (c), 0,86 (d); C = 0,74 (a), 0,68 (c), 0,66 (d)). Com exceção da Tmax e UR, todas as variáveis meteorológicas fornecidas pelo NASA/POWER tiveram uma tendência de superestimativa, com EAM percentuais variando entre 7,46 (Tmax) e 120,56% (Chuva). Esses resultados concordam com os

resultados dos trabalhos consultados que fizeram análise comparativa similar com o mesmo banco de dados testado (Zhang et al., 2007; White et al., 2008; Bai et al., 2010; White et al., 2011; van Wart et al., 2013; Monteiro, 2015 e van Wart et al., 2015).

Dessa forma, analisando as Figuras 2.1 e 2.2 conjuntamente aos valores apresentados na Tabela 2.4, vemos o quão dispersos foram os resultados de chuva, UR e u_2 , podendo interferir nos resultados da evapotranspiração de referência e do balanço hídrico. Entretanto, o EM e o RMSE apresentado na análise de u_2 foram da ordem de 1,6 e 1,65 m s^{-1} , respectivamente, o que confere pouca influência no termo aerodinâmico da equação de Penman-Monteith (Allen et al., 1998). Como estratégia de contorno aos dados de chuva, podemos utilizar a rede da Agência Nacional de Águas (ANA) para substituir os valores fornecidos pelo sistema NASA/POWER, já que a Agência possui uma ampla rede de estações coletoras de chuva espalhadas pelo Brasil.

2.3.3. INMET x *DailyGridded*

A Tabela 2.5 apresenta os índices estatísticos referentes à comparação das variáveis meteorológicas do banco de dados do INMET e do *DailyGridded*, nas diferentes escalas de tempo.

Tabela 2.5. Comparação entre os dados meteorológicos observados (INMET) e virtuais, obtidos do *DailyGridded*, em quatro diferentes escalas temporais: diária; decenal; mensal e anual.

Variável	Escala	EM	EAM	REMQ	d	r	R ²	C
Qg (MJ m ⁻² dia ⁻¹)	Diário	0,37	1,10	2,16	0,95	0,92	0,84	0,87
	Decenal	0,42	0,76	1,93	0,93	0,87	0,76	0,81
	Mensal	0,48	0,77	2,08	0,89	0,82	0,67	0,73
	Anual	0,76	0,95	2,48	0,80	0,71	0,50	0,57
Chuva (mm)	Diário	0,13	2,69	6,80	0,85	0,76	0,58	0,65
	Decenal	0,13	1,24	2,23	0,94	0,89	0,80	0,84
	Mensal	0,14	0,82	1,39	0,97	0,93	0,87	0,90
	Anual	0,14	0,38	0,53	0,95	0,88	0,78	0,84
Tmax (°C)	Diário	-0,01	0,09	0,20	1,00	1,00	1,00	1,00
	Decenal	-0,01	0,07	0,13	1,00	1,00	1,00	1,00
	Mensal	-0,01	0,06	0,12	1,00	1,00	1,00	1,00
	Anual	-0,01	0,05	0,10	1,00	1,00	1,00	1,00
Tmin (°C)	Diário	-0,18	0,33	1,06	0,98	0,96	0,92	0,94
	Decenal	-0,03	0,13	0,35	1,00	0,99	0,99	0,99
	Mensal	-0,03	0,12	0,34	1,00	0,99	0,99	0,99
	Anual	-0,03	0,09	0,22	1,00	1,00	0,99	0,99

Variável	Escala	EM	EAM	REMQ	d	r	R ²	C
UR (%)	Diário	0,27	1,68	3,30	1,00	0,94	0,88	0,94
	Decendial	0,60	3,22	4,11	0,97	0,95	0,90	0,92
	Mensal	0,49	3,09	4,02	0,97	0,94	0,89	0,92
	Anual	-0,12	3,00	4,28	0,90	0,81	0,66	0,73
u2 (m s ⁻¹)	Diário	-0,28	0,52	0,69	0,71	0,71	0,51	0,50
	Decendial	-0,25	0,46	0,61	0,70	0,75	0,56	0,52
	Mensal	-0,25	0,44	0,59	0,71	0,76	0,57	0,53
	Anual	-0,24	0,43	0,57	0,71	0,78	0,61	0,55

EM = erro médio; EAM = erro absoluto médio; REMQ = raiz quadrada do erro médio quadrático; d = coeficiente de concordância; R² = coeficiente de determinação e C = índice de confiança.

Os dados do *DailyGridded* apresentaram desempenho muito superior ao banco de dados do NASA/POWER, principalmente para as variáveis Tmax, Tmin e UR, que apresentaram, na escala diária, ótima precisão, R² = 1, 0,92 e 0,88, respectivamente, e acurácia, d = 1, 0,98 e 0,97, respectivamente. Em todas as escalas temporais analisadas, e para todas as variáveis meteorológicas estudadas, o sistema *DailyGridded* foi superior ao NASA/POWER. As tendências de super e subestimativas foram muito sutis nessa análise, sendo que o sistema tendeu a superestimar as variáveis Qg, Chuva e UR e tendeu a subestimar Tmax, Tmin e u2. A variação percentual do EAM também foi muito menor, da ordem de 0,3% para a Tmax até 71,02% para Chuva, quando comparada a variação desse índice na análise do NASA/POWER.

O índice de confiança C também teve classificação superior a ‘bom’ para todas as variáveis testadas, com exceção de u2. Na Figura 2.3 podemos ver a relação entre as variáveis meteorológicas da base de dados do INMET e do sistema *DailyGridded* para as localidades estudadas.

Figura 2.3. Relação entre as variáveis meteorológicas Qg (a), Chuva (b), Tmax (c), Tmin (d), UR (e) e u2 (f) obtidas de estações de superfície do INMET e do sistema *DailyGridded* para diferentes localidades brasileiras.

Dentre as bases de dados testadas e as que foram encontradas na literatura, o desempenho do sistema *DailyGridded* foi sempre superior, mesmo para elementos meteorológicos de alta variabilidade espacial, como a chuva, a UR e até mesmo u2. Por ser uma base de dados relativamente nova e restrita ao uso no Brasil, ainda não foi possível encontrar trabalhos que compararam essa base com dados medidos, no entanto, resultados reportados pelos autores (Xavier et al., 2015), comprovam o excelente desempenho dessa base de dados, tendo ainda como vantagem o fato de disponibilizar os dados com resolução de 0,25°. Diferentemente do ocorrido durante a análise dos dados do NASA/POWER, não foi

notada alteração no desempenho do sistema *DailyGridded* com a variação latitude do local avaliado para a maioria das variáveis meteorológicas (Figura 2.4). Uma possível explicação para isso está relacionada ao tamanho da grade utilizada nesse sistema ($0,25^\circ \times 0,25^\circ$), conferindo maior precisão por área, mesmo em latitudes mais próximas ao Equador.

Figura 2.4. Relação entre o índice de confiança 'C' da comparação entre os dados meteorológicos observados e provenientes do *DailyGridded* e a latitude das localidades analisadas

Para Qg, Tmax, Tmin, UR e u2, a variação da posição geográfica de cada cidade não teve nenhuma influência evidente no desempenho do índice C, de forma que apenas a chuva

apresentou alguma correlação entre a taxa de melhora do desempenho do índice em relação ao aumento da latitude sul. De forma geral, a escala diária apresentou ótimos índices tanto de precisão como de acurácia, mesmo para chuva, com $R^2 = 0,58$ e $d = 0,85$; UR, com $R^2 = 0,88$ e $d = 0,97$ e u_2 , com $R^2 = 0,51$ e $d = 0,71$, o que permite considerar essa base não apenas para o preenchimento de falhas de dados nas séries de estações meteorológicas, mas também no seu uso para gerar séries de dados meteorológicos virtuais para a simulação da produtividade de culturas agrícolas por meio de modelos agrometeorológicos.

2.4. Impacto dos dados meteorológicos em ponto de grade na estimação da produtividade potencial da cultura do milho

A fim de se avaliar o desempenho das bases de dados em ponto de grade (NASA/POWER e *DailyGridded*) na simulação da produtividade potencial da cultura do milho, foi empregado o modelo da zona agroecológica da FAO. A PP de da cultura do milho foi simulada para as 11 localidades estudadas, para o período de 1983 a 2014, considerando-se o banco de dados do NASA/POWER e para o período de 1980 a 2013 para o banco de dados do *DailyGridded*. A seguir são apresentados os dados das simulações para 36 épocas de semeadura por ano, considerando-se os dados meteorológicos observados (INMET) e em ponto de grade (NASA/POWER e *DailyGridded*) para as 11 localidades avaliadas. Foram feitas simulações de semeadura diárias para todas as fontes de dados utilizadas.

2.4.1. INMET x NASA/POWER

A Tabela 2.6 apresenta os resultados de desempenho dos dados do sistema NASA/POWER quando empregados na simulação da PP em comparação com os dados simulados com os dados observados do INMET.

Tabela 2.6. Indicadores estatísticos da comparação entre a produtividade potencial (PP) simulada com dados meteorológicos observados (INMET) e virtuais, obtidos do NASA/POWER (NP).

PP _{NP} -média (kg ha ⁻¹)	11.952,81 (± 2.125)
PP _{INMET} -média (kg ha ⁻¹)	11.287,92 (± 2.450)
EM (kg ha ⁻¹)	656,26
EAM (kg ha ⁻¹)	743,44
RMSE (kg ha ⁻¹)	1.415,47
d	0,91
r	0,94
R ²	0,89
C	0,86

Analisando a Tabela 2.6 pode-se observar que os dados do sistema NASA/POWER se mostraram bastante satisfatórios em estimar a PP da cultura do milho nos diferentes locais de estudo, com ótimas precisão ($R^2 = 0,89$) e acurácia ($d = 0,91$) (Figura 2.5). O EM foi baixo, da ordem de 656,26 kg ha⁻¹, cerca de 5% dos valores médios de PP, o que indica uma leve superestimativa na simulação. O RMSE apresentou um valor de 1.415,47 kg ha⁻¹ enquanto que o EAM ficou em 743,44 kg ha⁻¹, o que representa cerca de 12% e 6% em relação a PP_{INMET} média observada, respectivamente. O índice C também respondeu muito bem aos dados do NASA/POWER, sendo classificado como ótimo. A pouca inconsistência que possa ser apontada pode estar relacionada a necessidade do modelo MZA-FAO transformar a Qg em insolação, através de equações empíricas (Angström-PreScott, descrito por Allen et al., 1998), e não aos dados do sistema de grade em si, mesma situação apontada por Monteiro (2015), o que acaba trazendo algumas incertezas para a simulação.

Figura 2.5. Relação entre a produtividade potencial (PP) estimada com dados meteorológicos do INMET e do sistema NASA/POWER.

Os resultados obtidos neste estudo (Tabela 2.6 e Figura 2.5) mostram que os valores de PP obtidos com os dados do sistema NASA/POWER foram bastante satisfatórios, assim como os observados por Monteiro (2015), ao simular a PA da cana-de-açúcar com dados do sistema NASA/POWER, obtendo valores de R^2 da ordem de 0,7; índice $d = 0,89$ e $RMSE = 10.800 \text{ kg ha}^{-1}$. Van Wart et al. (2015), ao utilizar dados do NASA/POWER para simular a produtividade potencial de milho, arroz e trigo, encontrou uma variação do erro médio em relação aos dados simulados em torno de 10%, valores percentuais de RMSE variando de 19 a 45% em relação aos dados observados e um coeficiente de variação em torno de 0,5. Bai et al. (2010), utilizando o modelo *Hybrid-Maize* na simulação da PP de milho na China com dados no sistema NASA/POWER encontrou uma produtividade média da ordem de 9.300 kg ha^{-1} , um $EM = 1.400 \text{ kg ha}^{-1}$ e um $RMSE = 2.600 \text{ kg ha}^{-1}$ (cerca de 25% em relação aos dados de produtividade observados). Podemos citar ainda o trabalho elaborado por de Wit e van Diepen (2008), que utilizaram dados do satélite EUROSAT para alimentar o modelo WOFOST e simular o acúmulo de massa seca do trigo em três países europeus e encontraram em suas análises erros médios relativos superiores a 15% e valores de R^2 que variaram de 0,5 até 0,8.

A análise dos resultados de desempenho e da relação entre a PP simulada com os dois bancos de dados climáticos, assim como a comparação do desempenho dos trabalhos similares citados (de Wit e van Depen, 2008; Bai et al., 2010; Monteiro, 2015; van Wart et al., 2015), permite afirmar que o sistema NASA/POWER pode ser empregado para simular a

produtividade potencial de milho em diferentes regiões brasileiras. No entanto, para a estimacão da produtividade atingível (PA), ou seja, daquela que considera a penalizacão da PP pelo déficit hídrico, deve-se lançar mão de dados de chuva observados, já que o desempenho do sistema NASA/POWER para gerar esses dados foi ruim na escala diária (EAM = 9,38 mm dia⁻¹; RSME = 15,05 mm dia⁻¹; C = 0,18). Constatacão semelhante foi feita por Monteiro (2015), ao estudar as estimacões de PP e PA da cultura da cana-de-açúcar em diferentes regiões brasileiras ao utilizar essa base de dados.

2.4.2. INMET x *DailyGridded*

A Tabela 2.7 apresenta os resultados do desempenho dos dados do sistema *DailyGridded* quando empregados na simulacão da PP em comparacão com os dados simulados com os dados observados do INMET.

Tabela 2.7. Indicadores estatísticos da comparacão a produtividade potencial (PP) simulada com dados meteorológicos observados (INMET) e virtuais, obtidos do *DailyGridded* (DG).

PP _{DG} -média (kg ha ⁻¹)	11.429,46 (± 2.344)
PP _{INMET} -média (kg ha ⁻¹)	11.290,38 (± 2.450)
EM (kg ha ⁻¹)	139,09
EAM (kg ha ⁻¹)	335,51
RMSE (kg ha ⁻¹)	510,23
d	0,99
r	0,98
R ²	0,96
C	0,97

Analisando a Tabela 2.7 pode-se observar superioridade notória do desempenho das simulacões de PP da cultura do milho com os dados meteorológicos do sistema *DailyGridded* em comparacão ao NASA/POWER. Os erros foram reduzidos, assim como a dispersão dos dados (Figura 2.6), o que resultou em melhor acurácia, representada pelo índice d = 0,98, e precisão, com um R² = 0,93, resultando em um índice C de 0,95, considerado como “muito bom” por Camargo e Sentelhas (1997). O EAM caiu para menos de 3% quando comparado aos patamares produtivos simulados com os dados meteorológicos do INMET. Os resultados de desempenho desse sistema superaram o apresentado pelo sistema NASA/POWER, assim como o de outros sistemas encontrados na literatura, com abordagem similar à deste estudo (de Wit e van Depen, 2008; Bai et al., 2010; Monteiro, 2015; van Wart et al., 2015). A Figura 2.6 mostra o alto grau de correlacão entre os valores

de PP simulados com dados das estações meteorológicas de superfície e aqueles simulados com dados do sistema *DailyGridded*.

Figura 2.6. Relação entre a produtividade potencial (PP) estimada com dados meteorológicos do INMET e do sistema *DailyGridded*.

A dispersão apresentada na faixa entre 12.000 e 14.000 kg ha⁻¹, com valores de PP simulados pelos dados do *DailyGridded* inferiores daqueles obtidos com os dados do INMET, se referem à localidade de Catalão, GO, onde houve a pior correlação entre os dados meteorológicos e aqueles provenientes do sistema em ponto de grade, podendo ser uma falha na estimativa dos dados pelo modelo ou mesmo uma inconsistência de medida. Para as localidades avaliadas, os dados simulados de PP com dados do sistema *DailyGridded* foram muito próximos dos valores simulados com dados meteorológicos observados, mostrando o potencial de uso desse sistema na simulação da produtividade potencial de milho para as diferentes regiões brasileiras, assim como para outros fins.

Para a estimação da produtividade atingível, a chuva gerada pelo sistema *DailyGridded*, por apresentar um desempenho razoável (EAM = 2,69 mm dia⁻¹; RSME = 6,80 mm dia⁻¹; C = 0,65), poderia até ser empregada, porém, deve-se dar preferência para os dados observados, dada a grande variabilidade espacial que essa variável apresenta. A combinação de dados meteorológicos (Qg, Tmax, Tmin, UR e u2) do sistema *DailyGridded* com dados observados de chuva, normalmente com maior disponibilidade no Brasil, permitiria a criação de uma rede virtual de estações meteorológicas, aumentando, assim, a capacidade de análises agrometeorológicas de qualquer natureza.

2.5. conclusões

Considerando-se os resultados obtidos no presente estudo, conclui-se que:

- a) Apesar das limitações, ambos os bancos de dados avaliados se mostraram capazes de fornecer dados de Tmax, Tmin e Qg de forma satisfatória, sendo que o banco de dados *DailyGridded* mostrou um desempenho superior ao NASA/POWER, apresentando correlação satisfatória mesmo para os elementos meteorológicos chuva e UR. Sendo assim, considerou-se o *DailyGridded* como uma potencial ferramenta para a criação de estações meteorológicas virtuais nas diferentes regiões brasileiras, onde estações meteorológicas de solo forem ausentes;
- b) A PP simulada com ambos os bancos de dados em ponto de grade mostrou ótimos resultados de desempenho, sendo o sistema *DailyGridded* novamente superior ao NASA/POWER. Esses resultados possibilitam trabalhar estimando a PP do milho em escala nacional, gerando um valor a cada ponto de grade de $0,25^\circ \times 0,25^\circ$ com alta confiabilidade e
- c) O bom desempenho do sistema *DailyGridded* em simular a PP do milho associado a possibilidade do uso de dados medidos em solo da chuva fornece uma ferramenta interessante, que possibilita estimar a produtividade atingível (PA) em locais onde existam pontos de coleta de chuva, mitigando o erro gerado durante a simulação ao usar os dados de chuva disponibilizados pelos sistemas de ponto de grade.

REFERÊNCIAS

- AGGARWAL, P.K. Uncertainties in crop, soil and weather inputs used in growth models: Implications for simulated outputs and their applications. **Agricultural Systems**, Amsterdam v.48, p.361–384, 1995.
- ALLEN, R. G., PEREIRA, L. S., RAES, D., SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. FAO: **Irrigation Drainage and Paper**, 56, Roma, p.291, 1998.
- BAI, J., CHEN, X., DOBERMANN, A., YANG, H., CASSMAN, K. G. e ZHANG, F. Evaluation of NASA Satellite- and Model-Derived Weather Data for Simulation of Maize Yield Potential in China. **Agronomy Journal**, Madison, v.102, p. 9-16, 2010.
- BARBIERI, V., TUON, R. L. Metodologia para estimativa da produção potencial de algumas culturas. ESALQ - USP, Piracicaba, p.17, 1992.
- BATES, B. C., CHARLES, S. P., HUGHES, J. P. Stochastic downscaling of numerical climate model simulations. **Environmental Modelling & Software**, Amsterdam, p.325–331, 1998.
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes modelos de estimativa de evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.5, p.89-97, 1997.
- CHARLES, S.P., BATES, B.C., SMITH, I.N., HUGHES, J.P. Statistical downscaling of daily precipitation from observed and modelled atmospheric fields. **Hydrological Processes**, New Jersey, v.18, p.1373–1394, 2004.
- DOORENBOS, J.; KASSAM, A. H. Yield response do water. **FAO: Irrigation and Drainage Paper**, 33, Rome, p.179, 1979.
- DURÃES, F.O.M.; MAGALHÃES, P.C.; OLIVEIRA, A.C. Índice de colheita genético e as possibilidades da genética fisiológica para melhoramento do rendimento de milho. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v.1, p. 33-44, 2002.
- HARGREAVES, G. H.; SAMANI, Z. A. Reference crop evapotranspiration from ambient air temperature. **American Society of Agricultural and Biological Engineer**, Chicago, 1985.
- MANFRON, P. A.; NETO, D. D.; PEREIRA A. R.; BONNECARRÈRE, R. A. G.; MEDEIROS, S. L. M.; PILAU, F. G. Modelo do índice de área foliar da cultura do milho. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 11, p. 333-342, 2003.

- MONTEIRO, L. A. Sugarcane yield gap in Brazil: a crop modelling approach. **Tese apresentada para obtenção do título de Doutor em agronomia**, Piracicaba: ESALQ/USP, 2015.
- MONTEIRO, L. A.; SENTELHAS, P. C. Sugarcane yield gap: can it be determined at nacional level with a simple agrometeorological model?. **Crop & Pasture Science**, Melbourne, v.68, p. 272-284, 2017.
- MONTEIRO, M.A.R.; DURÃES, F.O.M.; CRUZ, J.C.; OLIVEIRA, A.C. Índice de colheita; um forte conceito fisiológico de uso inadequado para seleção de cultivares de milho tropical. **Congresso nacional de milho e sorgo**, Recife, Resumos ABMS, p.22, 1998.
- RIVINGTON, M., MATTHEWS, K. B., BELLOCCHI, G., BUCHAN, K. Evaluating uncertainty introduced to process-based simulation model estimates by alternative sources of meteorological data. **Agricultural Systems**, Amsterdam v.88, p. 451–471, 2006.
- STACKHOUSE, P. W. J., WESTBERG, D., HOELL, J. M., CHANDLER, W. S., ZHANG, T. Prediction of World Wide Energy Resource (POWER) --- Agroclimatology methodology --- (1.0° latitude by 1.0° longitude spatial resolution). **Langely Research Center**, Hampton: NASA 2015.
- THORNTHWAITE, C. W.; MATHER, J. R. The water balance. Publications in Climatology. **Drexel Institute of Technology**, New Jersey, p. 104, 1955.
- van WART, J.; GRASSINI, P.; CASSMAN, K.G. Impact of derived global weather data on simulated crop yields. **Global Change Biology**, Oxford, v. 19, p.3822-3834, 2013.
- Van WART, J.; GRASSINI, P.; YANG, H.; CLAESSENS, L.; JARVIS, A.; CASSMAN, K.G. Creating long-term weather data from thin air for crop simulation modeling. **Agricultural and Forest Meteorology**, Amsterdam, v.209-210, p.49-58, 2015.
- WHITE, J.W.; HOOGENBOON, G.; STACKHOUSE, P.W.; HOEL, J.M. Evaluation of NASA satellite and assimilation model-derived long-term daily temperature data over the continental US. **Agricultural and Forest Meteorology**, Amsterdam, v. 148, p.1574-1584, 2008.
- WHITE, J. W., HOOGENBOOM, G., WILKENS, P. W., STACKHOUSE, P. W. J., HOEL, J. M. Evaluation of satellite-based, model-derived daily solar radiation data for the continental United States. **Agronomy Journal**, Madison, v.103, p.1242-1251, 2011.
- WILLMOTT, C. J. On the validation of models. **Physical Geography**, Norwich, v.2, p.184-194, 1981.

de WIT, A. J., van DEPIEN, C. A. Crop growth modelling and crop yield forecasting using satellite-derived meteorological inputs. **International Journal of Applied Earth Observation and Geoinformation**, Wageningen, v.10, p. 414-425, 2008.

XAVIER, A. C., KING, C. W., SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **Royal Meteorology Society – International Journal of Climatology**, Austin, 2015.

3. CALIBRAÇÃO E AVALIAÇÃO DE TRÊS MODELOS DE SIMULAÇÃO DA CULTURA DO MILHO E SUAS COMBINAÇÕES PARA ESTIMAÇÃO DA PRODUTIVIDADE

Resumo

A determinação dos diferentes níveis de produtividade do milho é de extrema importância tanto para a identificação de locais com alto potencial produtivo quanto na identificação das quebras de produtividade, ou *yield gaps* (YG). A experimentação agrícola é o método mais antigo utilizado para esse fim, entretanto, seu desenvolvimento pode muitas vezes ser altamente dispendioso tanto em termos de tempo quanto de recursos, limitando sua aplicação. Para contornar esse problema, o uso de modelos de simulação, desde que bem calibrados e avaliados, é uma ferramenta eficiente para a determinação das produtividades potencial e atingível da cultura do milho. Estudos recentes apontam ainda a possibilidade da diminuição das incertezas inerentes à estimação dessas produtividades quando diversos modelos são avaliados em conjunto (*ensemble*). Assim, o objetivo deste trabalho foi: i) calibrar e avaliar os modelos MZA-FAO; DSSAT CSM Ceres-*Maize* e APSIM-*Maize*, para a estimação das produtividades potencial e atingível da cultura do milho e ii) avaliar o desempenho de diferentes estratégias de combinação dos modelos visando a diminuição dos erros associados às simulações. Para atingir os objetivos, foram coletados dados climáticos, de solo e de produtividade de milho de 75 localidades brasileiras, os quais foram aplicados na estimação da produtividade do milho. Após a calibração e validação, os modelos apresentaram um desempenho mediano, com erros absolutos médios (EAM) em torno de 1100 kg ha⁻¹, baixas precisões ($R^2 \leq 0,49$) e moderadamente acurados ($d \leq 81$), resultando em um índice C de 0,40. Entretanto, a combinação dos modelos, por meio da média deles, foi a estratégia que apresentou o melhor desempenho, reduzindo o EAM para 1000 kg ha⁻¹ e aumentando a precisão e acurácia das simulações ($C = 0,79$).

Palavras-chave: Milho; Modelos de simulação de culturas; *Ensemble*

Abstract

The determination of different maize yield levels has an extreme importance to identify sites with high yield potential and also to determine yield gaps (YG). Agricultural experimentation is the oldest method used to achieve this, however, its development can often be time and resources consuming, limiting its application. In order to overcome this problem, the use of crop simulation models, since well calibrated and evaluated, is an efficient tool to

determine the potential and attainable maize yields. Recent studies also pointed to the possibility of reducing the uncertainties inherent to the simulations when several models are evaluated together (ensemble). Thus, the objective of this study was: i) to calibrate and evaluate the AEZ-FAO, DSSAT CSM Ceres-Maize, and APSIM-Maize models, to estimate the maize potential and attainable yields and ii) to evaluate the performance of different combinations of models' outputs to reduce the estimate errors. To reach these objectives, climate, soil and actual maize yield data were obtained from 75 Brazilian localities, which were applied in the maize yield simulation. After calibration and validation, the models presented an average performance, with mean absolute errors (MAE) around 1100 kg ha⁻¹, low precision ($R^2 \leq 0.49$) and good accuracy ($d \leq 81$), resulting in a C index of 0.40. However, when the combination of the models, by their mean, was used a better performance was observed, reducing MAE to 1000 kg ha⁻¹ and increasing the precision and accuracy of the simulations ($C = 0.79$).

Keywords: Maize; Crop simulation models; Ensemble

3.1. Introdução

Modelos de simulação de culturas agrícolas vêm sendo cada vez mais utilizados na agricultura como ferramenta para identificar e quantificar os impactos na produtividade em função das condições climáticas, do uso de diferentes genótipos e das características do manejo, como irrigação, adubação, características do solo e data de semeadura (Heinemann et al., 2008; Peak et al., 2008; Wang et al., 2012; Costa et al., 2013; Justino et al., 2013; Jabeen et al., 2017; Lopez et al., 2017; Negm et al., 2017; Shrestha et al., 2017; Singh et al., 2017; Yin et al., 2017).

Diversos modelos vêm sendo empregados para simular a produtividade da cultura do milho em diferentes regiões, escalas espaciais e condições de cultivo, sejam eles de menor ou maior complexidade. Independentemente do tipo de modelo de simulação, todos necessitam ter seus parâmetros calibrados para que possam corresponder de forma satisfatória às condições às quais estão sendo submetidos. Vale ressaltar que todo parâmetro do modelo que necessita ser calibrado é uma fonte de incerteza, o que faz com que quanto mais complexo for o modelo, mais ele sofrerá com as incertezas decorrentes do processo de calibração, conforme apontado por Zhang et al. (2002). Por outro lado, os modelos mais simples, de natureza empírica, irão sofrer mais com os impactos das incertezas ligadas aos erros sistemáticos. Numa situação intermediária em termos de

complexidade estão os modelos híbridos, também conhecidos como modelos matemático-fisiológicos que descrevem alguns dos processos fisiológicos da planta associados à produtividade por meio de equações matemáticas e relações empíricas. Vale ressaltar que a qualidade dos resultados não necessariamente está ligada à complexidade do modelo utilizado, uma vez que modelos simples, quando bem calibrados, podem ser tão precisos e acurados quanto os modelos complexos (Sentelhas et al., 2015; Monteiro e Sentelhas, 2017).

A escolha do modelo quanto à sua complexidade deve ser baseada na necessidade do usuário, na quantidade e na qualidade dos dados de entrada. O modelo da Zona Agroecológica da FAO (MZA-FAO) (Doorenbos e Kassam, 1979) é um exemplo de modelo matemático-fisiológico que utiliza a interação entre o acúmulo de matéria seca pela planta e as condições meteorológicas (radiação solar, temperatura do ar e fotoperíodo), penalizando esse acúmulo de acordo com a deficiência hídrica que ocorre ao longo do ciclo. Esse tipo de modelo é de fácil aplicação nos níveis local, regional e nacional, trazendo resultados satisfatórios, principalmente para regiões onde o acesso às informações de solo, clima e parâmetros de cultura é restrito (Piccini et al., 2009; Raes et al., 2006; Garcia e Lopez et al., 2014). Resultados satisfatórios para simular a produtividade do milho com esse modelo foram obtidos por Andrioli e Sentelhas (2009); Piccini et al. (2009); Souza et al. (2014); Monteiro et al. (2017).

Entre os modelos mais complexos têm-se aqueles baseados em processos ou mecanísticos, que descrevem os processos metabólicos das plantas e sua interação com o clima e o solo, por meio de equações que requerem a calibração de diversos parâmetros, o que torna sua aplicação em larga escala e em condições operacionais de campo uma tarefa mais complexa. Exemplos desse tipo de modelo são o CSM-DSSAT-CERES *Maize* e o APSIM-*Maize*, capazes de integrar condições de adubação, concentração de CO₂ atmosférico e características de solo mais detalhadas, possibilitando seu uso até mesmo para predição em cenários futuros de mudanças climáticas. Diversos autores utilizaram esses modelos para simular a resposta do milho em diferentes condições no Brasil e no mundo, como Soler et al. (2010); Liu et al. (2012); Chauhan et al. (2013); Santos e Sentelhas (2014); Amaral et al. (2015); Ban et al. (2015); Andrade et al. (2016) e Jabeen et al. (2017).

Apesar da existência de diferentes tipos de modelos de simulação da cultura do milho, com distintos níveis de complexidade, não se pode afirmar que exista um com melhor desempenho do que outro ou que qualquer que seja o modelo ele seja livre de erros, já que

esses modelos são uma simplificação de um sistema biológico extremamente complexo em que interagem aspectos relativos ao genótipo, ao ambiente físico (clima e solo) e ao manejo agrícola. Sendo assim, modelos capazes de simular as diferentes condições sob as quais são submetidos são aqueles que forem bem calibrados e avaliados. Nesse sentido, uma abordagem que vem ganhando destaque nos estudos com modelos de simulação de culturas é a do uso de multi-modelos (*ensemble*), o que vem possibilitando melhorar a precisão e a acurácia das simulações, minimizando as incertezas associadas a cada um dos modelos quando empregados individualmente (Palusuo et al., 2011, Asseng et al., 2013, Battisti et al., 2017). O AGMIP (*Agricultural Model Intercomparison and Improvement Project*), é a entidade internacional mais conhecida e respeitada na área de modelagem de culturas agrícolas, direcionando seus estudos para os impactos do clima na produção agrícola em escalas regional e global, e recomenda a inter-comparação de modelos e o uso de *ensembles* como estratégia para melhorar os resultados de estudos sobre o impacto das mudanças climáticas na produtividade agrícola (Rosenzweig et al., 2013; Rosenzweig et al., 2016 e Wallach et al., 2016). Vários estudos vêm demonstrando a melhoria do desempenho das estimativas de produtividade com o uso de *ensembles* para diferentes culturas, dentre elas a cana-de-açúcar (Marin, 2014; Dias, 2016), trigo (Asseng et al., 2013; Martre et al., 2014) e soja (Battisti et al., 2017).

Considerando que a estimativa da produtividade do milho é de grande importância para fins de definição do desempenho da cultura em diferentes regiões e a determinação das quebras de produtividade decorrentes dos fatores físicos do ambiente e das ações de manejo são de grande importância, o presente estudo teve por objetivos calibrar e avaliar os modelos MZA-FAO, CSM-DSSAT CERES-Maize e APSIM-Maize para simular a produtividade da cultura do milho, assim como avaliar diferentes combinações desses modelos (*ensembles*) na melhoria dessas estimativas.

3.2. Material e métodos

3.2.1. Dados climáticos

Para este estudo foram coletados dados meteorológicos de 75 localidades espalhadas pelo Brasil, as quais são apresentadas na Figura 3.1, provenientes do Instituto Nacional de Meteorologia (INMET), do sistema *DailyGridded* (Xavier et al., 2015) e da

Angência Nacional de Águas (ANA), para o período compreendido entre janeiro de 1980 e dezembro de 2013. Após consistidas, as séries históricas apresentaram dados diários contínuos de radiação solar global, chuva, temperatura (máxima, mínima e média), umidade relativa média do ar e velocidade do vento a 2 metros de altura.

Figura 3.1. Localidades brasileiras para as quais foram obtidos os dados meteorológicos provenientes do INMET, *DaillyGridded* e ANA, que foram empregados no ajuste e avaliação dos modelos de simulação da cultura do milho

3.2.2. Dados de solo

O banco de dados de solo foi formado por um conjunto de fontes, como o projeto RadamBrasil (Ministério das Minas e Energia, 1981), o mapa de solos da EMBRAPA (Embrapa Solos, 2011) e a base de dados de solos brasileiros disponibilizada pela plataforma DSSAT (Hoogenboon et al., 2003). Por meio do uso conjunto do sistema de classificação de solos do DSSAT, do mapa de solos da EMBRAPA e do mapeamento de texturas feito pelo RadamBrasil, pôde-se identificar um possível perfil de solo predominante em cada localidade estudada.

Como cada modelo tem suas particularidades na abordagem da variável solo, após essa definição dos perfis de solo para cada localidade, foram necessárias algumas adaptações nesses para serem aplicados a cada um dos modelos de maneira adequada. No caso do DSSAT, bastou utilizar o perfil selecionado após os cruzamentos de informações. Para o modelo MZA-FAO, apenas o valor de capacidade de água disponível (CAD) no solo é exigido. Para tanto, correlacionou-se a textura do solo e a CAD, conforme sugerido por Driessem e Konijin (1992) e Prado (2013). No modelo APSIM, os perfis de solo foram construídos baseados nos perfis usados pelo DSSAT, mantendo-se os mesmos valores de capacidade de campo, ponto de murcha, albedo, teor de areia, silte e argila, teor de matéria orgânica, densidade e pH da solução do solo para cada um dos perfis. Os perfis de solo foram considerados até 1m de profundidade para todas as simulações. A Figura 3.2 mostra a distribuição dos solos do DSSAT e o mapa de solos da EMBRAPA.

Figura 3.2. Mapa de solos do Brasil e a distribuição das localidades com os perfis de solo descritos pelo DSSAT. Fonte: EMBRAPA (2011)

3.2.3. Dados de produtividade

As produtividades de milho das 75 localidades apresentadas na Figura 3.1 foram obtidas junto ao banco de dados dos Ensaios Nacionais de Milho (ENM) (Embrapa Milho e Sorgo, 2014). As informações extraídas dessa base de dados foram: data de semeadura; data de colheita (quando disponível) e produtividade final de grãos. Os dados coletados corresponderam às semeaduras realizadas entre os anos de 2003 e 2009. Apesar de não estarem atualizados, os grupos de genótipos desses ensaios ainda são empregados em boa

parte das regiões brasileiras. Um total de 136 observações de produtividade de milho distribuídas nas cidades estudadas foi utilizado nessa etapa do trabalho, sendo 51 delas para a fase de calibração e 85 para a fase de avaliação.

O banco de dados dos ENM foi consistido de modo que para cada híbrido com mesma data de semeadura e de colheita em cada localidade, escolheu-se apenas a produtividade do híbrido que apresentou o maior valor dentre todos os relatados. Essa estratégia foi adotada com a intenção de calibrar o modelo para estimar a produtividade atingível de um genótipo genérico, em que as plantas sofressem o mínimo possível de problemas fitossanitários e nutricionais, alcançando as máximas produtividades.

3.2.4. Modelos de simulação da cultura do milho

3.2.4.1. Modelo da zona agroecológica da FAO (MZA-FAO)

O MZA-FAO foi empregado na estimação da produtividade da cultura do milho, adotando-se algumas alterações em relação à abordagem original, apresentada por Doorenbos e Kassam (1979). Dentre essas alterações, a primeira foi adotar o passo de cálculo diário para o acúmulo de massa e desenvolvimento da área foliar. Para tal, os cálculos das produtividades potencial e atingível foram feitos com base nos dados meteorológicos diários e nos coeficientes relativos aos ajustes (coeficiente de área foliar- c_{IAF} e coeficiente de respiração- c_{resp}) também nessa escala. Basicamente, o modelo se divide em duas etapas, a primeira, ligada a estimação da produtividade potencial (PP) e, a segunda, ligada a penalização da PP pelo déficit hídrico relativo, de forma a obter a produtividade atingível (PA). O déficit hídrico relativo é dado segundo a equação 3.1, onde a ET_r representa a evapotranspiração real da cultura, fornecida pelo balanço hídrico de cultura, segundo o método de Thornthwaite e Mather (1955), adaptado para a escala diária, considerando-se a CAD respectiva ao solo de cada localidade, e, a ET_c , que representa a evapotranspiração máxima da cultura, obtida através da correção da evapotranspiração de referencia (ET_0) pelo coeficiente de cultura (K_c). A ET_0 , por sua vez, foi estimada segundo o método de Penman-Monteith, descrito por Allen et al. (1998).

$$\text{Déficit Hídrico Relativo} = 1 - \left(\frac{ET_r}{ET_c} \right) \quad (3.1)$$

O coeficiente de cultura (Kc), originalmente valorado de acordo com as fases fenológicas da planta, foi transformado em valores diários, com a intenção de melhor simular a resposta da cultura do milho às variações das condições meteorológicas. O modelo teórico de acúmulo de massa, descrito por Wit (1965), foi aplicado em escala diária, afim de estimar PP, levando em consideração a radiação solar no topo da atmosfera (Q0), a temperatura média do ar (Tmed), a insolação (n) e o fotoperíodo (N). A PP pode ser descrita segundo a equação 3.2:

$$PP = \left(\sum_i^{NDC} PPB_i * c_{resp} * c_{IAF} \right) * c_{colh} * c_{um} \quad (3.2)$$

em que PPB é o acúmulo bruto de massa seca, c_{resp} , c_{IAF} , c_{colh} e c_{um} são os coeficientes de ajuste específicos da cultura do milho, correspondendo à respiração, índice de área foliar, índice de colheita e umidade do grão, respectivamente, i é o dia corrente do cálculo e NDC é o número de dias do ciclo da cultura.

Outra alteração feita em relação ao modelo original foi a introdução de uma terceira faixa de correção para a respiração de manutenção (c_{resp}), penalizando ainda mais o acúmulo de carboidratos da cultura em dias com temperaturas médias mais elevadas, conforme a equação 3.3:

$$\begin{aligned} &0,6, \text{ se } Tmed_i < 20^\circ C \\ c_{resp.i} &= 0,5, \text{ se } 20^\circ C < Tmed_i < 27^\circ C \\ &0,4 \text{ se } Tmed_i > 27^\circ C \end{aligned} \quad (3.3)$$

em que $Tmed_i$ é a temperatura média do dia corrente.

O cálculo de IAF foi ajustado em função do número de dias após a semeadura (DAS), enquanto que o c_{iaf} foi multiplicado por 2 para ajustar este índice ao passo de cálculo diário, já que para a versão original do modelo esse índice é determinado para o ciclo como um todo. As alterações de IAF e c_{iaf} são apresentadas a seguir:

$$IAF_i = (-0,0005 * DAS_i)^2 + 0,0924 * DAS_i \quad (3.4)$$

$$c_{iaf.i} = 2 * (0,0093 + 0,185 * IAF_i - 0,175 * IAF_i^2) \quad (3.5)$$

em que: DAS é o número de dias após a semeadura, IAF é o índice de área foliar e i é o dia corrente dos cálculos.

Após a obtenção da PP, foi aplicada a penalização dela pelo déficit hídrico relativo, conforme sugerido por Doorenbos e Kassam (1979) e adaptado para a escala decendial. O coeficiente de sensibilidade ao déficit hídrico (K_y), originalmente valorado de acordo com as fases fenológicas da planta, foi transformado em valores decendiais, com a intenção de melhor simular a resposta da cultura do milho às variações das condições de umidade do solo.

$$PA_n = \prod_{i=1}^n \left\{ 1 - \left[k_{y_i} * \left(1 - \frac{ETr_i}{ETC_i} \right) \right] \right\} * PA_{i-1} \quad (3.6)$$

em que PA_n é a produtividade atingível final da cultura, em $t \text{ ha}^{-1}$, n é o número de decêndios no ciclo da cultura simulada, i é o decêndio corrente, k_y é o coeficiente de sensibilidade ao déficit da cultura no decêndio i , ETr_i é a evapotranspiração real da cultura e ETC_i é a evapotranspiração máxima da cultura, sendo que, quando $i = 1$, $PA_{i-1} = PP$.

A Tabela 3.1 apresenta os coeficientes que foram calibrados no MZA-FAO e seus intervalos de variação segundo a literatura consultada (Andrioli e Sentelhas, 2009; Piccinni et al., 2009; Souza et al., 2014; Monteiro et al., 2017). Toda estrutura de cálculos do modelo foi elaborada em ambiente R numa escala diária, com exceção da penalização pelo déficit hídrico relativo, que foi acumulada em escala decendial. O ciclo da cultura foi fixado em 140 dias para todas as simulações desse modelo. Esse valor foi estabelecido baseado no número de dias entre as datas de plantio e colheita, apresentados nos dados dos Ensaios Nacionais de Milho (Embrapa Milho e Sorgo, 2014).

Tabela 3.1. Coeficientes do modelo da Zona Agroecológica da FAO utilizados na calibração da cultura do milho e seus intervalos de variação, de acordo com Andrioli e Sentelhas, 2009; Piccinni et al., 2009; Souza et al., 2014; Monteiro et al., 2017

Coeficiente	Varição
C_{colh}	0,10 – 0,60
C_{um}	0,13 – 0,35
IAF	0,00 – 5,00
C_{resp}	0,40 – 0,60
Kc	≈ 0,00 – 1,40
K_y	≈ 0,00 – 2,15

3.2.4.2. Modelo DSSAT CERES-Maize

O modelo CSM CERES-Maize faz parte da plataforma *Decision Support System for Agrotechnology Transfer* (DSSAT), é classificado como um modelo mecanístico e tem um passo de cálculo em escala diária. A versão do modelo CERES-Maize utilizado nessas simulações está disponível em DSSAT 4.5. Suas variáveis de entrada são mais complexas, exigindo a calibração de diversos parâmetros relacionados ao solo, à espécie e até mesmo ao genótipo (Kiniry et al., 1997). No modelo CERES, o ciclo de vida das plantas é dividido em fases de desenvolvimento (Tabela 3.2), regidas pelo tempo térmico (graus dia - GD). O tempo térmico necessário para se completar uma fase e dar início a seguinte é um dos parâmetros que podem ser calibrados no modelo CERES. A Tabela 3.3 apresenta os parâmetros para a calibração de um genótipo no modelo, assim como o intervalo de variação sugerido pela plataforma DSSAT.

Tabela 3.2. Estádios de desenvolvimento do milho simuladas pelo modelo DSSAT CERES-Maize

Estádios de desenvolvimento do milho
Germinação
Emergência
Fim do período juvenil
Indução floral
Emissão de 75% do estiloestigma
Início do enchimento de grãos
Maturidade fisiológica
Colheita

Tabela 3.3. Coeficientes do modelo CERES-Maize e seus intervalos de variação utilizados na calibração de um genótipo de milho. Fonte: Hoogenboom et al. (2003)

Coeficiente	Variação
P1 ¹	100 – 400
P2 ²	0 – 4
P5 ³	600 – 1000
G2 ⁴	750 – 850
G3 ⁵	5 – 12
PHINT ⁶	38,9 – 75

Temperatura basal: 8°C

1: Tempo térmico necessário desde a emergência até o final do período juvenil

2: Atraso do desenvolvimento da planta (em dias) para cada hora a mais em relação ao fotoperíodo crítico

3: Tempo térmico da fase reprodutiva. Tem início na emissão do estiloestigma até sua maturidade fisiológica.

4: Número máximo de grãos de uma espiga.

5: Taxa de acúmulo de massa (mg d⁻¹) em condições ótimas de desenvolvimento.

6: Tempo térmico entre o aparecimento de duas folhas sucessivas (filocrono).

Nesse modelo, o acúmulo de massa e o crescimento da planta é calculado com base na interceptação da radiação fotossinteticamente ativa (RFA), utilizando um parâmetro

específico para as plantas compreendidas pelo modelo CERES. Já a interceptação da radiação é uma função do IAF e da densidade de plantio simulada. O estudo considerou uma densidade de plantio com quatro plantas por metro linear e 0,6 m entre as linhas de cultivo. Toda a matéria seca calculada pelo modelo é acumulada ao final do dia e corrigida de acordo com a concentração de CO₂ atmosférico, o estresse hídrico, o estresse de temperatura (Figura 3.3) ou por déficit de nitrogênio (Hoogenboon et al., 2003). Nesse trabalho, o balanço de nitrogênio foi desabilitado em todas as simulações, a fim de considerar uma condição potencial para esse nutriente durante toda a simulação.

Figura 3.3. Efeito relativo da temperatura na taxa de crescimento da planta de milho e na taxa de enchimento de grão simulada pelo modelo DSSAT CERES-Maize. Fonte: Adaptado de Hoogenboon et al. (2003)

Em relação ao estabelecimento do número de grãos de milho por planta e do crescimento desses grãos, apesar de ser possível calibrar o número máximo de grãos por espiga (G2), o modelo estabelece esse parâmetro como o máximo, sendo que seu valor final será determinado durante o período do florescimento, de acordo com o acúmulo de massa na parte aérea da planta, o acúmulo médio de carboidratos durante o período de florescimento e de fatores limitantes como água, temperatura (Figura 3.3) e nitrogênio. Da mesma forma, a taxa de crescimento dos grãos também pode ser calibrada (G3), entretanto ela também sofrerá influência do déficit hídrico e do estresse causado pela temperatura e pelo balanço de nitrogênio. O crescimento dos grãos se dá até a data da maturidade fisiológica, exceto em situações em que a planta está crescendo sob condições limitantes de algum recurso ou se a taxa de acúmulo de massa dos grãos estiver abaixo de um valor limite durante dias consecutivos (Hoogenboon et al., 2003). Uma descrição mais completa e

detalhada do modelo CERES pode ser encontrada em Jones e Kiniry (1986), Ritchie e Otter (1985) e Ritchie et al. (1998).

O modelo CERES ainda considera um complexo sistema solo-planta-atmosfera. Ritchie (1972) descreveu o modelo utilizado pela plataforma DSSAT para simular o balanço de água no solo. A evapotranspiração potencial (ET_0) pode ser calculada de quatro diferentes maneiras, de acordo com os dados meteorológicos disponíveis, sendo possível escolher entre os métodos de Priestley e Taylor (1972); Penman-FAO (Doorenbos e Pruitt, 1977); Penman-Monteith (Allen et al., 1998) e também pelo método horário do balanço de energia. O modelo ainda estima a transpiração das plantas, através de uma aproximação da equação de fluxo radial, onde a absorção de água pelas raízes da planta é calculada para cada perfil do solo, sendo o fluxo total dado pela soma do potencial de absorção de cada perfil. Trabalhando dessas formas em conjunto, o modelo consegue limitar a evapotranspiração de acordo com o que for mais limitante: a atmosfera (devido a temperaturas amenas e baixos índices de radiação incidente), de acordo com o dossel (índice de área foliar influenciando na água absorvida pelas plantas) ou ser limitada pelo teor de água no solo e densidade do sistema radicular.

3.2.4.3. Modelo APSIM-Maize

A versão do modelo *Agricultural Production Systems Simulator* (APSIM) empregada neste estudo foi a APSIM 7.7. O modelo APSIM-Maize foi construído com base no Plant Modeling Framework, descrito por Brown et al. (2014), que consiste na utilização de submódulos acoplados a estrutura principal do modelo, simulando diversos processos e órgãos da planta de forma independente, como fotossíntese e crescimento de folhas, por exemplo. Podemos dividir o modelo em quatro estruturas básicas: 1) um modelo fenológico para simular o desenvolvimento entre as fases da planta de milho; 2) um modelo estrutural para simular a morfologia da planta; 3) um conjunto de submódulos para simular as diversas partes da planta de milho e 4) um algoritmo responsável por distribuir e alocar os recursos absorvidos e produzidos nas diversas partes da planta de milho (Brown et al., 2014).

O modelo fenológico é responsável por simular o desenvolvimento da planta através das suas diferentes fases de crescimento. Ele é regido, basicamente, pelo tempo térmico (GD), sendo que, para passar de uma fase para a seguinte é necessário acumular uma certa quantia de GD. Essa quantidade de graus dia é específica para cada genótipo e

pode ser calibrada (Tabela 3.4). A Figura 3.4 mostra a relação entre a temperatura de um determinado dia e o acumulo de GD considerado pelo modelo em cada faixa de temperatura.

Tabela 3.4. Coeficientes do APSIM-Maize utilizados na calibração de um genótipo de milho e seus limites superiores, sugeridos pelo sistema (APSIM Documentation)

Coeficiente	Limite superior
tt_emerg_to_endjuv ¹	500
tt_flower_to_maturity ²	1000
head_grain_no_max ³	1000
grain_gth_rate ⁴	20

Temperatura basal: 8°C

1: Tempo térmico compreendido entre a emergência e o final do período juvenil;

2: Tempo térmico compreendido entre o florescimento e a maturidade fisiológica dos grãos;

3: Número máximo de grãos por espiga e

4: Taxa de acumulo de massa dos grãos.

Figura 3.4. Relação entre a temperatura do ar e o tempo térmico acumulado pelo modelo APSIM-Maize. Fonte: Adaptado de Brown et al. (2014)

O modelo estrutural é responsável por simular o crescimento das estruturas da planta. Ele determina o número total de folhas, de nós, altura da planta e crescimento do colmo. Ele é influenciado tanto pelo tempo térmico quanto pela fase de desenvolvimento em que a planta se encontra. Fatores como densidade populacional e suprimento de recursos (água e nitrogênio) também irão influenciar no desenvolvimento simulado por esse modelo. Nele, a fotossíntese é estimada com base na eficiência de uso da radiação (RUE), segundo metodologia proposta por Monteith et al. (1977). Esse método simula o acumulo da fotossíntese líquida e fraciona essa em duas partes, uma direcionada ao crescimento da planta e outra direcionada a manutenção da planta (respiração). A RUE é fixada num valor potencial que pode ser penalizado de acordo com fatores ligados a nutrição da planta, temperatura e umidade do ar, balanço de água no solo e concentração de CO₂ atmosférico.

O modelo conta ainda com um sistema que arbitra sobre a partição da matéria seca acumulada e nutrientes absorvidos pela planta nas suas diferentes estruturas. Basicamente, ele divide a matéria seca em três classes: 1) estrutural – a qual é fixada em um órgão da planta após a partição; 2) não estrutural – fica disponível para realocação em órgãos com alta demanda ou maior prioridade e 3) metabólica – geralmente fixada num órgão da planta, mas ainda disponível para realocação em alguns casos. Esse sistema trabalha em duas etapas, primeiro, alocando a matéria seca metabólica e estrutural nas diferentes partes da planta, de acordo com o potencial de demanda dessas partes para então realocar a matéria seca restante, de forma não estrutural, de acordo com a demanda de cada parte da planta.

Durante as simulações, a mesma estratégia utilizada no modelo DSSAT-CERES-*Maize* foi replicada para o APSIM-*Maize*, com relação à densidade de plantio e espaçamento entre linhas. Como nesse modelo não é possível desconsiderar o balanço de nitrogênio no solo, duas estratégias de adubação nitrogenada foram adotadas para suprir a demanda da cultura: a primeira aplicando-se 300 kg ha⁻¹ de ureia na data de semeadura, e a segunda, aplicando-se 50kg ha⁻¹ de NO₃ sempre que essa mesma quantia de NO₃ fosse retirada das três primeiras camadas do solo. Dessa forma, a planta não apresentou restrições nutricionais em nenhuma das simulações.

3.2.5. Calibração, avaliação e combinação dos modelos (*ensemble*)

O conjunto de coeficientes de cada um dos modelos descritos acima foi calibrado de modo a proporcionar as menores diferenças entre as produtividades estimadas e observadas. Para tanto foram usados os dados meteorológicos e de produtividade observados de 19 localidades (Figura 3.1). Na sequência, os modelos previamente calibrados foram avaliados com dados independentes, provenientes de outras 56 localidades (Figura 3.1). Para avaliar o desempenho dos modelos, tanto na fase de calibração quanto na fase de avaliação, foram empregados os seguintes erros e índices estatísticos: erro médio (EM), erro absoluto médio (EAM), raiz do erro médio quadrático (REMQ), índice de concordância 'd' (Willmot, 1985), índice de confiança 'C' (Camargo e Sentelhas, 1997) e coeficiente de determinação (R²). A escolha da melhor calibração para cada um dos modelos foi feita por meio de um sistema de pontos, de modo que o modelo pontua quando apresenta o melhor desempenho em um dos índices estatísticos ou erros utilizados na avaliação. Assim, a

melhor calibração foi aquela que somou a maior quantidade de pontos, apresentando os menores erros e os maiores índices estatísticos.

Foram adotadas três estratégias para desenvolver a combinação ou *ensemble* dos modelos: média dos três modelos; mediana dos modelos; e média de dois modelos, ou seja, MZA-FAO e CERES-*Maize*, MZA-FAO e APSIM-*Maize* e CERES-*Maize* e APSIM-*Maize*. Ao final, cinco possibilidades de *ensemble* foram testadas e a mesma estratégia de pontuação, utilizada na escolha da calibração e avaliação individual dos modelos foi aplicada para a escolha do melhor *ensemble*.

3.3. Resultados e discussão

3.3.1. Calibração dos modelos

As calibrações dos coeficientes de cada modelo foram feitas com o objetivo de se encontrar o melhor ajuste entre os dados de produtividade observados e estimados. As Tabelas 3.4, 3.5 e 3.6 apresentam os coeficientes calibrados para cada um dos modelos estudados, ou seja, MZA-FAO, CERES-*Maize* e APSIM-*Maize*, respectivamente.

Tabela 3.4. Coeficientes k_c (de cultura), k_y (de sensibilidade ao déficit hídrico), c_{colh} (de colheita) e $U\%$ (umidade do grão de milho), calibrados para o modelo da Zona Agroecológica da FAO (MZA-FAO)

	Decêndios													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Kc	0,30	0,40	0,60	0,65	0,80	0,90	1,10	1,30	1,40	1,45	1,35	1,10	0,70	0,30
Ky	0,05	0,10	0,17	0,18	0,20	0,25	0,30	0,30	0,40	0,45	0,30	0,25	0,10	0,05
U%	13%													
c_{colh}	0,37													

Tabela 3.5. Coeficientes P1 (tempo térmico necessário desde a emergência até o final do período juvenil), P2 (atraso do desenvolvimento da planta (em dias) para cada hora a mais em relação ao fotoperíodo crítico), P5 (tempo térmico da fase reprodutiva), G2 (número máximo de grãos de uma espiga), G3 (taxa de acúmulo de massa (mg d^{-1}) em condições ótimas de desenvolvimento) e SRGF (característica do solo ligada ao crescimento radicular), calibrados para o modelo CERES-*Maize*

P1	P2	P5	G2	G3	SRGF					
					0-10	10-20	20-40	40-60	60-80	80-100
340	0,5	1174	650	7,2	1	0,97	0,74	0,48	0,29	0,24

Tabela 3.6. Coeficientes tt_emerg (tempo térmico compreendido entre a emergência e o final do período juvenil), tt_flower (tempo térmico compreendido entre o florescimento e a maturidade fisiológica dos grãos), $head_grain$ (número máximo de grãos por espiga), $grain_gth$ (taxa de acúmulo de massa dos grãos) e KL (fator de controle da taxa de retirada de água do solo pelas raízes), calibrados para o modelo APSIM-*Maize*

tt_emerg	tt-flower	head-grain	grain-gth	KL					
				0-10	10-20	20-40	40-60	60-80	80-100
330	1000	830	8,6	0,12	0,12	0,12	0,10	0,10	0,09

Nessa fase, os modelos superestimaram os resultados de produtividade observados, com exceção do modelo APSIM-Maize, que apresentou um EM = -62,54 kg ha⁻¹. O coeficiente de determinação (R²) variou de 0,28 (MZA-FAO) a 0,39 (APSIM-Maize), enquanto que o índice d foi superior a 0,70 para todos os modelos. Uma possível explicação para a baixa precisão apresentada pelos modelos é o uso de produtividades observadas com pouca variabilidade, já que nos ensaios nacionais de milho, as produtividades tendem a ser elevadas. A Tabela 3.8 apresenta o desempenho de cada um dos modelos empregados, com seus respectivos erros e índices estatísticos.

Tabela 3.8. Desempenho dos modelos MZA-FAO (Modelo da Zona Agroecológica– FAO), CERES-Maize e APSIM-Maize para a estimação da produtividade do milho, na fase de calibração

	PA _{média} observada	PA _{média} estimada	EM	EAM	REMQ	d	R ²	C
			kg ha ⁻¹					
MZA-FAO	9164,0 (± 1267,9)	9654,60	490,64	1020,81	1459,05	0,72	0,28	0,38
CERES-Maize		9682,86	556,79	861,84	1192,95	0,74	0,39	0,46
APSIM-Maize		9101,43	-62,54	883,27	1205,62	0,76	0,31	0,42

EM = erro médio; EAM = erro absoluto médio; REMQ = raiz do erro médio quadrático; d = coeficiente de concordância; R² = coeficiente de determinação e C = índice de confiança.

Apesar da baixa precisão, os erros médios foram relativamente baixos, inferiores a 7% em relação a PA_{média} observada, com os valores de REMQ sendo próximos dos encontrados na literatura. Batistti (2016) trabalhando com simulação de soja, encontrou uma variação para o REMQ de 548 kg ha⁻¹ (DSSAT) até 650 kg ha⁻¹ (MZA-FAO); Monteiro (2015) simulou a cultura da cana-de-açúcar através do modelo MZA-FAO e encontrou um REMQ ≈ 13200 kg ha⁻¹, equivalente a 12,5% do erro médio em relação aos dados de produtividade observados. Para a cultura do milho, Zhang e Zhao (2017), utilizando o modelo APSIM-Maize, encontraram um REMQ que variou entre 600 e 800 kg ha⁻¹, enquanto que Liu et al. (2010), simulando a cultura do milho com o modelo DSSAT-CERES-Maize, encontraram valores de REMQ variando entre 1166 e 1391 kg ha⁻¹. Também com o modelo DSSAT-CERES-Maize, Amaral et al. (2015), Ban et al. (2015) e Chisanga et al. (2015) obtiveram valores de REMQ percentual em relação à PA_{média} observada entre 10 e 20%, concordando com os resultados apresentados neste estudo. A Figura 3.3 apresenta a relação entre as produtividades simuladas e observadas durante a fase de calibração dos modelos.

Figura 3.3. Relação entre as produtividades observadas e estimadas pelos modelos de simulação MZA-FAO(a); CERES-*Maize* (b) e APSIM-*Maize* (c) para a cultura do milho durante a fase de calibração

3.3.2. Avaliação dos modelos

Na fase de avaliação dos modelos com dados independentes (Tabela 3.9), observou-se um desempenho inferior aos observados na fase de calibração, especialmente para os modelos CERES-*Maize* e APSIM-*Maize*.

Tabela 3.9. Desempenho dos modelos MZA-FAO (Modelo da Zona Agroecológica – FAO), CERES-*Maize* e APSIM-*Maize* para a estimação da produtividade do milho na fase de avaliação

	PA _{média} observada	PA _{média} estimada	EM	EAM	REMQ	d	R ²	C
	kg ha ⁻¹							
MZA-FAO	9477,41 (± 2848,2)	9033,56	443,85	1459,09	2008,70	0,71	0,28	0,38
CERES- <i>Maize</i>		10469,18	991,77	1343,69	2114,77	0,69	0,27	0,36
APSIM- <i>Maize</i>		9998,82	521,41	1134,71	1554,62	0,81	0,49	0,57

EM = erro médio; EAM = erro absoluto médio; REMQ = raiz do erro médio quadrático; d = coeficiente de concordância; R² = coeficiente de determinação e C = índice de confiança.

Na fase de calibração, o modelo *CERES-Maize* foi superior, seguido pelo *APSIM-Maize* e *MZA-FAO*, como observado na Tabela 9. Durante a fase de avaliação, o *APSIM-Maize* mostrou-se com desempenho superior ao modelo *MZA-FAO* que, por sua vez, superou o *CERES-Maize* (Tabela 3.9). O aumento do EM indica uma ampliação das superestimativas, enquanto que o aumento do EAM e do REMQ indicam que, no geral, os modelos passaram a gerar erros de maior magnitude, da ordem de 12 a 15% para o EAM em relação à $PA_{média}$ observada. Pode-se atribuir esses resultados à fonte de dados de produtividade observados, a qual envolve a média de diversos genótipos, em diferentes regiões do país e com níveis variáveis de manejo da cultura, o que proporciona maiores erros. No entanto, observa-se na Figura 3.6 que os valores estimados permanecem próximos dos observados, ou seja, no entorno da linha 1:1 e expressando a variabilidade observada entre os distintos ambientes, entre 3.000 e 14.000 kg ha⁻¹.

Figura 3.6. Relação entre as produtividades observadas e simuladas pelos modelos de simulação MZA-FAO (a), *CERES-Maize* (b) e *APSIM-Maize* (c) para a cultura do milho durante a fase de avaliação

3.3.3. Ensemble dos modelos

Dada as incertezas associadas às simulações com os modelos, já que esses são aproximações da realidade, não levando em consideração todos os aspectos relativos aos processos fisiológicos das plantas que controlam a expressão do desenvolvimento, do crescimento e da produtividade das culturas, foram adotadas cinco estratégias de combinação dos modelos (*ensembles*), objetivando buscar a melhor delas para minimizar os erros e, dessa forma, as incertezas. Os *ensembles* foram obtidos por meio da média e da mediana dos três modelos e também pela combinação dos modelos dois a dois. Da mesma forma que as comparações anteriores, o desempenho dos *ensembles* foi avaliado por meio dos seguintes erros e índices estatísticos: EM, EAM, REMQ, R^2 , d e C, tanto na fase de calibração quanto na de avaliação dos modelos.

Tabela 3.10. Desempenho das diferentes estratégias de *ensemble* dos modelos MZA-FAO (Modelo da Zona Agroecológica-FAO), CM (CERES-Maize) e AM (APSIM-Maize) para a estimação da produtividade do milho, durante a fase de calibração

	PA _{média} observada	PA _{média} estimada	EM	EAM	REMQ	d	R ²	C
			kg ha ⁻¹					
Média		9480,0	315,67	627,38	837,87	1,00	0,62	0,79
Mediana		9381,8	217,84	590,10	834,06	1,00	0,61	0,78
AM + MZA-FAO	9164,0 (± 1267,9)	9378,0	214,05	704,90	945,22	1,00	0,49	0,70
AM + CM		9392,1	228,18	775,79	1035,55	1,00	0,42	0,65
CM + MZA-FAO		9668,7	504,77	717,96	924,32	1,00	0,62	0,79

EM = erro médio; EAM = erro absoluto médio; REMQ = raiz quadrada do erro médio quadrático; d = coeficiente de concordância; R^2 = coeficiente de determinação e C = índice de confiança.

Independente da estratégia adotada na elaboração do *ensemble*, pode-se notar uma substancial melhoria no desempenho das simulações. Em todas as situações houve melhoria tanto na acurácia quanto na precisão dos valores simulados pelos *ensembles*. O EM que variou de -62,54 até 556,79 kg ha⁻¹ passou a variar de 214 até 504,77 kg ha⁻¹. O coeficiente de determinação também melhorou muito, atingindo valores superiores a 0,6. Esses resultados mostram que os *ensembles* produziram estimativas melhores do que àquelas dos modelos individuais, com erros menores, inclusive do que aqueles encontrados na literatura. Essa melhoria nos resultados com o uso dos *ensembles* também foi observada para outras culturas como a da cana-de-açúcar (Marin, 2014; Dias, 2016), do trigo (Matre et al., 2014) e da soja (Battisti et al., 2017). A Figura 3.7 apresenta a relação entre a PA observada e a estimada pelos diferentes *ensembles*.

Figura 3.7. Relação entre as produtividades atingíveis observadas e a estimadas pelos *ensembles* dos modelos de simulação da cultura do milho, considerando-se a média (a), a mediana (b) e a combinação dos modelos APSIM-Maize + MZA-FAO (c), APSIM-Maize + CERES-Maize (d) e CERES-Maize + MZA-FAO (e)

É possível notar uma substancial melhoria na concordância entre as produtividades observadas e estimadas quando se empregaram os diferentes *ensembles*. Observa-se uma maior aproximação dos dados simulados em relação à linha 1:1 ($d = 1,00$) e a ausência de dados discrepantes (*outliers*), indicando uma simulação com maior confiabilidade, porém ainda com uma tendência de superestimativas, com os EMs entre 214 e 505 kg ha⁻¹ (2,3 a 5,5%).

Assim como na fase de calibração, na fase de ajuste também foram testados os *ensembles* dos modelos, com o intuito de avaliar o seu desempenho. Novamente, o

desempenho dos *ensembles* superou o dos modelos individuais em todos os itens avaliados, diminuindo os erros e aumentando a precisão e a exatidão das estimativas (Tabela 3.11 e Figura 3.8). A média se mostrou a melhor estratégia de obtenção do *ensemble*, assim como ocorrido na fase anterior, sendo o método mais preciso ($R^2 = 0,62$) e acurado ($d = 1,00$), resultando em um índice de confiança (C) de 0,79. Usando essa estratégia, o EAM e REMQ atingiram, respectivamente, 1048,57 e 1338,23 kg ha⁻¹, o que corresponde a erros da ordem de 11,4 a 14,6%.

Tabela 3.11. Desempenho das diferentes estratégias de *ensemble* dos modelos MZA-FAO (Modelo da Zona Agroecológica-FAO), CERES-Maize (CM) e APSIM-Maize (AM) para a estimação da produtividade do milho, na fase de avaliação

	PA _{média} observada	PA _{média} estimada	EM	EAM	REMQ	d	R ²	C
			kg ha ⁻¹					
Média		9833,85	356,44	1048,57	1338,23	1,00	0,62	0,79
Mediana	9477,41	9987,31	509,90	950,64	1372,78	1,00	0,61	0,78
AM + MZA-FAO	(± 2848,2)	9516,19	38,78	1058,55	1337,41	1,00	0,57	0,76
AM + CM		10234,0	756,59	1206,92	1711,60	1,00	0,44	0,66
CM + MZA-FAO*		9751,37	273,96	1106,85	1429,06	1,00	0,53	0,73

EM = erro médio; EAM = erro absoluto médio; REMQ = raiz do erro médio quadrático; d = coeficiente de concordância; R² = coeficiente de determinação e C = índice de confiança.

De modo geral, todas as estratégias de *ensemble* tenderam a superestimar os valores observados, sendo que a combinação dos modelos APSIM-Maize e CERES-Maize foi a que apresentou o pior desempenho para todos os índices testados. Ainda assim, conforme também observado no *ensemble* elaborado durante a etapa de calibração, todas as estratégias testadas tiveram desempenho superior aos modelos individuais, indicando o grande potencial de uso dessa ferramenta para diminuição das incertezas ligadas ao processo de modelagem da produção de milho.

Figura 3.8. Relação entre as produtividades atingíveis observadas e a estimadas pelos *ensembles* dos modelos de simulação da cultura do milho, considerando-se a média (a), a mediana (b) e a combinação dos modelos APSIM-Maize + MZA-FAO (c), APSIM-Maize + CERES-Maize (d) e CERES-Maize + MZA-FAO (e)

Nota-se a diminuição da dispersão dos dados e também a ausência de dados discrepantes (*outliers*) na análise do *ensemble* dos modelos combinados (Figura 3.8) quando comparados com os modelos analisados individualmente (Figura 3.6). Essa melhora no desempenho das simulações também foi apontada por outros autores ao usarem a abordagem multimodelos na simulação da produção de trigo, milho e arroz (Palosuo et al., 2011; Bassu et al., 2013; Asseng et al., 2013 e Durand et al., 2017).

3.4. Conclusões

Com base nos resultados apresentados neste estudo, pode-se concluir:

- a) Apesar da dificuldade em calibrar um genótipo hipotético em nível nacional, utilizando dados operacionais e sem o devido detalhamento de variáveis importantes para a simulação das produtividades, como a caracterização dos perfis de cada solo, data de florescimento, massa total, entre outros, foi possível se simular satisfatoriamente a produtividade da cultura do milho em diferentes regiões do Brasil, tanto na fase de calibração como de avaliação dos modelos MZA-FAO, CERES-Maize e APSIM-Maize;
- b) As estimativas foram ainda melhores quando os modelos foram utilizados em conjunto (*ensemble*). O uso da média dos modelos como estratégia para desenvolver o *ensemble* se mostrou a mais eficiente dentre as abordagens utilizadas, aumentando a precisão e exatidão das estimativas e, conseqüentemente, diminuindo os erros, sendo essa abordagem melhor do que o uso de qualquer modelo de forma individual;
- c) O uso do *ensemble* de modelos para a simulação da produtividade do milho a nível nacional é o mais recomendável para estudos agrometeorológicos sobre os riscos climáticos para a cultura.

REFERÊNCIAS

- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. FAO: **Irrigation Drainage and Paper**, **56**, Roma, p.291, 1998.
- ANDRADE, C. L. T.; SILVA, P. P. G.; MAGALHÃES, B. G.; PAIXÃO, J. S.; MELO, B. F.; TIGGES, C. H. P. Parametrização do modelo CSM-CERES-Maize para uma cultivar de alta produtividade. **XXXI Congresso Nacional de Milho e Sorgo**, Bento Gonçalves, 2016.
- ANDRIOLI, K. G.; SENTELHAS, P. C. Brazilian maize genotypes sensitivity to water deficit estimated through a simple crop model. **Pesquisa Agropecuaria Brasileira**, Brasília, v.44, p. 653-660, 2009.
- AMARAL, T. A.; LIMA, A. C. R.; ANDRADE, C. L. T.; SILVA, S. D. A. Parametrização e avaliação do modelo CSM-CERES-Maize para cultivares de milho recomendadas para a microrregião de Pelotas, RS. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v.14, p. 371-391, 2015.
- ASSENS, S.; EWERT, F.; ROSENZWEIG, C. J. W.; HATFIELD, J. L.; RUANE, A. C.; BOOTLE, K. J.; THORBURN, P.J.; ROTTER, R.P.; CAMMARANO, D.; BRISSON, N.; BASSO, B.; MATRE, P.; AGGARWAL, P. K.; ANGULO, C.; BERTUZZI, P.; BIERNATH, C.; CHALLINOR, A. J.; DOLTRA, J.; GAYLER, S.; GOLDBERG, R.; GRANT, R.; HEING, L.; HOOKER, J.; HUNT, L. A.; INGWERSEN, J.; IZAURRALDE, R. C.; KERSEBAUM, K. C.; MULLER, C.; NARESH KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. A.; OSBORNE, T. M.; PALOSUO, T.; STOCKLE, C.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; TRAVASSO, M.; WAHA, K.; WALLACH, D.; WHITE, J. W.; WILLIAMS, J. R.; WOLF, J. Uncertainty in simulation wheat yields under climate change. **Nature Climate Change**, London, v.3, p. 827-832, 2013.
- BAN, H. Y.; SIM, D.; LEE, K. J.; KIM, J.; KIM, K. S.; LEE, B. W. Evaluating maize growth models "CERES-Maize" and "IXIM-Maize" under elevation temperature conditions. **Journal of Crop Science and Biotechnology**, Van Godewijckstraat, v.18, p. 265-272, 2015.
- BATTISTI, R. Calibration, uncertainties and use of soybean crop simulation models for evaluating strategies to mitigate the effects of climate change in Southern Brazil. **Tese apresentada para obtenção do título de Doutor em agronomia**, Piracicaba: ESALQ - USP, 2016.

- BATTISTI, R., SENTELHAS, P.C., KENNETH, J.B. Inter-comparison of performance of soybean crop simulation models and their ensemble in southern Brazil. **Field Crops Research**, Amsterdam, v.200, p. 28-37, 2017.
- BASSU, S.; BRISSON, N.; DURAND, J.L.; BOOTE, K.; LIZASO, J.; JONES, J.W.; ROSENZWEIG, C.; RUANE, A.C.; ADAM, M.; BARON, C.; BASSO, B.; BIERNATH, C.; BOOGAARD, H.; CONJIN, S.; CORBEELS, M.; DERYNG, D.; SANCTIS, G.; GAYLER, S.; GRASSINI, P.; HATFIELD, J.; HOEK, S.; IZZAULRRAUDE, C.; JONGSCHAAP, R.; KEMANIAM, A.R.; KERSEBAUM, K.C.; KIM, S.H.; KUMAR, N.S.; MAKOWSKI, D.; MULLER, C.; NENDEL, C.; PRIESACK, E.; PRAVIA, M.V.; SAL, F.; SHCHERBANK, I.; TAO, F.; TEIXEIRA, E.; TIMLIM, D.; WAHA, K. **How do various maize crop models vary in their response to climate change factors?**. *Global Change Biology*, Madison, v. 20, p.2301-2320, 2014.
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes modelos de estimativa de evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.5, p.89-97, 1997.
- CHAUHAN, Y. S.; SOLOMON, K. F.; RODRIGUEZ, D. Characterization of north-eastern Australian environments using APSIM for increasing rainfed maize production. **Field Crops Research**, Amsterdam, v.144, p. 245-255, 2013.
- CHISANGA, C. B.; PHIRI, E.; SHEPANDE, C.; SICHINGABULA, H. Evaluating CERES-Maize model using planting dates and nitrogen fertilizer in Zambia. **Journal of Agricultural Science**, Cambridge, v.7, p. 79-97, 2015.
- COSTA, L. G.; MARIN, F. R.; NASSIF, D. S. P.; PINTO, H. M. S.; LOPES-ASSAD, M. L. R. C. Simulação do efeito do manejo da palha e do nitrogênio na produtividade da cana-de-açúcar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, p. 469-474, 2014.
- DIAS, H. B. Intercomparação de modelos de simulação da cana-de-açúcar e seu uso na avaliação da quebra de produtividade e dos impactos da irrigação em diferentes regiões do Brasil. **Tese apresentada para obtenção do título de Mestre em agronomia**, Piracicaba: ESALQ - USP, 2016.
- DRIESSEM, P. M.; KONIJM, N. T. Land use system analysis. **Wageningen Agricultural University**, Wageningen, p. 230, 1992.
- DOORENBOS, J.; KASSAM, A. H. Yield response to water. **FAO: Irrigation and Drainage paper**, 33, Roma, p. 212, 1979.

- DURAND, J.L.; DELUSCA, K.; BOOTE, K.; LIZASO, J.; MANDERSCHIED, R.; WEIGEL, H.J.; RUANE, A.C.; ROSENZWEIG, C.; JONES, J.; AHUJA, L.; ANAPALILIR, S.; BASSO, B.; BARON, C.; BERTUZZI, P.; BIERNATH, C.; DERYNG, D.; EWERT, F.; GAISER, T.; GAYLER, S.; HEINLEIN, F.; KERSEBAUM, K.C.; KIM, S.H.; MULLER, C.; NENDEL, C.; OLIOSO, A.; PRIESACK, E.; VILLEGAS, J.R.; RIPOCHE, D.; ROTTER, R.P.; SEIDEL, S.I.; SRIVASTAVA, A.; TAO, F.; TIMLIN, D.; TWINE, T.; WANG, E.; WEBBWE, H.; ZHAO, Z. How accurately do maize crop models simulate the interactions of atmospheric CO₂ concentration levels with limited water supply on water use and yield? **European Journal of Agronomy**, Amsterdam, v. 91, p.1-9, 2017.
- GARCÍA-LOPEZ, J.; LORITE, I. J.; GARCÍA-RUIZ, R.; DOMÍNGUEZ, J. Evaluation of three simulation approaches for assessing yield of rainfed sunflower in Mediterranean environment for climate change impact modeling. **Climate Change**, Dordrecht, v.162, p. 124-147, 2014.
- GOUVÊA, J. R. F.; SENTELHAS, P. C.; GAZZOLA, S. T.; SANTOS, M. C. Climate changes and technological advances: impacts on sugarcane productivity in tropical Southern Brazil. **Scientia Agricola**, Piracicaba, v.66, p. 593-605, 2009.
- HEINEMANN, A. B.; DINGKUHN, M.; LUQUET, D.; COMBRES, J. C.; CHAPMAN, S. Characterization of drought stress environments for upland rice and maize in central Brazil. **Euphytica**, Van Godewijckstraat, v.162, p. 395-410, 2008.
- HOOGENBOON, G.; JONES, J.W.; PORTER, C.H.; WILKENS, P.W.; BOOTE, K.J.; BATCHELOR, W.D.; HUNT, L.A.; TSUJI, G.Y. DSSAT v4 – A Decision Support System for Agrotechnology Transfer. **International Consortium for Agricultural Systems Applications**, Hawaii, 2003.
- JABEEN, F.; ASIF, M.; IFTIKHAR, A.; SALMAN, M. Temperature trends and its impact on Zea mays (maize) crop in Faisalabad city through DSSAT-CERES-Maize model. **Scientia Agriculturae**, Pakistan, v.17, p. 8-14, 2017.
- JUSTINO, F.; OLIVEIRA, E. C.; RODRIGUES, R. A.; GONÇALVES, P. H. L.; SOUZA, P. J. O. P.; STORDAL, F.; MARENGO, J.; SILVA, T. G.; DELGADO, R. C.; LINDEMANN, D. S.; COSTA, L. C. Mean and interannual variability of maize and soybean in Brazil under global warming conditions. **American Journal of Climate Change**, Chicago, v.2, p. 237-253, 2013.
- KINIRY, J.R.; WILLIAMS, J.R.; VANDERLIP, R.L.; ATWOOD, J.D.; REICOSKY, D.C.; MULLIKEN, J.; COX, W.J.; MASCANI JR., H.J.; HOLLINGER, S.E.; WIEBOLD, W. J. Evaluation of two maize models for nine U. S. locations. **Agronomy Journal**, Madison, v.89, p.421-426, 1997.

- LIU, H. L.; YANG, J. Y.; DRURY, C. F.; REYNOLDS, W. D.; TAN, C. S.; BAI, Y. L.; HE, P.; JIN, J.; HOOGENBOON, G. Using the DSSAT-CERES-Maize model to simulate crop yield and nitrogen cycling in fields under long-term continuous maize production. **Nutrient Cycling in Agrossystems**, Van Godewijkstraat, v.89, p. 131-328, 2011.
- LIU, Z.; YANG, X.; HUBBARD, K. G.; LIN, X. Maize potential yield gaps in the changing climate of northeast China. **Global Change Biology**, Oxford, v.18, p. 3441-3454, 2012.
- LOPEZ, J. R.; ERICKSON, J. E.; ASSENG, S.; BOBEDA, E. L. Modification of the CERES grain sorghum model to simulate optimum sweet sorghum rooting depth for rainfed production on coarse textured soils in a sub-tropical environment. **Agricultural Water Management**, Amsterdam, v.181, p. 47-55, 2017.
- MARIN, F. R. Eficiência da produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos. **Tese de livre-docência**, Piracicaba: ESALQ - USP, 2014.
- MARTRE, P.; WALLACH, D.; ASSENG, S.; EWERT, F.; JONES, J. W.; ROTTER, R. P.; BOOTE, K. J.; RUANE, A. C.; THORBURNE, P. J.; CAMMARANO, D.; HATFIELD, J. L.; ROSENZWEIG, C.; AGGARWAL, P. K.; ÂNGULO, C.; BASSO, B.; BERTUZZI, P.; BIERNATH, C.; BRISSON, N.; CHALLINOR, A. J.; DOLTRA, J.; GAYLER, S.; GOLDBERG, R.; GRANT, R. F.; HENG, L.; HOOKER, J.; HUNT, L. A.; INGWERSEN, J.; IZAURRALDE, R. C.; KERSEBAUM, K. C.; MULLER, C.; KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. A.; OSBORNE, T.; PALOSUO, T.; PRIESACK, E.; RIPOCHE, D.; SEMENOV, M. A.; SHCHERBAK, I.; STEDUTO, P.; STOCKLE, C. O.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; TRAVASSO, M.; WAHA, K.; WHITE, J. W.; WOLF, J. Multimodel ensembles of wheat growth: many models are better than one. **Global Change Biology**, Oxford, v.21, p. 911-925, 2014.
- MONTEIRO, J. E. B. A.; ASSAD, E. D.; SENTELHAS, P. C.; AZEVEDO, L. C. Modeling of corn yield in Brazil as a function of meteorological conditions and technological level. **Pesquisa Agropecuária Brasileira**, Brasília, v.52, p. 137-148, 2017.
- MONTEIRO, L. A. Sugarcane yield gap in Brazil: a crop modelling approach. Tese apresentada para obtenção do título de Doutor em agronomia, Piracicaba: ESALQ - USP, 2015.
- MONTEIRO, L. A.; SENTELHAS, P. C. Sugarcane yield gap: can it be determined at national level with a simple agrometeorological model?. **Crop & Pasture Science**, Melbourne, v.68, p. 272-284, 2017.

- NEGM, L. M.; YOUSSEF, M. A.; JAYNES, D. B. Evaluation of DRAINMOD-DSSAT simulated effects of controlled drainage on crop yield, water balance, and water quality for a corn-soybean cropping system in central Iowa. **Agricultural Water Management**, Amsterdam, v.187, p. 57-68, 2017.
- PALOSUO, T.; KERSEBAUM, K. C.; ANGULO, C.; HILAVINKA, P.; MORIONDO, M.; OLESEN, J. E.; PATIL, R. H.; RUGET, F.; RUMBAUR, C.; TAKÁČ, J.; TRNKA, M.; BINDI, M.; CALDAG, C.; EWERT, F.; FERRISE, R.; MIRSCHEL, W.; SAYLAN, L.; SISKÁ, B.; ROTTER, R. Simulation of winter wheat yield and its variability in different climates of Europe: a comparison of eight crop growth models. **European Journal Agronomy**, Amsterdam, v.35, p. 103-114, 2011.
- PEAK, A. S.; ROBERTSON, M. J.; BIDSTRUP, R. J. Optimizing maize plant population and irrigation strategies on the Darling Downs using the APSIM crop simulation model. **Australian Journal of Experimental Agriculture**, Collingwood, v.48, p. 313-325, 2008.
- PICCINI, G.; KO, J.; MAREK, T.; HOWELL, T. Determination of growth-stage-specific crop coefficients (K_c) of maize and sorghum. **Agricultural Water Management**, Amsterdam, v.96, p. 1698-1704, 2009.
- PRADO, H. Pedologia fácil: aplicação em solos tropicais. 4ª Edição, Piracicaba: O Autor, UFV, p. 284, 2013.
- PRIESTLEY, C.H.B., TAYLOR, R.J. On the assessment of surface heat flux and evapotranspiration, using large scale parameters. **Monthly Weather Review**, New York, v.100, p. 81-92, 1972.
- RAES, D.; GEERTS, S.; KIPKORIR, E.; WELLENS, J.; SHALI, A. Simulation of yield decline as a result of water stress with a robust soil water balance model. **Agricultural Water Management**, Amsterdam, v.81, p. 335-357, 2006.
- RITCHIE, J.T. Model for predicting evaporation from a row crop with incomplete cover. **Water Resources Research**, Colorado, v.8, p. 1204-1213, 1972.
- ROSENZWEIG, C.; JONES, J.W.; HATFIELD, J.L.; RUANE, A.C.; BOOTE, K.J.; THORBURN, P.; ANTLE, J.M.; NELSON, G.C.; POTER, C.; JANSSEN, S.; ASSENG, S.; BASSO, B.; EWERT, F.; WALLACH, D.; BAIGORRIA, G.; WINTER, J.M. The agricultural model intercomparison and improvement project (AgMIP): Protocols and pilot studies. **Agricultural and Forest Meteorology**, Amsterdam, v.170, p. 166-182, 2013.

- ROSENZWEIG, C.; JONES, J.W.; ANTLE, J.M.; HATFIELD, J.L. Protocols for AgMIP regional integrated assessments. The Agricultural Model Intercomparison and Improvement Project, New York, v.6, p. 1-63, 2015.
- SANTOS, D. L.; SENTELHAS, P. C. Climate change scenarios and their impact on water balance and sugar yield in Southern Brazil. **Sugar Tech**, Stanford, v.16, p.356-365, 2014.
- SENTELHAS, P. C.; BATTISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A. C.; NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **Journal of Agriculture and Science**, Cambridge, v.158, p. 1394-1411, 2015.
- SHRESTHA, S.; CHAMPAGAIN, R.; BABEL, M. S.; Quantifying the impact of climate change on crop yield and water footprint on rice in the Nam Oon irrigation Project, Thailand. **Science of the Total Environment**, Amsterdam, p. 689-699, 2017.
- SINGH, P. K.; SINGH, K. K.; BHAN, S. C.; BAXLA, A. K.; SINGH, S.; RATHORE, L. S.; GUPTA, A. Impact of projected climate change on rice (*Oryza sativa* L.) yield using CERES-rice model in a different agroclimatic zones of India. **Current Science**, Bengaluru, v.112, p. 108-115, 2017.
- SOLER, C. M. T.; SENTELHAS, P. C.; HOOGENBOON, G. The impact of El Niño Southern Oscillation phases on off-season maize yield for a subtropical region of Brazil. **International Journal of Climatology**, Oxford, v.30, p. 1056-1066, 2010.
- SOUZA, R. F.; BARROS, A. C.; BARROS, A. H. C.; TABOSA, J. N. Estimates for maize yield (*Zea mays* L.) in rainfed and irrigated crops determined by the method of Agroecological Zone/FAO (MZA/FAO), state of Alagoas, Brazil. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.8, p. 127-138, 2014.
- THORNTHWAITE, C. W.; MATHER, J. R. The water balance. Publications in Climatology. **Drexel Institute of Technology**, New Jersey, p. 104, 1955.
- WALLACH, D.; MEARNES, L. O.; RUANE, A. C.; ROTTER, R. P.; ASSENG, S. Lessons for climate modeling on the design and use of ensembles for crop modeling. **Climatic Change**, Van Godewijckstraat, v.139, p. 551-564, 2016.
- WANG, J.; WANG, E.; YANG, X.; ZHANG, F.; YIN, H. Increased yield potential of wheat-maize cropping system in the north China plain by climate change adaptation. **Climatic Change**, Van Godewijckstraat, v.113, p. 825-840, 2012.
- WILLMOTT, C. J. On the validation of models. **Physical Geography**, Norwich, v.2, p.184-194, 1981.

- XAVIER, A. C., KING, C. W., SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **Royal Meteorology Society – International Journal of Climatology**, Austin, 2015.
- YIN, X.; KERSEBAUMB, K. C.; KOLLAS, C.; MANEVSKIA, K.; BABY, S.; BEAUDOIN, N.; ÖZTÜRK, I.; GAISER, T.; WU, L.; HOFFMANN, M.; CHARFEDDINE, M; CONRADT, T.; CONSTANTIN, J.; EWERT, F.; CORTAZAR-ATAURI, N. G.; GIGLIO, L.; HLAVINKA, P.; HOFFMANN, H.; LAUNAY, M.; LOUARN, G.; MANDERSCHIED, R.; MARY, B.; MIRSCHEL, W.; NENDEL, C.; PACHOLSKI, A.; PALOSUO, T.; RIPOCHE-WACHTER, D.; RÖTTER, R. P.; RUGET, F.; SHARIF, B.; TRNKA, M.; VENTRELLA, D.; WEIGEL, H.; OLESEN, J. E. Performance of process-based models for simulation of grain N in crop rotation across Europe. **Agricultural Systems**, Amsterdam, v.154, p. 63-77, 2017.
- ZHANG, L.; WALKER, G. R.; DAWES, W.R. Water balance modeling: concepts and applications. In: MECVICAR, T. R.; RUI, L; WALKER, J; FITZPATRICK, R. W.; CHANGMING, L. Regional water and soil assessment for managing sustainable agriculture in China and Australia. **CISRO**, Adelaide, p. 31-47, 2002.
- ZHANG, Y.; ZHAO, Y. Ensemble yield simulation: using heat-tolerant and later-maturing varieties to adapt to climate warming. **Plos ONE**, Changchun, v.12, 2017.

4. DEFINIÇÃO DA ÉPOCA PREFERENCIAL DE SEMEADURA E PREVISÃO DE PRODUTIVIDADE DA CULTURA DO MILHO EM DIFERENTES LOCALIDADES BRASILEIRAS, COM BASE NO USO DE MODELOS DE SIMULAÇÃO

Resumo

A crescente demanda mundial por produtos agropecuários vem incentivando os produtores rurais a aumentar suas produtividades, o que tem contribuindo para reduzir o impacto ambiental, já que com isso há uma desaceleração do avanço da fronteira agrícola para áreas marginais. Entretanto, diversos são os fatores que dificultam o aumento da produtividade, dentre eles, o manejo dos cultivos. Das diversas características do manejo, o posicionamento adequado da semeadura na época correta e a utilização de sistemas de previsão de produtividade são características de baixo ou nenhum custo que possibilitam tanto maiores ganhos em produtividade quanto maior tempo e flexibilidade para traçar estratégias de colheita, armazenamento e comercialização da produção. Para auxiliar na determinação de épocas mais adequadas à semeadura assim como para estimar a produção com antecedência, pode-se lançar mão dos modelos de simulação de culturas, que são ferramentas que consideram de forma integrada as diversas características do ambiente de produção e da cultura a ser simulada. Tendo em vista a importância da definição correta da época de semeadura e da previsão de safra, os objetivos deste estudo foram: i) determinar as melhores épocas de semeadura para a cultura do milho no Brasil, considerando três diferentes tipos de solo, por meio da combinação de diferentes modelos de simulação da cultura do milho, previamente calibrados e testados; e ii) desenvolver uma ferramenta capaz de prever a produtividade da cultura do milho com certa antecedência em relação à colheita, baseada na combinação do modelo MZA-FAO e de dados climáticos históricos médios. Para tanto, foram utilizados modelos de simulação de cultura, previamente calibrados e ajustados, afim de determinar as melhores épocas de semeadura para uma série de dados meteorológicos compreendida entre 1980 e 2013. A média histórica dessa série também foi utilizada para a combinação dos dados meteorológicos presentes, utilizada na previsão de safra. A época mais recomendada para a semeadura do milho foi durante os meses de outubro e novembro, para o milho safrinha, e durante os meses de janeiro e início de fevereiro, para o milho safrinha, na grande maioria das regiões analisadas. Nesses meses, além de produtividades mais elevadas, ocorreram as menores variabilidades interanuais dessas, indicando baixos riscos de quebra de produtividade devido a adversidades climáticas, especialmente na condição de solo com textura argilosa. Quanto ao sistema de previsão de safra, os resultados indicaram a possibilidade de se prever com alto grau de precisão acurácia ($R^2 \geq 0,81$, $d \geq 0,90$ e $C \geq 0,81$) a produtividade do milho com até 25 dias de antecedência à colheita, sendo que em alguns casos esse prazo chegou a 45 dias.

Palavras-chave: Milho; Época de semeadura; Modelos de simulação de cultura; Previsão de safra

Abstract

The increasing worldwide demand for agricultural products has encouraging growers to improve their yields, which has contributed to reduce the environmental impact, once the advance of agricultural frontier to marginal areas is diminishing. However, there are several factors that make difficult to increase yields, among them, crop management. Among the several crop managements, the definition of the correct sowing and the use of a yield forecast system are those of low or no cost that can allow to achieve both higher yields and enough time and flexibility to adopt the best strategies for harvest, storage and commercialization. In order to determine the best sowing dates for maize, as well as to forecast yields, a crop simulation model was employed, to integrate all the characteristics of the environment and of the crop to be simulated. Considering the importance of the correct definition of the sowing date and yield forecast, the objectives of this study were: i) to determine the best maize sowing dates in Brazil, considering three different soils and combining three different maize simulation models, previously calibrated and tested; and (ii) to develop a tool capable to forecast maize yields in advance to the harvest, based on the AEZ-FAO model and combining observed and average historical climatic data. To that, calibrated and adjusted crop simulation models were used to determine the best sowing dates for data historical series of 34 years, from 1980 to 2013. The weather historical data was also used, combined with present weather data, to forecast maize yield. The most recommended maize sowing date was between October and November, for the first maize season, and between January and beginning of February, for the second maize season. In these months, in addition to higher yields, there were lower risks of yield gaps, caused by the rainfall interannual variability, indicating absence of adverse weather conditions, especially in the clay soil condition. Regarding to the yield forecasting system, the results indicated the possibility of predicting maize yields with high precision and accuracy ($R^2 \geq 0.81$, $d \geq 0.90$ and $C \geq 0.81$) with up to 25 days before harvest, with some cases reaching 45 days.

Keywords: Maize; Sowing date; Crop simulation models; Yield forecasting

4.1. Introdução

Nos últimos anos, agricultores do mundo todo vêm enfrentando o desafio de elevar suas produtividades, a fim de suprir a crescente demanda por alimentos, fibras e energia (Sacks et al., 2010). Diversos são os fatores que influenciam a produtividade agrícola, desde

o clima local, genótipo escolhido, práticas de manejo adotadas, tais como data de plantio, adubação, irrigação, entre outras. Nesse contexto, o clima, sua variabilidade e as possíveis mudanças futuras se tornaram temas frequentes de diversos estudos ao redor do mundo (Andrioli e Sentelhas, 2009; Cantele, 2009; Gouvêa et al., 2009; Wang et al., 2009; Lobell e Burke, 2010; Costa et al., 2014; Skocaj et al., 2013; Santos e Sentelhas, 2014; Andarzian et al., 2015; Battistti e Sentelhas, 2015; Challinor et al., 2015; Chisanga et al., 2015; Magaia et al., 2017; Nouri, 2017; Nyagumbo et al., 2017; Shrestha et al., 2017).

Com relação às práticas de manejo, o posicionamento da cultura dentro da janela de semeadura é uma das que mais afeta o potencial produtivo, principalmente para as culturas de sequeiro, havendo uma grande variação das produtividades em função da data de semeadura escolhida (Bannayan et al., 2013; Andarzian et al., 2015). Portanto, ajustar a data de semeadura é uma alternativa barata e que pode trazer grandes benefícios para o produtor, evitando períodos de adversidades climáticas em momentos críticos para os cultivos, resultando assim, em um maior potencial produtivo e um menor risco para a produção.

Dentre as diversas ferramentas que podem ser utilizadas para aumentar a eficiência de uma propriedade agrícola, podemos destacar o preparo do solo, a escolha de um genótipo adaptado e o posicionamento da cultura em épocas favoráveis ao seu desenvolvimento. Além dessas ações de planejamento pré-plantio, também se destacam as ferramentas de manejo durante o período de crescimento/desenvolvimento da cultura, como controle de pragas, doenças e plantas invasoras. Outro ponto importante que deve ser considerado, ligado ao planejamento de colheita, armazenamento e comercialização, é a previsão de safra, a qual depende da estimativa da produtividade agrícola e da área plantada.

Várias são as metodologias utilizadas tanto para a determinação das melhores épocas de semeadura como para a previsão de safra. Dentre as ferramentas empregadas para a determinação das melhores datas de semeadura tem-se os experimentos de campo, as simulações do balanço hídrico, como empregado no zoneamento de risco climático do Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2017), ou o emprego de simulações das produtividades por meio de modelos de culturas, os quais também podem ser utilizados para a previsão de safra, conjuntamente com outras ferramentas, como previsão do clima, como o DEMETER (*Development of a European Multimodel Ensemble*

System for Seasonal to Interannual Prediction) (Palmer et al., 2004) e imagens de satélites ou fotos digitais para aplicação de índices de vegetação, como o NDVI (*Normalised Difference Vegetation Index*) (Son et al., 2014; Song et al., 2016; Saeed et al., 2017).

Os modelos de simulação de culturas proporcionam a interação entre o genótipo (cultura e genótipo) o ambiente (solo e clima) e as práticas de manejo, como irrigação e adubação, de modo a definir os níveis de produtividade potencial (PP) e atingível (PA). Essa abordagem multidisciplinar proposta pelos modelos de simulação possibilita um melhor entendimento das interações solo-clima-plantas, auxiliando na escolha das melhores épocas de semeadura, quando as produtividades são simuladas para diferentes datas e anos, o que possibilita gerar informações com mais critério e mais precisas. Além disso, esses modelos, quando devidamente ajustados para a condição local, podem auxiliar na previsão de safra, definindo com precisão e acurácia os níveis de produtividade da cultura. Diversos são os tipos de modelos de simulação de cultura disponíveis na literatura, desde os mais simples, como os modelos empíricos, até os mais complexos, como os modelos mecanísticos. Além desses existem também os modelos intermediários, que mesclam características empíricas e mecanísticas de forma a facilitar sua utilização. A complexidade dos modelos e seus desempenhos dependem também da quantidade de informações necessárias para alimentá-los, sendo que quanto maior a complexidade do modelo maior a quantidade de dados de entrada - *inputs* (Zhang et al., 2002).

Como exemplo de modelo intermediário, pode-se citar o Modelo da Zona Agroecológica da FAO (MZA-FAO), proposto por Doorenbos e Kassam (1979), que se baseia na determinação de uma produtividade potencial (PP), por meio de relações empíricas entre um potencial acúmulo de matéria seca pela planta em função da radiação solar, temperatura do ar e do fotoperíodo, e a sua correção por meio de coeficientes como: coeficiente de respiração (c_{resp}); coeficiente do índice de área foliar (c_{IAF}); coeficiente de colheita (c_{col}) e coeficiente de umidade (c_{um}). Uma vez definida a PP, o modelo calcula a PA por meio da penalização da PP pelo déficit hídrico, usualmente determinado pelo balanço hídrico de Thornthwaite e Mather (1955) para uma capacidade de água disponível do solo, definida pelas características do solo predominante da região e da cultura em questão, modulado por um coeficiente de sensibilidade ao déficit hídrico (K_y), específico para cada fase fenológica da cultura.

Em relação aos modelos classificados como complexos, pode-se citar os modelos mecanísticos que fazem parte dos sistemas DSSAT (*Decision Support System for Agrotechnology Transfer*) e APSIM (*Agricultural Production Systems sIMulator*), os quais determinam o crescimento e o desenvolvimento da planta baseados em diferentes processos. Esses sistemas empregam modelos mais complexos para simular o balanço de água no solo, ambos com base no método de Ritchie (1972), além de estimar a evapotranspiração das culturas por meio da interação dos métodos de Penman-Monteith (Allen et al., 1998) ou Priestley-Taylor (1972), para a estimação da evapotranspiração de referência, com o crescimento simulado da cultura. Apesar dessa distinção entre a complexidade dos modelos, vale ressaltar que maiores complexidades nem sempre se refletem num melhor desempenho. Na realidade, o desempenho dos modelos está condicionado aos processos de calibração e avaliação, ou seja, o desempenho independe do grau de complexidade, conforme apontaram Sentelhas et al. (2015) e Monteiro e Sentelhas (2017).

Mesmo com essa grande diversidade de modelos, de suas aplicações e de seus níveis de complexidade, o processo de calibração de um modelo para um dado genótipo posicionado num determinado ambiente é difícil, sendo praticamente impossível fazê-lo isento de erros, já que as incertezas das simulações são inevitáveis para qualquer modelo de simulação de culturas. Assim, com o intuito de minimizar ao máximo os erros gerados por esses modelos de simulação, vem se tornando frequente o uso da técnica denominada de *ensemble*, ou abordagem multi-modelos, que visa combinar os resultados de diferentes modelos de simulação de culturas, com diferentes níveis de complexidade, a fim de melhorar o desempenho das simulações, aumentando a acurácia e a precisão dos resultados (Palosuo et al., 2011, Asseng et al., 2013, Battisti et al., 2017). Vários trabalhos já relataram melhorias significativas no desempenho das simulações quando o *ensemble* é aplicado (Asseng et al., 2013); Marin, 2014; Martre et al., 2014; Dias ,2016; Battisti et al., 2017), o que se deve basicamente à compensação de erros.

Visto a importância da determinação da melhor época de semeadura e da previsão da produtividade do milho, o presente estudo teve por objetivo identificar, por meio do uso de modelos de simulação de culturas, as épocas mais favoráveis à semeadura do milho durante a primeira e a segunda (safrinha) safras, assim como desenvolver e avaliar um

sistema de previsão de produtividade com base em dados meteorológicos históricos médios em conjunto com dados diários observados, para diferentes localidades brasileiras.

4.2. Material e métodos

4.2.1. Localidades do estudo

A fim de avaliar a variabilidade da produtividade atingível (PA) do milho ao longo do ano, buscando determinar as melhores épocas de semeadura da cultura, assim como elaborar um sistema de previsão da produtividade dessa cultura, 15 localidades brasileiras distribuídas em diferentes regiões (Tabela 4.1) foram selecionadas.

Tabela 4.1. Localidades empregadas na determinação das melhores épocas de semeadura e na previsão de produtividade da cultura do milho

Cidade	UF	Latitude Sul	Longitude Oeste	Altitude
Abelardo Luz	SC	26,56	52,26	760
Altamira	PA	06,48	53,89	109
Brasília	DF	15,78	47,82	1171
Caarapó	MS	22,59	54,80	471
Catalão	GO	17,93	47,67	835
Lagarto	SE	10,90	37,67	183
Machado	MG	21,66	45,52	820
Mateiros	TO	10,58	46,51	493
Muitos Capões	RS	28,39	51,23	937
Piracicaba	SP	22,70	47,60	547
Ponta Grossa	PR	25,08	50,15	975
Primavera do Leste	MT	15,10	54,22	636
S. Raimundo das Mangabeiras	MA	07,00	45,50	225
São Desiderio	BA	12,30	45,00	492
Uruçuí	PI	07,79	44,57	167

As épocas ou janelas de semeadura da cultura do milho, assim como a densidade de distribuição da semeadura dentro da janela, para cada região do país se encontram na Tabela 4.2.

Tabela 4.2. Densidade de distribuição da semente da cultura do milho dentro da janela de cultivo em cada região geográfica do Brasil

Época recomendada para a semente na safra e a concentração % da semente em cada região do Brasil								
	Setembro	Out-1	Out-2	Out-3	Nov-1	Nov-2	Nov-3	Dezembro
S	<0,01	0,12	0,12	0,25	0,25	0,12	0,12	<0,01
SE	<0,01	0,12	0,12	0,25	0,25	0,12	0,12	<0,01
CO	<0,01	0,12	0,12	0,25	0,25	0,12	0,12	<0,01
NE	<0,01	0,12	0,12	0,25	0,25	0,12	0,12	<0,01
N	<0,01	0,12	0,12	0,25	0,25	0,12	0,12	<0,01
Época recomendada para a semente na safrinha e a concentração % da semente em cada região do Brasil								
	Janeiro	Fev-1	Fev-2	Fev-3	Mar-1	Mar-2	Mar-3	Abril
S	<0,05	0,15	0,35	0,25	0,08	0,06	0,06	<0,01
SE	<0,01	<0,01	0,07	0,08	0,20	0,35	0,15	<0,15
CO	<0,01	0,15	0,30	0,20	0,15	0,15	0,05	<0,01
NE	<0,01	0,40	0,35	0,20		<0,05		<0,01
N	<0,01	0,40	0,35	0,20		<0,05		<0,01

Adaptado de: Cruz et al. (2010); EMBRAPA (2010); CONAB (2017) e Ministério da agricultura, pecuária e abastecimento (2017).

4.2.2. Dados meteorológicos

O presente estudo empregou dados meteorológicos diários (chuva, radiação solar, temperatura e umidade relativa do ar e velocidade do vento) para o período compreendido entre 1980 e 2013. Essas informações foram obtidas junto ao Instituto Nacional de Meteorologia (INMET), ao sistema *DailyGridded* (Xavier et al., 2012) e ao banco de dados de chuva da Agência Nacional de Águas (ANA). A consistência de todo o banco de dados seguiu os mesmos procedimentos apresentados nos Capítulos 2 e 3.

4.2.3. Dados de solo

Buscando demonstrar a variabilidade dos solos nas diferentes localidades escolhidas, três perfis de solo foram aplicados no estudo, classificados de acordo com a textura, em: argilosa; média e arenosa. Por não existirem pontos de coleta de dados de solo para o estudo, se fez uso dos perfis de solos brasileiros disponíveis na plataforma DSSAT 4.6 (2015). Esses perfis foram limitados em um metro de profundidade, divididos em camadas de 0 a 10, 11 a 20, 21 a 40, 41 a 60, 61 a 80, e 81 a 100 cm, e agrupados de acordo com a classe textural média ao longo do perfil. A partir desse agrupamento, foram calculadas as médias dos valores de cada característica do solo para cada uma das camadas, formando um perfil médio de solo com texturas argilosa, média e arenosa. A partir desses solos, foram desenvolvidos os perfis de solo de cada um dos modelos utilizados nesse estudo (Anexo A).

4.2.4. Avaliação da influência das épocas de semeadura na produtividade da cultura do milho em diferentes localidades brasileiras

Para a determinação das produtividades atingíveis (PA) das localidades apresentadas na Tabela 4.1, foi utilizado o *ensemble* dos modelos de simulação da cultura do milho MZA-FAO, DSSAT Ceres-Maize e APSIM-Maize, os quais foram devidamente apresentados, calibrados e avaliados no Capítulo 3. Foram simuladas semeaduras decendiais, totalizando 36 semeaduras por ano para cada local e para cada classe textural de solo. As épocas com as melhores produtividades simuladas foram comparadas às épocas de semeadura de safra e safrinha apresentadas na Tabela 4.2. Com o intuito de apresentar a variabilidade da PA para cada época de semeadura (decêndio) em cada uma das localidades, além da variabilidade interanual da PA para a safra e a safrinha, foram elaborados gráficos do tipo *boxplot* com o auxílio da plataforma R (R Core Team, 2017). O critério para se considerar uma dada de semeadura como recomendável se baseou nos valores mais elevados de PA e com menor variabilidade interanual.

4.2.5. Previsão da produtividade do milho safra e safrinha para diferentes localidades do Brasil

Para as análises de previsão de produtividade, fez-se uso do modelo MZA-FAO, devido a sua maior simplicidade e agilidade de uso, já que o intuito foi de avaliar o efeito do uso da média histórica dos dados meteorológicos na simulação da produtividade do milho e não o efeito do modelo na previsão em si. Além disso, esse modelo apresentou desempenho comparável com os demais modelos de simulação da cultura do milho, tanto na fase de calibração quanto na de avaliação, como apresentado no Capítulo 3.

O sistema de previsão de produtividade da cultura do milho empregou as séries históricas de dados meteorológicos diários para a série histórica de 1980 a 2013 para as localidades listadas na Tabela 4.1, assim como as médias diárias para esse período. As semeaduras da safra e da safrinha foram simuladas sempre no segundo decêndio de cada mês da janela de semeadura, de setembro a abril (Tabela 4.2). Nessa etapa, apenas um cenário de solo, classificado como de textura média, foi utilizado durante as análises.

Para avaliar o efeito do uso de dados médios na previsão da produtividade de milho, cinco estratégias de previsão foram elaboradas (Figura 4.1): E1) utilizando dados históricos apenas nos últimos cinco dias do ciclo; E2) utilizando dados históricos nos últimos 25 dias do ciclo; E3) utilizando dados históricos nos últimos 45 dias do ciclo; E4) utilizando dados nos 65 últimos dias do ciclo e E5) utilizando dados históricos nos últimos 85 dias do ciclo. Dessa forma, foram realizadas oito simulações por ano (semeaduras de setembro a abril) para cada uma das estratégias de previsão elaboradas e para cada uma das localidades estudadas. Na condição de controle foi considerada a simulação da produtividade apenas com dados meteorológicos diários observados em cada ano.

Figura 4.1. Esquema representativo da elaboração das estratégias de previsão da produtividade da cultura do milho para as diferentes localidades brasileiras (Controle: uso de dados meteorológicos observados na estimação da produtividade; E1: estratégia 1; E2: estratégia 2; E3: estratégia 3; E4: estratégia 4 e E5: estratégia)

Os resultados de cada estratégia adotada foram comparados aos da condição de controle (Figura 4.1). O desempenho de cada estratégia de previsão da produtividade foi obtido por meio dos seguintes indicadores: erro médio (EM); erro absoluto médio (EAM); raiz quadrada do erro médio (RQEM); índice de concordância 'd' (Willmott, 1981); coeficiente de determinação (R^2); e índice de confiança 'C' (Camargo e Sentelhas, 1997), além de gráficos do tipo *boxplot*, que foram elaborados para demonstrar a variabilidade interanual e sazonal da previsão de cada uma das estratégias adotadas em relação ao controle.

4.3. Resultados e discussão

4.3.1. Influência das épocas de semeadura na produtividade da cultura do milho em diferentes localidades do Brasil

A variabilidade da produtividade atingível do milho ao longo do ano foi expressiva em todos os locais analisados (Figura 4.2). De um modo geral, as melhores épocas de semeadura encontradas por meio das simulações coincidiram com o período indicado na janela de semeadura para cada região (Tabela 4.2), tanto para a safra quanto para a safrinha. Entretanto, é possível refinar ainda mais o posicionamento da semeadura do milho para se atingir maiores produtividades, evitando épocas com potenciais riscos climáticos. A Figura 4.2 apresenta a variabilidade da produtividade da cultura do milho ao longo do ano e para a série histórica analisada nas diferentes localidades, para uma situação de solo com textura média. As mesmas análises para os solos arenosos e argilosos se encontram no Anexo B.

Figura 4.2. Variabilidade da produtividade atingível (PA) da cultura do milho ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura 4.2. Variabilidade da produtividade atingível (PA) da cultura do milho ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura 4.2. Variabilidade da produtividade atingível (PA) da cultura do milho ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura 4.2. Variabilidade da produtividade atingível (PA) da cultura do milho ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura 4.2. Variabilidade da produtividade atingível (PA) da cultura do milho ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura 4.2. Variabilidade da produtividade atingível (PA) da cultura do milho ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

A Figura 4.2 indica as melhores épocas de semeadura em função da variabilidade da produtividade atingível (PA), tanto para safra quanto para a safrinha, já que o ideal é que as semeaduras sejam posicionadas nos momentos em que sejam obtidas as maiores PAs. Os resultados mostram uma forte ascensão do potencial produtivo a partir do final de agosto, alcançando valores médios próximos a 10.000 kg ha⁻¹ para locais como Abelardo Luz (SC); Brasília (DF); Piracicaba (SP) e Ponta Grossa (PR), entretanto, o risco climático em semeaduras antecipadas deve ser avaliado com cautela, já que a amplitude dos boxplot nas semeaduras do mês de agosto são maiores, indicando maior risco climático.

A janela de cultivo da Tabela 4.2 apresenta uma baixa concentração de semeaduras nos meses de setembro e dezembro, entretanto, os resultados mostram que semeaduras realizadas nesses meses, para a maioria dos locais avaliados, podem ser uma alternativa

interessante pois, apesar de uma ligeira redução da PA em semeaduras nesses meses, o risco associado a elas ainda é relativamente baixo. Em Uruçuí (PI), Catalão (GO) e São Desiderio (BA), o mês de dezembro é o que oferece o maior patamar produtivo. Para a safrinha, a Tabela 4.2 aponta uma forte concentração de semeaduras entre os meses de fevereiro e março, os quais, de acordo com os resultados obtidos, apresentam patamares de PA inferiores aos das semeaduras de janeiro e início de fevereiro, o que indica maiores penalizações da produtividade tanto pela redução da radiação solar e fotoperíodo, como também pelo aumento do déficit hídrico ao longo do ciclo. Em locais como Machado (MG), Muitos Capões (RS) e Ponta Grossa (PR), semeaduras de milho realizadas no mês de março podem atingir produtividades inferiores a 1000 kg ha^{-1} , devido às condições climáticas mais adversas, incluindo o risco de geadas.

Para se alcançar as melhores produtividades no cultivo do milho safrinha, a semeadura no mês de janeiro é a mais indicada, por apresentar os maiores patamares de PA na grande maioria das localidades analisadas. Semeaduras a partir do segundo decêndio de março implicam em reduções drásticas da PA, especialmente nas localidades situadas nos estados de SC, RS, DF, GO, TO, MT, MA, BA e PI (Figura 2). Padrão semelhante, porém, com menor redução da PA é observado em Altamira (PA), Caarapó (MS), Machado (MG), Piracicaba (SP) e Ponta Grossa (PR). Já em Lagarto (SE), em razão do regime diferenciado de chuvas, com essas se concentrando no primeiro semestre do ano, as melhores épocas de semeadura para a safra se encontram entre os meses de março e maio, enquanto que para a safrinha o período se estende de junho a julho.

Os resultados apresentados neste estudo concordam com os obtidos por Tommaselli e Vila Nova (1995), que indicaram que a melhor época de semeadura do milho, para o estado do Paraná, está compreendida entre o último decêndio de outubro e o primeiro decêndio de novembro. Faria et al. (2000) mostraram que, para o estado de Minas Gerais, a semeadura do milho safra é mais indicada a partir do último decêndio de setembro e ao longo de todo mês de outubro, mesmo período indicado por Flesch e Massignam (2000) para o cultivo do milho safra em Santa Catarina. Para o estado do Rio Grande do Sul, Nied et al. (2005) observaram que as datas de semeadura com menor risco para o cultivo do milho safra são aquelas ao longo do mês de dezembro, podendo se estender para o início do mês de janeiro. Já Garcia et al. (2013) encontraram que as melhores épocas de semeadura do

milho no estado do Mato Grosso estão compreendidas entre o final do mês de outubro e início do mês de novembro.

Apesar da época de semeadura do milho estar bem definida para diversas regiões do país, tão importante quanto avaliar o melhor momento para a semeadura é avaliar a variabilidade do seu potencial produtivo ao longo dos anos e o risco climático embutido em cada data de semeadura, analisando a variabilidade da produtividade atingível em cada época, e não apenas uma interação entre variáveis climáticas para um determinado período. Com isso, obtém-se uma informação mais precisa em relação ao posicionamento da semeadura do milho. Os resultados apresentados neste estudo permitem um melhor planejamento, distribuição e avaliação do risco climático da semeadura do milho ao longo da janela de cultivo para diversas localidades, buscando minimizar o impacto de condições meteorológicas adversas por meio de uma análise multi-fatores, pela interação entre o genótipo e o ambiente, e caracterizando a variabilidade dessa interação em termos da produtividade da cultura do milho na safra e na safrinha.

4.3.2. Previsão da produtividade da cultura do milho safra e safrinha para diferentes localidades do Brasil

Durante o processo de previsão da produtividade da cultura do milho em diferentes regiões do país foram observados EAMs variando entre 300 e 5000 kg ha⁻¹ para as diferentes estratégias de previsão nas diferentes épocas de semeadura, o que resultou em valores do índice C variando de 0,27 a 0,94. De um modo geral, pôde-se notar um desempenho melhor das estratégias de previsão que fizeram uso de menos dados históricos médios. As Figuras de 4.3 a 4.7 mostram o desempenho de cada estratégia de previsão da produtividade nas diferentes datas de semeadura para as localidades de Muitos Capões (RS); Piracicaba (SP); Catalão (GO); Primavera do Leste (MT); São Desiderio (BA) e São Raimundo das Mangabeiras (MA). O desempenho para as demais localidades avaliadas encontra-se no Anexo C.

Houve boa similaridade entre as simulações da estratégia E1 e as simulações com dados observados (Figura 4.3). Uma ligeira superestimativa, confirmada pelas análises apresentadas nas Tabelas 4.3 a 4.6, pode ser observada tanto pelo deslocamento do *boxplot* para cima quanto pelo deslocamento da linha de média dessa estratégia. E1 ainda acompanhou a variabilidade assim como acompanhou os valores máximos e mínimos

simulados com os dados meteorológicos observados (controle). Para todos os locais apresentados na Figura 4.3, os meses de melhor desempenho visual para a estratégia E1 foram aqueles no final da janela de cultivo do milho safrinha.

Figura 4.3. Variabilidade e comparação de médias da estratégia 1 (E1), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades de Muitos Capões, RS (a); Piracicaba, SP (b); Catalão, GO (c); Primavera do Leste, MT (d); São Desidério, BA (e) e São Raimundo das Mangabeiras, MA (f)

A estratégia E2 (Figura 4.4) apresentou uma maior superestimativa de previsão em relação a E1. Tanto o deslocamento do *boxplot* quanto o deslocamento da média ficaram

mais evidentes na Figura 4.4. Os valores máximos e mínimos também foram dilatados, prejudicando o desempenho da estratégia de previsão E2 em relação ao desempenho de E1. Entretanto, a amplitude de variação de E2 é similar à amplitude observada nas simulações com dados meteorológicos observados (controle). Assim como na estratégia anterior, os meses que apresentaram o melhor desempenho visual para a estratégia E2 foram os meses finais da janela de cultivo do milho safrinha, já que para as semeaduras nessas datas a variabilidade das chuvas nos últimos 25 dias do ciclo do milho são menores, se aproximando muito dos valores médios históricos.

Figura 4.4. Variabilidade e comparação de médias da estratégia 2 (E2), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades de Muitos Capões, RS (a); Piracicaba, SP (b); Catalão, GO (c); Primavera do Leste, MT (d); São Desiderio, BA (e) e São Raimundo das Mangabeiras, MA (f)

Figura 4.4. Variabilidade e comparação de médias da estratégia 2 (E2), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades de Muitos Capões, RS (a); Piracicaba, SP (b); Catalão, GO (c); Primavera do Leste, MT (d); São Desidério, BA (e) e São Raimundo das Mangabeiras, MA (f)

A estratégia de previsão E3, apresentada na Figura 4.5, mostra uma evidente superestimativa das simulações, confirmada pelas análises estatísticas das Tabelas 4.3 a 4.6. Além do deslocamento para cima do *boxplot* e da superestimativa das médias, é possível notar também um achatamento na variabilidade dos valores simulados por E3 assim como uma menor amplitude entre os valores máximos e mínimos. Essa menor variabilidade pode ser explicada pela própria característica da estratégia E3, que se vale do uso de 45 dias de dados meteorológicos médios para completar a simulação. Mesmo com essa queda de desempenho em relação às estratégias anteriores, notamos um bom ajuste de E3 ao prever as produtividades do milho semeado ao final da janela de cultivo da safrinha. Esse padrão de desempenho superior das estratégias de previsão na safrinha pode ser um indicativo de baixa variabilidade climática no período, já que os dados meteorológicos médios conseguem desempenhar melhor previsão da produtividade do milho semeado nessa época, o que, no entanto, depende da região.

Figura 4.5. Variabilidade e comparação de médias da estratégia 3 (E3), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades de Muitos Capões, RS (a); Piracicaba, SP (b); Catalão, GO (c); Primavera do Leste, MT (d); São Desidério, BA (e) e São Raimundo das Mangabeiras, MA (f)

Com um desempenho bem inferior às estratégias de previsão apresentadas até o momento, a estratégia E4 (Figura 4.6) apresenta grande superestimativa nos valores simulados, apresentando, em alguns casos, previsões de produtividade superiores a 90% em relação às produtividades simuladas com os dados meteorológicos observados (controle).

Também houve um forte achatamento da variabilidade e da amplitude devido ao uso de grande número de dados meteorológicos médios para a previsão.

Figura 4.6. Variabilidade e comparação de médias da estratégia 4 (E4), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades de Muitos Capões, RS (a); Piracicaba, SP (b); Catalão, GO (c); Primavera do Leste, MT (d); São Desidério, BA (e) e São Raimundo das Mangabeiras, MA (f)

Com desempenho ainda mais inferior para previsão da produtividade da cultura do milho, a estratégia E5 (Figura 4.7) foi a que apresentou as menores variabilidades e

amplitudes nos dados simulados, as maiores diferenças de médias e as maiores superestimativas. Por utilizar 85 dias do ciclo da cultura com dados meteorológicos médios (60% dos dados meteorológicos do ciclo), essa estratégia teve dificuldade em prever a produtividade do milho nos locais avaliados, devido à grande variabilidade climática interanual, característica de regiões tropicais. Ainda assim, E5 apresentou desempenho razoável na previsão das produtividades de milho simuladas ao final da janela de cultivo da safrinha, especialmente em março e abril, tanto para as médias quanto para variabilidade e amplitude, nas localidades de Catalão, Primavera do Leste, São Desiderio e São Raimundo das Mangabeiras.

Figura 4.7. Variabilidade e comparação de médias da estratégia 5 (E5), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades de Muitos Capões, RS (a); Piracicaba, SP (b); Catalão, GO (c); Primavera do Leste, MT (d); São Desiderio, BA (e) e São Raimundo das Mangabeiras, MA (f)

Figura 4.7. Variabilidade e comparação de médias da estratégia 5 (E5), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades de Muitos Capões, RS (a); Piracicaba, SP (b); Catalão, GO (c); Primavera do Leste, MT (d); São Desiderio, BA (e) e São Raimundo das Mangabeiras, MA (f)

Com o intuito de melhor avaliar os desempenhos apresentados pelas diferentes estratégias de previsão da produtividade do milho (Figuras 4.3 a 4.7), assim como o desempenho das estratégias nas diferentes épocas de semeadura, são apresentadas as análises estatísticas de cada uma delas nas Tabelas 4.3 a 4.6.

Tabela 4.3. Desempenho das diferentes estratégias de previsão da produtividade da cultura do milho para as semeaduras no início da safra (Setembro/Outubro), considerando-se seis localidades brasileiras

Estratégias	**EM	**EAM	**REMQ	**R²	**d	**C
	kg ha ⁻¹					
*E1	66,29	304,78	771,49	0,92	0,98	0,94
*E2	491,65	678,71	1020,15	0,89	0,96	0,91
*E3	1404,42	1542,47	1953,18	0,76	0,87	0,75
*E4	2374,40	2487,13	2991,63	0,62	0,73	0,58
*E5	3063,00	3172,64	3723,25	0,56	0,65	0,49

*Estratégias: E1 – estratégia de previsão 1; E2 – estratégia de previsão 2; E3 – estratégia de previsão 3; E4 – estratégia de previsão 4; E5 – estratégia de previsão 5.

** Índices de desempenho: EM – erro médio; EAM – erro absoluto médio; REMQ – raiz do erro médio quadrado; R² - coeficiente de determinação; d – índice de concordância; C – índice de confiança.

Tabela 4.4. Desempenho das diferentes de previsão da produtividade da cultura do milho para as semeaduras no final da safra (Novembro/Dezembro), considerando-se seis localidades brasileiras

Estratégias	**EM	**EAM	**REMQ	**R²	**d	**C
	kg ha ⁻¹					
*E1	106,16	367,65	902,37	0,89	0,97	0,91
*E2	900,02	1106,31	1448,67	0,83	0,92	0,84
*E3	2349,52	2445,73	2893,89	0,62	0,76	0,60
*E4	3657,08	3785,25	4244,67	0,43	0,63	0,42
*E5	4422,41	4562,00	5272,76	0,33	0,56	0,32

*Estratégias: E1 – estratégia de previsão 1; E2 – estratégia de previsão 2; E3 – estratégia de previsão 3; E4 – estratégia de previsão 4; E5 – estratégia de previsão 5.

** Índices de desempenho: EM – erro médio; EAM – erro absoluto médio; REMQ – raiz do erro médio quadrado; R² - coeficiente de determinação; d – índice de concordância; C – índice de confiança.

Tabela 4.5. Desempenho das diferentes estratégias de previsão da produtividade da cultura do milho para as semeaduras no início da safrinha (Janeiro/Fevereiro), considerando-se seis localidades brasileiras

Estratégias	**EM	**EAM	**REMQ	**R²	**d	**C
	kg ha ⁻¹					
*E1	153,16	464,07	1145,29	0,87	0,95	0,88
*E2	974,67	1219,21	1699,47	0,80	0,90	0,81
*E3	2618,37	2789,17	3429,12	0,55	0,71	0,53
*E4	4127,61	4262,02	4890,89	0,36	0,58	0,35
*E5	5038,21	5124,34	5770,82	0,26	0,52	0,27

*Estratégias: E1 – estratégia de previsão 1; E2 – estratégia de previsão 2; E3 – estratégia de previsão 3; E4 – estratégia de previsão 4; E5 – estratégia de previsão 5.

** Índices de desempenho: EM – erro médio; EAM – erro absoluto médio; REMQ – raiz do erro médio quadrado; R² - coeficiente de determinação; d – índice de concordância; C – índice de confiança.

Tabela 4.6. Desempenho das diferentes de previsão da produtividade da cultura do milho para as semeaduras no final da safrinha (Março/Abril), considerando-se seis localidades brasileiras

Estratégias	**EM	**EAM	**RQEM	**R²	**d	**C
	kg ha ⁻¹					
*E1	53,61	157,23	306,58	0,99	1,00	0,99
*E2	276,36	379,63	533,12	0,97	0,99	0,97
*E3	813,56	934,38	1296,34	0,90	0,94	0,89
*E4	1360,78	1545,58	2124,59	0,81	0,86	0,77
*E5	2027,10	2144,21	2661,33	0,74	0,79	0,68

*Estratégias: E1 – estratégia de previsão 1; E2 – estratégia de previsão 2; E3 – estratégia de previsão 3; E4 – estratégia de previsão 4; E5 – estratégia de previsão 5.

** Índices de desempenho: EM – erro médio; EAM – erro absoluto médio; REMQ – raiz do erro médio quadrado; R² - coeficiente de determinação; d – índice de concordância; C – índice de confiança.

Com base nas análises apresentadas, confirma-se uma superioridade no desempenho das estratégias que utilizaram menos dados climáticos médios nas simulações, sendo que, para qualquer época de semeadura, a estratégia E1 foi superior enquanto que a estratégia E5 foi a que obteve o pior desempenho. Entretanto, foi observado desempenhos superiores de todas as estratégias de previsão nas semeaduras da safrinha realizadas nos meses de março e abril (Tabela 4.6), seguidas das semeaduras realizadas no início da safra, entre setembro e outubro (Tabela 4.3), o que pode estar relacionado aos períodos do ano onde a variabilidade climática é menor ao longo do ciclo da cultura do milho.

Todas as estratégias testadas mostraram tendências de superestimativa dos valores simulados, apresentando erros médios entre 53 kg ha^{-1} (E1 aplicada nas semeaduras de março e abril) e 5038 kg ha^{-1} (E5 aplicada nas semeaduras de janeiro e fevereiro). A RQEM também teve uma grande amplitude de variação, apresentando ótimo desempenho na estratégia E1 ao final do cultivo do milho safrinha ($306,58 \text{ kg ha}^{-1}$) e também valores elevados de erro quando se aplicou a estratégia E5 no início da janela de cultivo do milho safrinha ($5770,82 \text{ kg ha}^{-1}$). O índice C, que combina precisão (r) e acurácia (d), apresentou os melhores valores quando as estratégias de previsão foram avaliadas ao final da janela de semeadura da safrinha, variando entre 0,68 (E5) e 0,99 (E1).

Considerando-se a classificação de desempenho do índice C para a escolha da melhor estratégia de previsão de produtividade da cultura do milho com dados médios, chega-se à seguinte definição: E1 = ótima em todas as épocas de semeadura; E2 = ótima para semeaduras de início da safra e final da safrinha, e como muito boa para as demais datas de semeadura; E3 = ótima para semeaduras ao final da janela de cultivo do milho safrinha e como mediana ou boa para as demais datas; E4 = muito bom apenas para as previsões do final da janela de cultivo da safrinha; E5 = bom apenas para o período final da janela de cultivo do milho safrinha, não sendo uma estratégia recomendada para prever produtividades da cultura do milho quando semeada em outras épocas do ano.

Os resultados apresentados neste estudo mostram que quanto menor o tempo entre a previsão e data da colheita, melhor o desempenho na determinação da produtividade, o que também foi observado por Chipanshiet et al. (1997). Da mesma forma, quanto melhor o sistema de geração de dados meteorológicos ou de imagens utilizados na previsão, melhor será a qualidade dessa previsão. Soler (2004), utilizando dados climatológicos combinados aos dados climáticos dos anos de suas simulações, aponta que a

produtividade do milho pode ser estimada com precisão com até 45 dias antes da data de colheita, com erros médios variando entre 296 e 821 kg ha⁻¹, sendo que o desempenho da previsão aumenta conforme diminuem os dias restantes para a colheita. Martins (2017), utilizando o modelo ETA de previsão climática combinado com dados climáticos dos anos de suas simulações, sugere que a previsão da produtividade do milho pode ser feita com resultados satisfatórios entre 45 e 60 dias antes da colheita. Bannayan et al. (2003), combinando dados meteorológicos diários com dados futuros do gerador de dados meteorológicos SIMMETEO acoplado à plataforma DSSAT para prever a produtividade do trigo, mostraram que, quanto mais tardias eram as simulações de produtividade, menores foram os erros encontrados, apontando valores de REMQ superiores a 950 kg ha⁻¹ para simulações feitas com 132 dias após a semeadura e inferiores a 700 kg ha⁻¹ para simulações de previsão de safra feitas com 244 dias após a semeadura.

A utilização de dados médios, apesar de não possibilitar um horizonte longo e seguro para a previsão da produtividade do milho, é uma alternativa prática, fácil e que pode ser aplicada em larga escala, possibilitando, para semeaduras em algumas épocas do ano, previsões satisfatórias da produtividade de milho com até 45 dias de antecedência à colheita. Sem grande robustez e complexidade, esse sistema é capaz de prever satisfatoriamente e para qualquer época de semeadura a produtividade do milho com 25 dias de antecedência, possibilitando o auxílio à tomada de decisão num momento crítico da colheita e comercialização do milho.

4.4. Conclusões

Os resultados obtidos nas duas etapas deste estudo permitiram concluir que:

- a) As datas de semeadura do milho de maior produtividade atingível e menor risco climático observado para o período de safra foram àquelas apontadas nos meses de outubro e novembro. Para a safrinha, a janela praticada posiciona o milho num momento onde os patamares de produtividade são menores, sendo interessante antecipar a semeadura do milho safrinha para janeiro até o início de fevereiro, a fim de buscar produtividades mais elevadas. A única exceção ocorreu na localidade do Sergipe, onde as semeaduras da safra devem se concentrar entre março e maio;

- b) As estratégias de previsão da produtividade da cultura do milho indicaram que quanto menor o número de dias restante entre o momento da previsão e a data de colheita, melhor será o desempenho da previsão. As estratégias de previsão tiveram melhor desempenho em prever a produtividade da cultura do milho semeado no início da janela de cultivo da safra (setembro e outubro) e no final da janela de cultivo da safrinha (março e abril), sugerindo uma menor variabilidade climática durante os períodos finais das semeaduras realizadas nesses meses e
- c) Considerando que a melhor ferramenta de previsão de produtividade é aquela que oferece os menores erros com o máximo de antecedência na previsão e pode ser aplicada a qualquer época do ano, a estratégia E2 é a que mais se encaixa nesse perfil, permitindo prever a produtividade da cultura do milho com 25 dias de antecedência de forma satisfatória e para qualquer época de semeadura. Dependendo da época de semeadura e do local considerado, essa antecedência poderá ser ainda maior.

REFERÊNCIAS

- ALLEN, R.G., PEREIRA, L.S., RAES, D., SMITH, D.M. Crop evapotranspiration: guidelines for computing crop water requirements. **FAO: Irrigation and Drainage Paper**, 56, Roma, p. 297, 1997.
- ANDARZIAN, B., HOOGENBOOM, G., BANNAYAN, M., SHIRALI, M., ANDARZIAN, B. Determining optimum sowing date of wheat using CSM-CERES-Wheat model. **Journal of Saudi Society of Agricultural Sciences**, Riade, v.14, p. 189-199, 2015.
- ANDRIOLI, K.G., SENTELHAS, P.C. Brazilian maize genotypes sensitivity to water deficit estimated through a simple crop yield model. **Pesquisa Agropecuaria Brasileira**, Brasília, v.44, p. 653-660, 2009.
- ASSENS, S.; EWERT, F.; ROSENZWEIG, C. J. W.; HATFIELD, J. L.; RUANE, A. C.; BOOTLE, K. J.; THORBURN, P.J.; ROTTER, R.P.; CAMMARANO, D.; BRISSON, N.; BASSO, B.; MATRE, P.; AGGARWAL, P. K.; ANGULO, C.; BERTUZZI, P.; BIERNATH, C.; CHALLINOR, A. J.; DOLTRA, J.; GAYLER, S.; GOLDBERG, R.; GRANT, R.; HEING, L.; HOOKER, J.; HUNT, L. A.; INGWERSEN, J.; IZAURRALDE, R. C.; KERSEBAUM, K. C.; MULLER, C.; NARESH KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. A.; OSBORNE, T. M.; PALOSUO, T.; STOCKLE, C.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; TRAVASSO, M.; WAHA, K.; WALLACH, D.; WHITE, J. W.; WILLIAMS, J. R.; WOLF, J. Uncertainty in simulation wheat yields under climate change. **Nature Climate Change**, London, v.3, p. 827-832, 2013.
- BANNAYAN, M., CROUT, N.M.J., HOOGENBOOM, G. Application of the Ceres-Wheat model for within-season prediction of winter wheat yield in the United Kingdom. **Agronomy Journal**, Madison, v.95, p. 114-125, 2003.
- BANNAYAN, M., REZAEI, E.E., HOOGENBOOM, G. Determining optimum planting dates for rainfed wheat using the precipitation uncertainty model and adjusted crop evapotranspiration. **Agricultural Water Management**, Amsterdam, v.126, p. 56-63, 2013.
- BATTISTTI, R., SENTELHAS, P.C. Drought tolerance of Brazilian soybean cultivars simulated by a simple agrometeorological yield model. **Experimental Agriculture**, Cambridge, v.51, p. 285-298, 2014.
- BATTISTI, R., SENTELHAS, P.C., KENNETH, J.B. Inter-comparison of performance of soybean crop simulation models and their ensemble in southern Brazil. **Field Crops Research**, Amsterdam, v.200, p. 28-37, 2017.

- BRASIL. **Ministério da Agricultura, Pecuária e Abastecimento**. Secretaria de Política Agrícola do MAPA. Disponível em: <http://www.agricultura.gov.br/assuntos/riscos-seguro/risco-agropecuário/zoneamento-agrícola>.
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes modelos de estimativa de evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.5, n.1, p.89-97, 1997.
- CANTELE, E.F. Desempenho da cultura do milho em diferentes épocas de cultivo no sudoeste paulista. **Tese de Mestrado, Escola Superior de Agricultura 'Luiz de Queiroz'**, Piracicaba, 2009.
- CHALLINOR, A.J., PARKES, B., VILLEGAS, J.R. Crop yield response to climate change varies with cropping intensity. **Global Change Biology**, Oxford, v.21, p. 1679-1688, 2015.
- CHIPANSHI, A.C., RIPLEY, E.A., LAWFORD, R.G. Early prediction of spring wheat yields in Saskatchewan from current and historical weather data using the CERES-Wheat model. **Agricultural and Forest Meteorology**, Amsterdam, v.84, p. 223-232, 1997.
- CHISANGA, C.B., PHIRI, E., SHEPAND, C., SICHINGABULA, H. Evaluating CERES-Maize model using planting dates and nitrogen fertilizer in Zambia. **Journal of Agricultural Science**, Cambridge, v.7, p. 79-97, 2015.
- COSTA, L.G., MARIN, F.R., NASSIF, D.S.P, PINTO, H.M.S., LOPES-ASSAD, M.L.R.C Simulação do efeito do manejo da palha e do nitrogênio na produtividade da cana-de-açúcar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, p. 469-474, 2014.
- DIAS, H. B. Intercomparação de modelos de simulação da cana-de-açúcar e seu uso na avaliação da quebra de produtividade e dos impactos da irrigação em diferentes regiões do Brasil. **Tese apresentada para obtenção do título de Mestre em Engenharia de Sistemas Agrícolas**, Piracicaba, 2016.
- DOORENBOS, J., KASSAM, A. H. Yield response to water. **FAO: Irrigation and drainage paper**, 33, Roma, p.193, 1979.
- FARIA, R.A., SOARES, A.A., SEDIYAMAG.C., RIBEIRO, C.A.A.S. Demanda de irrigação suplementar para a cultura do milho no estado de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.4, p. 46-50, 2000.
- FLESCHE, R.D., MASSIGNAM, A.M. Épocas de semeadura do milho para as regiões de Chapecó e Campos Novos. **Agropecuária Catarinense**, Santa Catarina, v.13, p. 43-47, 2000.

- GARCIA, R.G., DALLACORT, R. Calendário agrícola para a cultura do milho em Sinop (MT). **Pesquisa Agropecuaria Tropical**, Goiânia, v.43, p. 128-222, 2013.
- GOUVÊA, J.R.F., SENTELHAS, P.C., GAZZOLA, S.T., SANTOS, M.C. Climate changes and technological advances: impacts on sugarcane productivity in tropical southern Brazil. **Scientia Agricola**, Piracicaba, v.66, p. 593-605, 2009.
- LOBELL, D.B., BURKE, M.B. on the use of statistical models to predict crop yield responses to climate change. **Agricultural and Forest Meteorology**, Amsterdam, v.150, p. 1443-1452, 2010.
- MAGAIA, E., FAMBA, S., WESSTROM, I., BRITO, R., JOEL, A. Modelling maize yield response to plant density and water and nitrogen supply in semi-arid region. **Field Crops Research**, Amsterdam, v.205, p. 170-181, 2017.
- MARIN, F. R. Eficiência da produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos. **Tese de livre-docência**, Piracicaba, 2014.
- MARTINS, M.A. Estimativa da produtividade da cultura do milho no semiárido brasileiro, com base no modelo AquCrop e previsão climática sazonal. **Tese de doutorado, INPE – Instituto Nacional de Pesquisas Espaciais**, São José dos Campos, 2017.
- MARTRE, P.; WALLACH, D.; ASSENG, S.; EWERT, F.; JONES, J. W.; ROTTER, R. P.; BOOTE, K. J.; RUANE, A. C.; THORBURNE, P. J.; CAMMARANO, D.; HATFIELD, J. L.; ROSENZWEIG, C.; AGGARWAL, P. K.; ÂNGULO, C.; BASSO, B.; BERTUZZI, P.; BIERNATH, C.; BRISSON, N.; CHALLINOR, A. J.; DOLTRA, J.; GAYLER, S.; GOLDBERG, R.; GRANT, R. F.; HENG, L.; HOOKER, J.; HUNT, L. A.; INGWERSEN, J.; IZAURRALDE, R. C.; KERSEBAUM, K. C.; MULLER, C.; KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. A.; OSBORNE, T.; PALOSUO, T.; PRIESACK, E.; RIPOCHE, D.; SEMENOV, M. A.; SHCHERBAK, I.; STEDUTO, P.; STOCKLE, C. O.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; TRAVASSO, M.; WAHA, K.; WHITE, J. W.; WOLF, J. Multimodel ensembles of wheat growth: many models are better than one. **Global Change Biology**, Oxford, v.21, p. 911-925, 2014.
- MONTEIRO, L. A.; SENTELHAS, P. C. Sugarcane yield gap: can it be determined at nacional level with a simple agrometeorological model?. **Crop & Pasture Science**, Melbourne, v.68, p. 272-284, 2017.
- NIED, A.H., HELDWEIN, A.B., ESTEFANEL, V., SILVA, J.C., ALBERTO, C.M. Épocas de semeadura do milho com menor risco de ocorrência de deficiência hídrica no município de Santa Maria, RS, Brasil. **Ciencia Rural**, Santa Maria, v.35, p. 995-1002, 2005.

- NOURI, M., HOMAEI, M., BANNAYAN, M., HOOGENBOOM, G. towards shifting planting dates as an adaptation practice for rainfed wheat response to climate change. **Agricultural Water Management**, Amsterdam, v.186, p. 108-119, 2017.
- NYAGUMBO, I., MKUHLANI, S., MUPANGWA, W., RODRIGUEZ, D. Planting date and yield benefits from conservation agricultural practices across southern Africa. **Agricultural Systems**, Amsterdam, v.150, p. 21-33, 2017.
- PALOSUO, T.; KERSEBAUM, K. C.; ANGULO, C.; HILAVINKA, P.; MORIONDO, M.; OLESEN, J. E.; PATIL, R. H.; RUGET, F.; RUMBAUR, C.; TAKÁČ, J.; TRNKA, M.; BINDI, M.; CALDAG, C.; EWERT, F.; FERRISE, R.; MIRSCHEL, W.; SAYLAN, L.; SISKI, B.; ROTTER, R. Simulation of winter wheat yield and its variability in different climates of Europe: a comparison, of eight crop growth models. **European Journal Agronomy**, Amsterdam, v.35, p. 103-114, 2011.
- PRIESTLEY, C.H.B., TAYLOR, R.J. On the assessment of surface heat flux and evapotranspiration, using large scale parameters. **Monthly Weather Review**, New York, v.100, p. 81-92, 1972.
- RITCHIE, J.T. Model for predicting evaporation from a row crop with incomplete cover. **Water resources research**, Colorado, v.8, p. 1204-1213, 1972.
- SACKS, W.J., DERYNG, D., FOLEY, J.A., RAMANKUTTY, N. Crop planting dates: an analysis of global patterns. **Global Ecology and Biogeography**, Maine, v.19, p. 607-620, 2010.
- SAEED, U.; DEMPEWOLF, J.; RESHEF, I.B.; KHAN, A.; AHMAD, A.; WAJID, S.A. forecasting wheat yield from weather data and MODIS NDVI using random forests from Punjab province, Pakistan. **International Journal of Remote Sensing**, Basel, v. 38, p.4831-4854, 2017.
- SANTOS, D.L., SENTELHAS, P.C. Climate change Scenarios and their impact on water balance and sugarcane yield in southern Brazil. **Sugar Tech**, Stanford, v.16, p. 356-365, 2014.
- SENTELHAS, P. C.; BATTISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A. C.; NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **Journal of Agriculture and Science**, Cambridge, v.158, p. 1394-1411, 2015.
- SHRESTHA, S., CHAPAGAIN, R., BABEL, M.S. Quantifying the impact of climate change on crop yield and water footprint on rice in the Nam Oon irrigation project, Thailand. **Science of the Total Environment**, Amsterdam, v.599-600, p. 689-699, 2017.

- SKOCAJ, D.M., HURNEY, A.P., INMAN-BAMBER, N.G., SCHROEDER, B.L., EVERINGHAM, Y.L. Modelling sugarcane yield response to applied nitrogen fertiliser in a wet tropical environment. **Australian Society of Sugarcane Technologists**, Mackay, v.35, p. 1-9, 2013.
- SON, N.T.; CHEN, C.F.; CHEN, C.R.; MINH, V.Q.; TRUNG, N.H. A comparative analyses of multitemporal MODIS EVI and NDVI data for large-scale rice yield estimation. **Agricultural and Forest Meteorology**, Amsterdam, v. 197, p.52-64, 2014.
- SONG, R.; CHENG, T.; YAO, X.; TIAN, Y.; ZHU, Y.; CAO, W. Evaluation of Landsat 8 time series image stack for predicting yield and yield components of winter wheat. International Geoscience and Remote Sensing Symposium, Pequim, p. 6300-6303, 2016.
- SOLER, C. M. T., Uso do Modelo Ceres-Maize para Previsão de Safra do Milho “Safrinha”. **Tese apresentada para obtenção do título de Doutor em agronomia**, Piracicaba: ESALQ-USP, 2004.
- THORNTON, C.W., MATHER, J.R. The wahter balance. **Drexel Institute of Technology**, Philadelphia, p.104, 1955.
- TOMMASELLI, J.T.G., VILLA NOVA, N.G. Épocas de plantio de milho em função das deficiências hídricas no solo em Cambará-PR. **Pesquisa Agropecuaria Brasileira**, Brasília, v.30, p. 505-514, 1995.
- WANG, E., CHEN, C., YU, Q. Modeling the response of wheat and maize productivity to climate variability and irrigation in north China plain. 18th **World IMACS/MODSIM Congress**, Cairns, 2009.
- WILLMOTT, C. J. On the validation of models. **Physical Geography**, Norwich, v.2, p.184-194, 1981.
- XAVIER, A. C., KING, C. W., SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, Austin, 2015.
- ZHANG, L.; WALKER, G. R.; DAWES, W.R. Water balance modeling: concepts and applications. In: MECVICAR, T. R.; RUI, L; WALKER, J; FITZPATRICK, R. W.; CHANGMING, L. Regional water and soil assessment for managing suitable agriculture in China and Australia. **CISRO**, Adelaide, p. 31-47, 2002.

5. PRODUTIVIDADE E *YIELD GAP* DA CULTURA DO MILHO DA SAFRA E DA SAFRINHA NO BRASIL

Resumo

Sendo o cereal mais plantado no mundo e de grande importância econômica e estratégica para o Brasil, o milho vem cada vez mais ganhando espaço nas lavouras brasileiras, principalmente no cultivo de segunda safra (safrinha). Apesar dessa importância, da grande área plantada e da elevada quantidade de grãos produzidos, as produtividades do milho no Brasil ainda são baixas, da ordem de 5000 kg ha⁻¹ para o período de safra e de 4000 kg ha⁻¹ para a safrinha, enquanto que seu potencial produtivo genético supera os 30000 kg ha⁻¹. O presente estudo teve por objetivo determinar não apenas as produtividades potenciais, atingíveis e reais do milho no Brasil, mas também determinar suas quebras de produtividade (*yield gap* = YG) ocasionadas pelos déficits hídrico e de manejo agrícola. Os resultados obtidos demonstraram que o déficit hídrico é responsável por 53% de quabra em relação à produtividade potencial, enquanto que as perdas de produtividade causadas por déficits de manejo correspondem a mais de 52% das quebras em relação à produtividade atingível.

Palavras-chave: Milho; *Yield gap*; Déficit hídrico; Manejo; Modelos de simulação de cultura

Abstract

As the most cultivated cereal in the world and of great economic and strategic importance for Brazil, maize crop has increasing expressively in Brazilian, especially as the second crop (*safrinha*). In spite of this importance and also of the large planted area and production, the levels of Brazilian maize yield are still low, reaching 5000 kg ha⁻¹ for the main season and 4000 kg ha⁻¹ for safrinha, too far of its genetic potential which can exceeds 30000 kg ha⁻¹. This study study aimed to identify not only the potential, attainable and actual maize yields in Brazil but also to calculate yield gaps caused by the water and crop management deficits. The results showed that water deficit is responsible for 53% of yield gap in relation to potential yield, whereas yield losses caused by sub-optimum crop management accounted for more than 52% in relation potential yield.

Keywords: Maize; Yeld gap; Water deficit; Managemant; Crop simulation models

5.1. Introdução

O milho é o cereal mais produzido no mundo, ultrapassando as 960 milhões de toneladas produzidas na safra 2016/2017 (USDA, 2017). Em 2016, o Brasil produziu mais de 64 milhões de toneladas de milho, sendo que mais de 60% dessa produção foi proveniente de áreas de milho safrinha (IBGE, 2017). Para o período de safra no Brasil, nesse mesmo ano, as regiões que mais contribuíram com a produção nacional de milho foram as do Sul e do Sudeste, com mais de 10 e 7 milhões de toneladas, respectivamente, enquanto que, para a safrinha, a região Centro-Oeste foi a mais significativa, contribuindo com mais de 25 milhões de toneladas de grãos de milho (IBGE, 2017).

Apesar das elevadas produções, os níveis de produtividade alcançados nas lavouras brasileiras ainda são considerados baixos. Segundo levantamento do Instituto Brasileiro de Geografia e Estatística (IBGE, 2017), a produtividade brasileira média de milho é de apenas 5000 kg ha⁻¹ para a safra e de 4000 kg ha⁻¹ para a safrinha, valores muito aquém da produtividade potencial do milho, que, segundo Yamada (1997), pode chegar a mais de 31.000 kg ha⁻¹. O aumento da produtividade é, atualmente, o maior desafio dos produtores brasileiros, já que os mesmos enfrentam restrições de diferentes naturezas, quer seja ambiental, econômica ou tecnológica, para incrementar sua produção frente a uma demanda cada vez maior pelos grãos de milho, fontes de alimento, fibras e biocombustível (Hertel et al., 2010; Stacciarini et al., 2010; Grassini et al., 2011).

Para atingir maiores produtividade é preciso se entender melhor quais são os fatores que estão limitando a produção agrícola do local, ou seja, se estão mais relacionados às perdas por efeitos climáticos ou por deficiências no manejo agrícola. A fim de melhor entender e quantificar o impacto dos efeitos do clima e do manejo agrícola nas produtividades agrícolas, as produtividades podem ser classificadas de acordo com o tipo e os fatores de influência, os quais podem ser ordem climática, de manejo da água (para culturas irrigadas) ou de manejo agrícola, como ilustra a Figura 5.1. A produtividade mais elevada é denominada de produtividade potencial (PP), a qual sofre influência de

características ambientais, como radiação solar, temperatura do ar e fotoperíodo, associadas ao tipo de cultura, genótipo e população de plantas adotada. A PP é um valor teórico e representa o máximo que uma cultura/genótipo bem adaptada ao ambiente poderia produzir por hectare sem que houvesse penalizações desta decorrente do déficit hídrico, déficit nutricional e ataque de pragas, doenças ou plantas daninhas (Pereira et al., 2002). No caso de uma cultura de sequeiro, a produtividade potencial é penalizada apenas pela ocorrência do déficit hídrico, resultando na produtividade atingível (PA), expressa o máximo que poderia ser produzido por hectare em uma cultura de sequeiro. A partir desses dois tipos de produtividade, ainda podem ser derivados outros tipos que irão depender do nível tecnológico empregado, tanto em termos do manejo de irrigação como do manejo agrícola, que juntos para as culturas irrigadas, ou apenas o último para as culturas de sequeiro, irão definir a produtividade real (Lobell et al., 2009; Battisti et al., 2012; van Ittersum et al., 2013; Sentelhas et al., 2015).

Figura 5.1. Tipos de produtividade e seus fatores de influência. Adaptado de: Lobell et al. (2009); van Ittersum et al. (2013) e Sentelhas et al. (2015).

Os diferentes tipos/níveis de produtividade apresentados na Figura 1, quando comparados, permitem se identificar diferentes tipos de quebra de produtividade, os quais podem ser predominantemente causados pelas condições meteorológicas ao longo do ciclo,

pelo manejo (de irrigação e/ou agrícola) ou por ambos. Mundialmente, essas quebras de produtividade agrícola são denominadas de *Yield Gap* (YG). A determinação do YG em regiões tropicais é um grande desafio, dada a grande variabilidade climática interanual que ocorre nessas áreas, principalmente no que diz respeito à distribuição das chuvas e sua variação espacial (Affholder et al., 2013). Apesar da complexidade de sua determinação, o conceito de YG pode ser aplicado em qualquer cultura e local, desde que se tenha uma boa base de dados meteorológicos, assim como ampla disponibilidade de dados agrônômicos para comparação.

Segundo Affholder et al. (2013), a determinação do YG deve obedecer às seguintes etapas: empregar modelo de simulação bem calibrado e adaptado às condições locais; utilizar dados meteorológicos medidos; fazer as simulações de acordo com o solo e sistema de cultivo predominante na região; empregar informações agrônômicas e de produtividade do local de interesse; comparar o YG local ao YG obtido dados de experimentos; extrapolar os resultados para escalas maiores por meio do uso de sistemas de informações geográficas. Modelos de simulação de culturas, quando bem calibrados, são ferramentas úteis para a determinação das produtividades potencial e atingível de uma dada localidade. Os níveis de complexidade dos modelos de simulação variam conforme o número de processos simulados, o número de parâmetros a serem ajustados pelo usuário e a quantidade de dados de entrada. A maior complexidade dos modelos nem sempre implica em melhor desempenho ou um que os modelos mais complexos estejam livres de erros (Zhang et al. 2002; Sentelhas et al., 2015; Monteiro e Sentelhas, 2017). Sendo assim, os melhores modelos serão aqueles capazes de simular as produtividades de forma precisa e acurada sob as mais diferentes condições de clima e solo.

A fim de minimizar ainda mais os erros dos modelos de simulação da produtividade agrícola, uma abordagem que vem ganhando se consolidado é a do uso da combinação de diferentes modelos (*ensemble*) para a obtenção das estimativas de produtividade com melhor precisão e acurácia, minimizando as incertezas associadas aos modelos (Palosuo et al., 2011, Asseng et al., 2013, Battisti et al., 2017). Tal abordagem, apesar de já ser usada há muito tempo, foi estimulada mais recentemente pelo AGMIP (*Agricultural Model Intercomparison and Improvement Project*) para ser empregada em estudos sobre os impactos das mudanças climáticas na produção agrícola em escalas regional e global (Rosenzweig et al., 2013; Rosenzweig et al., 2016 e Wallach et al., 2016). Com base nessa

abordagem multi-modelos, vários estudos vêm demonstrando a melhoria do desempenho das estimativas de produtividade com o uso de *ensembles* para diferentes culturas, dentre elas a da cana-de-açúcar (Marin, 2014; Dias, 2016), do trigo (Asseng et al., 2013; Martre et al., 2014) e da soja (Battisti et al, 2017).

A análise pontual das produtividades (PP e PA), assim como a determinação dos diferentes tipos de YG, não permite uma visualização da variabilidade especial e temporal dessas variáveis, dificultando a identificação de regiões com elevados potenciais produtivos e/ou com grandes quebras de produtividade. Para solucionar isso, a integração das técnicas de simulação das produtividades com a de mapeamento e interpolação de dados, por meio de sistemas de informação geográfica (SIG), vem ganhando cada vez mais espaço na agricultura, ajudando a definir estratégias de mitigação dos impactos do clima na produção agrícola.

Nesse sentido, a hipótese do presente estudo é de que a integração de um modelo de simulação da cultura do milho com um SIG é uma poderosa ferramenta de gestão agrícola, permitindo definição e o mapeamento das produtividades potencial (PP), atingível (PA) e real (PR), assim como das quebras de produtividade (YG) decorrentes do déficit hídrico e do déficit de manejo agrícola. Sendo assim, os objetivos deste estudo foram estimar as produtividades potencial e atingível da cultura do milho na safra e na safrinha e compará-las às produtividades reais da cultura provenientes do IBGE, de modo a determinar as quebras de produtividade associadas à deficiência hídrica ao longo dos ciclos do milho e à deficiência de manejo da cultura, para as diferentes regiões brasileiras, de modo a identificar ações para diminuir tais quebras (*yield gap*) e incrementar a produtividade real da cultura do milho nessas duas safras.

5.2. Material e métodos

5.2.1. Locais Estudados

O presente estudo contou com informações de 152 localidades distribuídas por todo o Brasil, buscando-se uma boa distribuição espacial dos principais polos produtores de milho no Brasil (Figura 5.2).

Figura 5.2. Localidades brasileiras para as quais foram simuladas as produtividades potencial (PP), atingível (PA) e determinados os *yield gaps* (YG) para a cultura do milho

5.2.2. Dados Meteorológicos

Os dados meteorológicos empregados neste estudo foram consistidos a partir das seguintes bases de dados: Instituto Nacional de Meteorologia (INMET); Agência Nacional de Águas (ANA); e *DailyGridded* (Xavier et al., 2015). Foi dada prioridade ao uso dos dados meteorológicos provenientes do INMET, seguido pelo banco de dados da ANA (apenas chuva) e, por fim, do sistema *DailyGridded* (Xavier et al., 2015). A partir desses bancos foram obtidas séries de dados meteorológicos diários (chuva, radiação solar, temperatura máxima, temperatura mínima, temperatura média, umidade relativa e velocidade do vento), para o período de 1980 a 2013, totalizando 34 anos.

5.2.3. Dados de Solo

Para os dados de solos foram empregados três níveis de textura de solo: solos argilosos; médios e arenosos, os quais foram adotados como referência para a definição da disponibilidade de água no solo. Por não existirem pontos de coleta de dados de solo para o estudo, se fez uso dos perfis de solos brasileiros disponíveis na plataforma DSSAT 4.6 (2015). Esses perfis foram limitados em um metro de profundidade, divididos em camadas de 0 a 10, 11 a 20, 21 a 40, 41 a 60, 61 a 80, e 81 a 100 cm, e agrupados de acordo com a classe textural média ao longo do perfil. A partir desse agrupamento, foram calculadas as médias dos valores de cada característica do solo para cada uma das camadas, formando um perfil médio de solo com texturas argilosa, média e arenosa. A partir desses solos, foram desenvolvidos os perfis de solo de cada um dos modelos utilizados nesse estudo (Anexo A).

5.2.4. Dados de Produtividade Real (PR)

Os dados de produtividade real da cultura do milho, cultivado durante a safra (semeaduras entre setembro e dezembro) a safrinha (semeaduras entre janeiro e abril), foram obtidos junto ao banco de dados do IBGE (2017), para cada uma das 542 microrregiões brasileiras que reportaram dados entre os anos de 2003 e 2016.

Os dados de PR obtidos junto ao IBGE (2017), tanto para safra quanto para safrinha foram tratados e consistidos de forma a se eliminar a tendência tecnológica decorrente do aumento da produtividade ao longo dos anos, empregando-se conforme metodologia apresentada em Heinemann e Sentelhas (2011) e Monteiro (2015). Desse modo, a variabilidade da série de PR passou a considerar somente os efeitos da variabilidade climática.

5.2.5. Estimação das produtividades potencial e atingível para a cultura do milho no Brasil

As produtividades potencial e atingível foram obtidas por meio da combinação ou *ensemble* das saídas dos modelos MZA-FAO, DSSAT Ceres-Maize e APSIM-Maize, os quais foram devidamente calibrados e avaliados para a estimação da PP e da PA do milho safra e do milho safrinha. Um resumo do desempenho desses modelos de seus *ensembles* nas fases de calibração e de avaliação é apresentado na Tabela 5.1. Para a determinação da PP e da PA

foram simuladas 36 semeaduras por ano, uma no início de cada decêndio do mês, para cada localidade apresentada na Figura 5.2 e para cada classe de solo. Para a estimação da PP, o déficit hídrico foi desconsiderado em todas as simulações, de forma que a cultura simulada não sofresse nenhum tipo de estresse durante seu ciclo.

Tabela 5.1. Desempenho dos modelos MZA-FAO (Modelo da Zona Agroecológica – FAO), DSSAT CERES-Maize, APSIM-Maize e de seu *Ensemble* para a estimação da produtividade atingível (PA) do milho

	PA média observada	PA média estimada	EM	EAM	REMQ	d	R ²	C
			kg ha ⁻¹					
MZA-FAO		9344,08	467,24	1239,95	1733,87	0,71	0,28	0,38
CERES-Maize	9320,7 (±2058,05)	10076,02	774,28	1102,76	1653,86	0,71	0,33	0,41
APSIM-Maize		9550,12	229,43	1008,99	1380,12	0,78	0,40	0,49
<i>Ensemble</i> Média		9480,00	336,05	837,97	1088,05	1,00	0,62	0,79

EM = erro médio; EAM = erro absoluto médio; REMQ = raiz do erro médio quadrático; d = coeficiente de concordância; R² = coeficiente de determinação e C = índice de confiança.

5.2.6. Interpolação e mapeamento das produtividades potencial e atingível da cultura do milho no Brasil

A fim de se mapear a PP e a PA da cultura do milho safra e safrinha no Brasil ao longo do ano, foi feita a média decendial dessas produtividades simuladas para cada uma das localidades e para cada tipo de solo considerado, para toda a série histórica avaliada. Essas médias foram agrupadas mensalmente, de forma que, ao final, obteve-se um único valor de PP e de PA para cada mês do ano, em cada local e para cada tipo de solo. Para a interpolação desses dados médios, três diferentes métodos foram testados: o inverso do quadrado da distância (IQD); a krigagem ordinária (KRG) e a regressão linear múltipla (RLM) (McKinion et al., 2010; Viola et al., 2010; Li e Heap, 2011; Souza et al., 2016). Para avaliar o desempenho dos métodos IQD e KRG na espacialização da PP e da PA foi empregada a validação cruzada (Xavier et al., 2015) de modo a comparar os valores observados e os estimados por meio do mapa. Para avaliar o desempenho do método da RLM foi realizada uma validação com pontos independentes. Após a etapa de validação, os métodos foram comparados entre si de acordo com o desempenho dos seguintes erros e indicadores estatísticos: erro médio (EM); erro absoluto médio (EAM); raiz quadrada do erro médio (REMQ); coeficiente de determinação (R²); coeficiente de correlação (d) e o índice C (Camargo e Sentelhas, 1997).

Uma vez determinado o método de melhor desempenho para espacialização, foram gerados os mapas de PP e PA para cada mês do ano, com informações interpoladas numa resolução de 0,18°. Todo o processo de interpolação e geoestatística foi realizado com auxílio da plataforma *ArcGis 10.5.1* (ESRI, 2011).

5.2.7. Determinação e mapeamento dos níveis dos diferentes *Yield Gaps* (YG) para a cultura do milho no Brasil

Das séries consistidas, foram extraídas as PRs médias de cada uma das microrregiões, delimitadas pelo IBGE, as quais foram especializadas na mesma resolução adotada na espacialização da PP e da PA, ou seja, 0,18°. Com o auxílio da plataforma *ArcGis 10.5.1* foram obtidos os mapas de YG, para cada tipo de solo, da seguinte maneira:

1. *Yield Gap* por déficit hídrico (YG_{dh}) – diferença entre os mapas de PP e PA;
2. *Yield Gap* por déficit de manejo para o milho safra (YG_{dm1}) – diferença entre os mapas de PA PR na safra (semeaduras de setembro a dezembro);
3. *Yield Gap* déficit de manejo para o milho safrinha (YG_{dm2}) – diferença entre os mapas de PA e PR na safrinha (semeaduras de janeiro a abril).

5.3. Resultados e discussão

5.3.1. Mapeamento das produtividades potencial (PP), atingível (PA), real (PR) e do *yield gap* (YG) da cultura do milho no Brasil

5.3.1.1. Desempenho dos métodos de interpolação das produtividades potencial e atingível

Todos os métodos de interpolação testados neste estudo apresentaram desempenho satisfatório na espacialização da PP (Tabela 5.2) e da PA (Tabela 5.3) para os diferentes tipos de solos considerados. De acordo com a análise estatística da comparação entre os dados observados e os interpolados, o processo de espacialização resultou em baixos valores de EAM, variando entre 220 e 557 kg ha⁻¹, precisão elevada, com R² variando entre 0,87 e 0,98, e altíssima concordância, com d acima de 0,96, resultando em índices de confiança classificados como ótimo ($C \geq 0,90$), de acordo com a classificação de Camargo e Sentelhas (1997).

Apesar dos desempenhos semelhantes entre os diferentes métodos de interpolação da PP e da PA, o método da krigagem ordinária (KRG) foi o que apresentou os menores erros, quer sejam expressos em termos do EAM ou da RQEM. Resultados semelhantes foram obtidos por Souza et al. (2016) para a interpolação da produtividade real do milho e da soja, porém com os menores erros sendo obtidos pela espacialização realizada pelo método do inverso do quadrado da distância, com EAM variando entre 40 e 320 kg ha⁻¹.

Tabela 5.2. Avaliação estatística dos métodos de interpolação empregados na espacialização da produtividade potencial da cultura do milho no Brasil

Método	EM	EAM	RQEM	R ²	d	C
	kg ha ⁻¹					
IQD	6,40	236,1	326,05	0,92	0,98	0,94
KRG	-3,09	220,89	309,71	0,93	0,98	0,94
RLM	0,00	324,35	419,67	0,87	0,96	0,90

Inverso do quadrado da distância = IQD; Krigagem ordinária = KRG; Regressão linear múltipla = RLM; Erro médio = EM; Erro absoluto médio = EAM; Raiz quadrada do erro médio = RQEM; Coeficiente de determinação = R²; Índice de concordância = d e Índice de confiança (C)

Tabela 5.3. Avaliação estatística dos métodos de interpolação empregados na espacialização da produtividade atingível da cultura do milho no Brasil

Método	EM	EAM	RQEM	R ²	d	C
	kg ha ⁻¹					
IQD	51,14	420,11	644,14	0,95	0,99	0,96
KRG	7,41	362,66	539,58	0,96	0,99	0,97
RLM	-5,90	600,99	785,18	0,92	0,98	0,94

Inverso do quadrado da distância = IQD; Krigagem ordinária = KRG; Regressão linear múltipla = RLM; Erro médio = EM; Erro absoluto médio = EAM; Raiz quadrada do erro médio = RQEM; Coeficiente de determinação = R²; Índice de concordância = d e Índice de confiança (C)

Considerando-se que o método da krigagem ordinária foi o que gerou os menores erros entre os valores observados e interpolados de produtividade do milho, optou-se por adotar este método para a elaboração dos mapas de PP e de PA da cultura do milho safra e safrinha.

5.3.1.2. Produtividades potencial (PP) e atingível (PA) do milho no Brasil

O mapeamento dos níveis de produtividade permite uma identificação prática dos locais com maiores potenciais produtivos, facilita a percepção da variabilidade dessas variáveis tanto no espaço quanto no tempo, mostrando o quanto as condições climáticas são

importantes na definição dos patamares de produtividade do milho. O mapeamento da PP do milho mostrou que o maior valor nacional médio ocorre na semeadura do mês de setembro, correspondendo a 12028 kg ha^{-1} . A região Sul foi a que apresentou a maior PP, para semeaduras em novembro, com 13956 kg ha^{-1} , enquanto que a região Norte apresentou a menor PP para o mesmo mês de semeadura, com 10621 kg ha^{-1} (Figura 5.3). Essa variação da PP ao longo do ano e nas diferentes latitudes acontece principalmente, devido ao fotoperíodo e a disponibilidade de radiação solar, já que na região Sul o fotoperíodo é mais longo e os dias mais ensolarados em relação à região Norte, para o período mencionado, proporcionando às plantas de milho mais horas diárias para o processo de fotossíntese.

As semeaduras realizadas nos meses de fevereiro, março, abril e maio proporcionam as menores PPs em quase todo o país, já que, durante semeaduras realizadas nesses meses a cultura é submetida a temperaturas mais baixas, prejudicando o acúmulo de biomassa e o desenvolvimento da planta. Como o fator hídrico não é limitante para a definição da PP, observa-se essa variando basicamente em função do fotoperíodo e da quantidade de energia disponível ao longo do ciclo da planta de milho. Assim, observa-se uma maior PP nas latitudes mais altas, ao sul do país, onde o fotoperíodo é maior na safra e menor na safrinha, enquanto nas latitudes mais baixas, próximas ao equador, praticamente não há variação do fotoperíodo ao longo do ano. Os estados do Pará e Rio Grande do Sul ilustram essa influência da variação anual do fotoperíodo na PP.

Figura 5.3. Produtividade potencial da cultura do milho no Brasil, estimada por meio da combinação de três modelos de simulação da cultura (MZA-FAO, DSSAT Ceres-Maize e APSIM-Maize), para semeaduras simuladas mensalmente no período de 1980 a 2013

Assim como para a PP, o mapeamento da PA facilita a identificação dos melhores locais e momentos para a semeadura da cultura do milho de sequeiro no Brasil, assim como a percepção da sua variabilidade espacial e temporal. Neste estudo, o mapeamento também permitiu avaliar a influência de diferentes texturas de solo na definição dos patamares médios de PA ao longo do ano. Os valores de PA aumentaram conforme a textura do solo foi modificada de arenosa para argilosa, devido ao aumento na capacidade de água disponível, proporcionado pelo aumento no teor de argila (Figuras 5.4, 5.5 e 5.6). Para todos os tipos de solo, as maiores PAs foram encontradas nas semeaduras de outubro, novembro e dezembro, quando grande parte do desenvolvimento das plantas de milho coincide com períodos chuvosos, minimizando o déficit hídrico, neste caso, a região Centro-Sul foi a que apresentou os maiores patamares de PA (Figuras 5.4, 5.5 e 5.6).

Ao se analisar um solo de textura mais arenosa, vemos uma menor flexibilidade na janela de semeadura tanto durante a safra como na safrinha, além de menores valores de PA. O mês de semeadura em que se observa a maior média nacional é o mês de dezembro, apresentando 7359 kg ha^{-1} , enquanto que, durante o mesmo mês, a região Sul apresentou a maior PA, 8530 kg ha^{-1} . Essa menor flexibilidade nas datas favoráveis de semeadura e os menores níveis de PA estão relacionados ao fato das plantas de milho sofrerem mais com o déficit hídrico em solos arenosos, onde a capacidade de água disponível é menor, levando ao secamento mais rápido do solo em períodos sem chuva, acarretando em perdas de produtividade decorrentes de veranicos e secas prolongadas. Mesmo mostrando altos potenciais produtivos em casos de anos com chuvas bem distribuídas, o risco de perdas é mais elevado, o que acaba por diminuir os patamares da PA para a cultura do milho em solos arenosos (Figura 5.4).

Em solos classificados como sendo de textura média, nota-se uma maior flexibilidade na janela de semeadura tanto da safra como da safrinha, assim como um aumento nos níveis de PA. Durante o mês de dezembro observa-se a maior PA nacional, com 330 kg ha^{-1} a mais do que a média nacional para solos arenosos semeados no mesmo mês. A região Sul também se mostra com as maiores PAs, apresentando uma média de 9098 kg ha^{-1} para semeaduras realizadas em dezembro, 570 kg ha^{-1} a mais do que para a condição de semeadura em solo arenoso nesse mesmo mês. Em solos com textura média, a semeadura do milho safrinha fica mais segura no Centro-Oeste brasileiro, principal região de cultivo do milho safrinha, com uma janela de semeadura que ainda apresenta patamares de PA

elevados para a segunda safra (Figura 5.5). A maior capacidade de água disponível em solos de textura média eleva a PA do milho em praticamente todo o território nacional ao longo do ano, pois proporciona o abastecimento de água para a cultura durante um período mais longo, atrasando a entrada da planta de milho em estado de déficit hídrico, minimizando a perda de produtividade em relação à condição potencial (PP).

O mapeamento da PA em solos argilosos mostra uma influência positiva do aumento da textura do solo na PA da cultura do milho. O armazenamento de uma maior quantidade de água proporciona um melhor abastecimento hídrico da cultura por um período maior de dias, fazendo com que as plantas de milho passem menos tempo submetidas a condições de déficit hídrico do que as plantas cultivadas em solos de textura arenosa ou média. Esse efeito também pode ser observado na PA média nacional, que é de 8308 kg ha⁻¹ durante o mês de dezembro, obtida em condições de maior teor de argila no solo. Também é perceptível o prolongamento na janela de semeadura tanto da safra quanto da safrinha (Figura 5.6).

Figura 5.4. Produtividade atingível da cultura do milho no Brasil, estimada por meio da combinação de três modelos de simulação (MZA-FAO, DSSAT Ceres-Maize e APSIM-Maize), para semeaduras simuladas mensalmente no período de 1980 a 2013, considerando-se solos de textura arenosa

Figura 5.5. Produtividade atingível da cultura do milho no Brasil, estimada por meio da combinação de três modelos de simulação (MZA-FAO, DSSAT Ceres-Maize e APSIM-Maize), para semeaduras realizadas mensalmente no período de 1980 a 2013, considerando-se solos de textura média

Figura 5.6. Produtividade atingível da cultura do milho no Brasil, estimada por meio da combinação de três modelos de simulação (MZA-FAO, DSSAT Ceres-Maize e APSIM-Maize), para semeaduras realizadas mensalmente no período de 1980 a 2013, considerando-se solos de textura argilosa

A análise dos mapas de PA (Figuras 5.4, 5.5 e 5.6) evidencia o forte efeito do déficit hídrico sofrido pelas regiões Centro-Oeste e Nordeste ao longo do ano, caracterizado pelas manchas avermelhadas dos mapas, reflexo da penalização da produtividade pelo déficit hídrico, especialmente na safrinha. Em alguns locais, mesmo em épocas do ano e condições de solo favoráveis, as produtividades atingíveis médias não ultrapassam os 7500 kg ha^{-1} , evidenciando um regime hídrico extremo. É perceptível também que a região Sul é a que menos sofre com penalizações hídricas, por ter um regime de chuvas mais bem distribuído, predominando tonalidades verdes e azuis ao longo do ano todo para os três tipos de solo estudados.

5.3.1.3. *Yield gaps* (YG) da cultura do milho no Brasil

Por meio da diferença entre os valores de PP e PA determinou-se os mapas do *Yield Gap* por déficit hídrico (YG_{dh}) para a cultura do milho no Brasil (Figuras 5.7, 5.8 e 5.9). Esses mapas buscam mostrar o quanto cada região perde de produtividade de milho em decorrência do déficit hídrico (YG_{dh}) ao longo do ciclo, de forma que, quanto menor for o YG_{dh} , menor a perda de produtividade ocasionada pela baixa disponibilidade de água no solo. Assim como a PA, o YG_{dh} também foi avaliado para cada textura de solo.

Em solos arenosos, o YG_{dh} foi o mais elevado, com valores médios para o período de safra e safrinha de 5259 kg ha^{-1} e 6977 kg ha^{-1} , respectivamente. A região Sul do país foi a que apresentou os menores valores de YG_{dh} tanto para a safra quanto para a safrinha, o que mostra que, ao longo dos anos, há uma boa disponibilidade de água durante o período em que a cultura se encontra no campo (Figura 5.7). Durante a safra, as regiões tradicionais no cultivo do milho (Sul e Sudeste) apresentam valores médios de YG_{dh} variando entre 5769 kg ha^{-1} e 4700 kg ha^{-1} . Por outro lado, na região Nordeste, principalmente no extremo leste, os valores de YG_{dh} superaram os 12000 kg ha^{-1} nas semeaduras de setembro a dezembro, quando o ciclo da cultura do milho se desenvolve na estação seca dessa região. Durante a safrinha, os piores resultados de YG_{dh} foram encontrados na região de maior importância para esse cultivo, ou seja, na região Centro-Oeste, onde o YG_{dh} médio é de 7285 kg ha^{-1} .

Analisando a condição de YG_{dh} em solos médios (Figura 5.8), observa-se uma diminuição dos níveis em todo o país, mostrando a importância e o benefício trazido pelo maior abastecimento de água para as plantas de milho durante mais tempo. Para a safrinha, na região Centro-Oeste, nota-se uma diminuição do YG_{dh} médio para 6541 kg ha^{-1} , 740 kg ha^{-1}

¹ a menos do que as perdas ocasionadas pelo déficit hídrico em condição de solo arenoso. Durante a safra, a região Centro-Oeste apresentou o menor patamar de YG_{dh} , 3340 kg ha⁻¹, indicando a ocorrência de um regime hídrico mais satisfatório para a cultura do milho nessa região. Nas regiões tradicionais de plantio do milho safra (Sul e Sudeste), os níveis do YG_{dh} diminuíram nos solos de textura média, passando para 5182 e 4279 kg ha⁻¹, respectivamente.

O YG_{dh} para a condição de solos argilosos (Figura 5.9) foi o que apresentou o menor valor, devido à capacidade desses solos em armazenar uma maior quantidade de água, mantendo a evapotranspiração relativa da cultura próximo da exigida por mais tempo do que nas condições de solos médios ou arenosos. Tanto para o período de safra quanto para o de safrinha, o YG_{dh} é menor em praticamente todas as regiões brasileiras, mostrando os benefícios de se cultivar milho em solos com maior teor de argila, ou seja, com maior capacidade de água disponível (Figura 5.9). A maior capacidade de água disponível dos solos argilosos possibilitou que a região Centro-Oeste, durante a safrinha, apresentasse um YG_{dh} médio de 5395 kg ha⁻¹, quase 2000 kg ha⁻¹ a menos do que para a situação de safrinha em solos arenosos. Durante a safra, com exceção da região litorânea do Nordeste, os níveis de YG_{dh} foram baixos em quase todo o território nacional, mostrando que, para esse tipo de solo, a distribuição das chuvas nesse período é satisfatória para atender a demanda hídrica da cultura do milho, alcançando, assim, elevados patamares de produtividade, mesmo em condição de sequeiro. As regiões Sul e Sudeste foram as que apresentaram as menores perdas de produtividade decorrentes do déficit hídrico durante a safra para o cultivo em solos argilosos, com YG_{dh} da ordem de 3752 e 4471 kg ha⁻¹, respectivamente.

Figura 5.7. Quebra de produtividade (*Yield Gap*) por déficit hídrico da cultura do milho no Brasil, para semeaduras realizadas mensalmente, para o período de 1980 a 2013, considerando-se solos de textura arenosa

Figura 5.8. Quebra de produtividade (*Yield Gap*) por déficit hídrico da cultura do milho no Brasil, para semeaduras realizadas mensalmente para o período de 1980 a 2013, considerando-se solos de textura média

Figura 5.9. Quebra de produtividade (*Yield Gap*) por déficit hídrico da cultura do milho no Brasil, para semeaduras realizadas mensalmente para o período entre 1980 e 2013, considerando-se solos de textura argilosa

Analisando os mapas de YG_{dh} , nota-se que a quebra de produtividade é sempre maior nos períodos do ano onde a seca é mais intensa, usualmente durante o inverno, assim como é maior nas regiões brasileiras tipicamente menos chuvosas, como a região Nordeste. É notório também o efeito positivo do aumento da textura do solo na redução dos níveis do YG_{dh} , tanto ao longo do ano, amenizando o efeito do déficit hídrico durante a estação seca, quanto para as diferentes regiões, atenuando a quebra de produtividade nos locais menos favorecidos pela distribuição anual das chuvas.

Ao compararmos os resultados apresentados com os de trabalhos obtidos na literatura, comprovamos o efeito negativo do déficit hídrico, evidenciado por esse estudo, como apontam Serpa et al. (2009), que, por meio de experimentos de campo conduzidos na região Sul do país, identificaram redução no número de grãos nas espigas das plantas de milho conduzidas em ambiente sem irrigação, impactando a quebra de produtividade na condição de sequeiro que foi 2 a 4,5 t ha⁻¹ menor do que a produtividade com irrigação. Carvalho et al. (2014), em Alto Jacuí (RS), também observaram perda de produtividade do milho causada pelo déficit hídrico nessa região, com a produtividade do milho irrigado sendo 36% maior do que a de sequeiro. Na região Centro Oeste, Silva et al. (2016), utilizando o modelo DSSAT Ceres-Maize, apontaram um YG_{dh} para as simulações durante a safra da ordem de 14%, enquanto que para a safrinha o YG_{dh} foi superior a 20% em todas as simulações, em função da pior distribuição das chuvas durante esse período.

Uma vez determinado o YG_{dh} , passou-se à determinação e mapeamento da perda de produtividade decorrente do déficit de manejo, denominada de *Yield Gap* manejo (YG_m), para as três texturas de solo classificadas neste estudo, por meio da diferença entre as produtividades atingível e a real (Figura 5.10) durante a safra e a safrinha. Os baixos níveis de PR apresentados na Figura 5.10 para a safra e a safrinha indicam que além das perdas decorrentes do déficit hídrico, apresentadas nas Figuras 5.7, 5.8 e 5.9, ainda ocorrem perdas decorrentes do manejo (YG_m).

Figura 5.10. Produtividade real média da cultura do milho no Brasil no período entre 2003 e 2013. Adaptado de: IBGE 2017

Ao contrário do observado na análise do YG_{dh} , os maiores valores de YG_m foram observados na condição de solos argilosos, justamente por apresentarem um maior patamar de PA. O YG_m para o período de safra, com milho cultivado em solos arenosos, foi menor na região Sul, em especial no estado do Paraná, com valores médios de YG_m de 2231 e 1595 kg ha⁻¹, respectivamente, enquanto que a média nacional foi de 3171 kg ha⁻¹. Para o período de safrinha, a região com melhor desempenho foi a Centro-Oeste, com um YG_m médio de 280 kg ha⁻¹, enquanto que a média nacional foi de 2596 kg ha⁻¹ (Figura 5.11).

Para o YG_m em condições de solos de textura média, é perceptível o aumento de manchas esverdeadas tanto no mapa da safra quanto no da safrinha, indicando maiores

quebras de produtividade. O YG_m médio nacional foi de 3539 kg ha^{-1} para a safra e 3006 kg ha^{-1} para a safrinha, sendo que a região de pior desempenho, tanto na safra quanto na safrinha, foi a região Norte, com um YG_m médio de 4228 kg ha^{-1} para a safra e de 5123 kg ha^{-1} para a safrinha. As regiões tradicionais de cultivo do milho na safra e safrinha foram as que apresentaram os menores índices de YG_m , sendo de 2721 kg ha^{-1} para a safra na região Sul e 496 kg ha^{-1} para a safrinha na região Centro-Oeste (Figura 5.12). Os locais mais tradicionais e relevantes na produção do milho safra e safrinha tendem a ser os mais tecnificados e experientes no cultivo do grão, que normalmente resulta em baixos níveis do YG_m .

Os maiores patamares nacionais do YG_m foram encontrados para a condição de solos argilosos, correspondendo a 4107 kg ha^{-1} para a safra e 3691 kg ha^{-1} para a safrinha. Esses valores são maiores devido aos solos argilosos terem uma maior capacidade de água disponível, proporcionando uma maior PA. Para a safrinha cultivada em solos argilosos a região de melhor desempenho foi a Centro-Oeste, com destaque para os estados do Mato Grosso e Goiás, que apresentaram um YG_m de 845 e 738 kg ha^{-1} , respectivamente. Para o milho safra, o melhor desempenho é observado no estado do Paraná, com um YG_m médio de 2425 kg ha^{-1} (Figura 5.13).

Figura 5.11. *Yield Gap* de déficit de manejo agrícola da cultura do milho durante a safra e a safrinha para a condição de solo de textura arenosa no Brasil

Figura 5.12. Yield Gap de déficit de manejo agrícola da cultura do milho durante a safra e a safrinha para a condição de solo de textura média no Brasil

Figura 5.13. *Yield Gap* de déficit de manejo agrícola da cultura do milho durante a safra e a safrinha para a condição de solo de textura argilosa no Brasil

Os mapas de YG_m mostram a relevância do tipo de solo no estabelecimento dos patamares da quebra de produtividade e também a relevância do nível tecnológico local, capaz de reduzir o YG_m para zero em algumas situações. As regiões Norte e Nordeste, assim como o estado de Minas Gerais, foram os locais que apresentaram as maiores quebras de produtividade por déficit de manejo, indicando serem as regiões com as piores práticas no cultivo do milho. O investimento em tecnologia e assistência técnica nessas regiões pode ser muito rentável, principalmente em áreas de cultivo com solos argilosos. A fim de mostrar os

resultados mapeados em formato numérico, as produtividades e *yield gaps* médios do solo de textura média foram apresentados nas Tabelas 4 e 5 para cada estado brasileiro considerado no estudo. De um modo geral, observa-se que na maioria dos estados a maior fonte de perdas de produtividade na cultura do milho é por déficit hídrico, tanto na safra como na safrinha, havendo algumas poucas exceções como nos estados do ES, MT, RJ, SP e TO na safra e nos estados do PA, RS e SC na safrinha.

Tabela 5.4. Produtividade potencial (PP), produtividade atingível (PA), produtividade real (PR), *yield gap* por déficit hídrico (YG_{dh}) e *yield gap* por manejo (YG_m) para a condição de solo médio durante o período de safra

Estado	Sigla	PP	PA	PR	YG _{dh}	YG _m
Alagoas	AL	12655,0	1335,1	1265,2	11319,9	69,9
Bahia	BA	12506,5	5016,2	2285,7	7490,3	2730,5
Ceará	CE	11895,3	2685,3	360,0	9210,0	2325,3
Brasília	DF	12713,0	9300,2	7831,7	3412,8	1468,5
Espírito Santo	ES	12721,7	8037,7	2548,1	4684,0	5489,6
Goiás	GO	12241,0	8924,3	6127,1	3316,7	2797,2
Maranhão	MA	10802,5	6088,2	2455,7	4714,3	3632,5
Mato Grosso	MT	11600,9	8545,7	4637,6	3055,2	3908,1
Mato Grosso do Sul	MS	12735,3	8510,4	5096,5	4224,9	3413,9
Minas Gerais	MG	12673,9	8142,0	4259,1	4531,9	3882,9
Pará	PA	10628,8	6403,3	2371,8	4225,5	4031,5
Paraíba	PB	12425,8	1223,3	346,0	11202,5	877,3
Paraná	PR	13495,0	8978,3	7279,9	4516,7	1698,4
Pernambuco	PE	12442,9	1294,5	340,1	11148,4	954,4
Piauí	PI	11719,1	5638,0	1685,8	6081,1	3952,2
Rio de Janeiro	RJ	12758,5	9004,3	1793,9	3754,2	7210,4
Rio Grande do Norte	RN	12341,2	1145,4	358,1	11195,8	787,3
Rio Grande do Sul	RS	14008,4	7885,7	4890,9	6122,7	2994,8
Santa Catarina	SC	14022,5	9898,7	6590,8	4123,8	3307,9
São Paulo	SP	12837,5	9092,5	5049,9	3745,0	4042,6
Sergipe	SE	12761,9	2097,9	2615,6	10664,0	0,0
Tocantins	TO	10975,7	8156,0	3125,1	2819,7	5030,9

Tabela 5.5. Produtividade potencial (PP), produtividade atingível (PA), produtividade real (PR), *yield gap* por déficit hídrico (YG_{dh}) e *yield gap* por manejo (YG_m) para a condição de solo médio durante o período de safrinha

Estado	Sigla	PP	PA	PR	YG _{dh}	YG _m
Alagoas	AL	12076,3	5821,0	190,8	6255,30	5630,2
Bahia	BA	11975,6	4417,2	3057,3	7558,4	1359,9
Ceará	CE	11698,6	4119,7	254,0	7578,9	3865,7
Brasília	DF	12736,1	3827,7	6795,7	8908,4	0,0
Espírito Santo	ES	11943,2	3993,8	1372,4	7949,4	2621,4
Goiás	GO	11052,2	4034,5	5132,6	7017,7	0,0
Maranhão	MA	11145,2	4765,8	573,0	6379,4	4192,8
Mato Grosso	MT	11249,2	4796,2	5166,7	6453,0	0,0
Mato Grosso do Sul	MS	11302,6	6121,3	4407,5	5181,3	1713,8
Minas Gerais	MG	12137,9	4075,1	3469,7	8062,8	605,4
Pará	PA	10920,6	6840,8	906,8	4079,8	5934,0
Paraíba	PB	11958,3	4535,2	23,6	7423,1	4511,6
Paraná	PR	11188,3	6823,4	4439,3	4364,9	2384,1
Pernambuco	PE	11980,2	4578,8	554,4	7401,4	4024,4
Piauí	PI	11706,2	3804,5	1180,2	7901,7	2624,3
Rio de Janeiro	RJ	11755,8	5310,6	763,3	6445,2	4547,3
Rio Grande do Norte	RN	11904,2	4227,6	738,6	7676,6	3489,0
Rio Grande do Sul	RS	10407,6	5542,0	26,7	4865,6	5515,3
Santa Catarina	SC	10226,0	5572,9	205,5	4653,1	5367,4
São Paulo	SP	11630,0	6519,0	4086,2	5111,0	2432,8
Sergipe	SE	12103,9	6521,7	2504,1	5582,2	4017,6
Tocantins	TO	11246,6	4208,8	2789,6	7037,8	1419,2

Uma abordagem semelhante à deste estudo é apresentada pelo sistema *Global Yield Gap Atlas* (GYGA, 2017), da Universidade de Nebraska, o qual já quantificou e mapeou a produtividade e o YG da cultura do milho no Brasil. Esse sistema aponta que o YG_m para o milho cultivado no Brasil é homogêneo e da ordem de 8500 kg ha⁻¹. Poucos são os estudos que evidenciam quebras de produtividade devido ao manejo (YG_m), entretanto, o presente estudo mostrou que essas perdas não são homogêneas ao longo do território nacional cultivado com milho (Figuras 5.11 a 5.13), já que essas foram menores nas regiões tradicionais de produção do grão e também em locais onde o nível tecnológico é mais elevado. Considerar características locais para determinar e mapear o YG_m é essencial para estabelecer sua real variabilidade e assim poder identificar as regiões mais carentes em

tecnologia e extensão rural, já que o YG_m varia tanto no espaço quanto no tempo, conforme podemos observar nas Figuras 5.11, 5.12 e 5.13, onde o YG_m variou de 0 até 10000 kg ha⁻¹.

A identificação da variabilidade e quantificação do YG_m proporciona uma melhor escolha das estratégias para mitigar as quebras de produtividade tanto em relação a época do ano (cultivos de safra ou safrinha) quanto aos locais de produção (ambientes mais ou menos tecnificados, tipos de solo, etc.), auxiliando o produtor a escolher o genótipo mais adequado para cada região em função do déficit hídrico, ajustar a adubação e até definir a densidade populacional. O posicionamento da semeadura no mês ideal também é um fator que pode diminuir o YG, já que as janelas de cultivo tanto da safra quanto da safrinha englobam meses onde o potencial e o risco climático nem sempre são os mesmos. Nas regiões onde o YG_m foi baixo porpém o Y_{dh} foi alto, indicando que o local alcançou produtividades próximas da PA, é interessante avaliar a possibilidade de se explorar um maior perfil de solo, proporcionando às plantas um maior fornecimento de água e nutrientes. A instalação de sistemas de irrigação nesses locais onde o YG_{dh} é alto é uma possibilidade, já que a restrição hídrica é a principal barreira para o aumento da produtividade.

5.4. Conclusões

- a) A PP variou principalmente com a latitude e a época de plantio de cada região do país, apresentando valores superiores a 8000 kg ha⁻¹ ao longo do ano para a maioria das localidades;
- b) A grande variabilidade na distribuição das chuvas ao longo do território nacional e ao longo do período estudado se refletiu nos valores de YG_{dh} encontrados neste estudo, mostrando que o regime hídrico é o principal fator responsável pelas baixas produtividades do milho brasileiro;
- c) Em média, o YG_{dh} representou uma quebra de 52% na produtividade atingível do milho no Brasil, sendo que seus piores resultados foram encontrados nos solos arenosos, para os locais e épocas do ano onde as chuvas são mais escassas e mau distribuídas;

- d) As práticas sub-ótimas de manejo fizeram com que o YG_m seja expressivo em grande parte do território nacional, sendo responsável por uma quebra da produtividade, em média, de 54% para todo o país. Regiões tradicionais e também as mais tecnificadas, como a região Sul (para a safra) e Centro-Oeste (para a safrinha), apresentaram níveis de YG_m mais baixos, inferiores a 30 e 12%, respectivamente e
- e) A identificação dos principais fatores limitantes da produtividade para cada região possibilita a adoção de estratégias mais eficientes para se aumentar as produtividades de milho. No caso das localidades em que o YG_m é elevado, pode-se ter melhorar o desempenho do cultivo por meio da escolha de genótipos mais adaptados à região, do refinamento da adubação e do controle fitossanitário, do ajuste da população de plantas, entre outras. Em locais onde o YG_m é maior, o uso da irrigação e a exploração de um maior perfil de solo são as soluções mais adequadas, além da escolha de genótipos com maior grau de tolerância à seca.

REFERÊNCIAS

- AFFHOLDER, F.; POEYDEBAT, C.; CORBEELS, M.; SCOPEL, E.; TITTONELL, P. The yield gap of major food crops in family agriculture in the tropics: Assessment and analysis through field surveys and modeling. **Fields Crops Research**, v.143, p.106-118, 2013.
- ASSENS, S.; EWERT, F.; ROSENZWEIG, C. J. W.; HATFIELD, J. L.; RUANE, A. C.; BOOTLE, K. J.; THORBURN, P.J.; ROTTER, R.P.; CAMMARANO, D.; BRISSON, N.; BASSO, B.; MATRE, P.; AGGARWAL, P. K.; ANGULO, C.; BERTUZZI, P.; BIERNATH, C.; CHALLINOR, A. J.; DOLTRA, J.; GAYLER, S.; GOLDBERG, R.; GRANT, R.; HEING, L.; HOOKER, J.; HUNT, L. A.; INGWERSEN, J.; IZAURRALDE, R. C.; KERSEBAUM, K. C.; MULLER, C.; NARESH KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. A.; OSBORNE, T. M.; PALOSUO, T.; STOCKLE, C.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; TRAVASSO, M.; WAHA, K.; WALLACH, D.; WHITE, J. W.; WILLIAMS, J. R.; WOLF, J. Uncertainty in simulation wheat yields under climate change. **Nature Climate Change**, London, v.3, p. 827-832, 2013.
- BATTISTI, R.; SENTELHAS, P.C. Eficiência climática para as culturas da soja e do trigo no estado do Rio Grande do Sul em diferentes datas de semeadura. **Ciência Rural**, Santa Maria, v. 43, p. 390-396, 2012.
- BATTISTI, R., SENTELHAS, P.C., KENNETH, J.B. Inter-comparison of performance of soybean crop simulation models and their ensemble in southern Brazil. **Field Crops Research**, Amsterdam, v.200, p. 28-37, 2017.
- DIAS, H. B. Intercomparação de modelos de simulação de cana-de-açúcar e seu uso na avaliação da quebra de produtividade e dos impactos da irrigação em diferentes regiões do Brasil. **Tese apresentada para obtenção do título de Mestre em agronomia**, Piracicaba: ESALQ - USP, 2015.
- GYGA. **Global Yield Gap Atlas – Basic data**. 2017. Disponível em: < <http://www.yieldgap.org/gygamaps/app/index.html> >. Acesso em: 14 nov. 2017.
- HEINEMANN, A.B.; SENTELHAS, P.C. Environmental group identification for upland rice production in central Brazil. **Scientia Agricola**, Piracicaba, v. 68, p. 540-547, 2011.
- LOBELL, D.B.; CASSMAN, K.G.; FIELD, C.B. Crop yield gaps: their importance, magnitudes, and causes. **The Annual Review of Environment and Resources**, Palo Alto, v.34, 174–204, 2009.

- MARIN, F. R. Eficiência da produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos. **Tese de livre-docência**, Piracicaba, 2014.
- MARTRE, P.; WALLACH, D.; ASSENG, S.; EWERT, F.; JONES, J. W.; ROTTER, R. P.; BOOTE, K. J.; RUANE, A. C.; THORBURNE, P. J.; CAMMARANO, D.; HATFIELD, J. L.; ROSENZWEIG, C.; AGGARWAL, P. K.; ÂNGULO, C.; BASSO, B.; BERTUZZI, P.; BIERNATH, C.; BRISSON, N.; CHALLINOR, A. J.; DOLTRA, J.; GAYLER, S.; GOLDBERG, R.; GRANT, R. F.; HENG, L.; HOOKER, J.; HUNT, L. A.; INGWERSEN, J.; IZAURRALDE, R. C.; KERSEBAUM, K. C.; MULLER, C.; KUMAR, S.; NENDEL, C.; O'LEARY, G.; OLESEN, J. A.; OSBORNE, T.; PALOSUO, T.; PRIESACK, E.; RIPOCHE, D.; SEMENOV, M. A.; SHCHERBAK, I.; STEDUTO, P.; STOCKLE, C. O.; STRATONOVITCH, P.; STRECK, T.; SUPIT, I.; TAO, F.; TRAVASSO, M.; WAHA, K.; WHITE, J. W.; WOLF, J. Multimodel ensembles of wheat growth: many models are better than one. **Global Change Biology**, Oxford, v.21, p. 911-925, 2014.
- MCKINION, J.M.; WILLERS, J.L.; JENKINS, J.N. Spatial analyses to evaluate multi-crop stability for a field. **Computer and Electronics in Agriculture**, Amsterdam, v. 70, p. 187-198, 2010.
- MONTEIRO, L. A. Sugarcane yield gap in Brazil: a crop modelling approach. **Tese apresentada para obtenção do título de Doutor em agronomia**, Piracicaba: ESALQ/USP, 2015.
- PALOSUO, T.; KERSEBAUM, K. C.; ANGULO, C.; HILAVINKA, P.; MORIONDO, M.; OLESEN, J. E.; PATIL, R. H.; RUGET, F.; RUMBAUR, C.; TAKÁČ, J.; TRNKA, M.; BINDI, M.; CALDAG, C.; EWERT, F.; FERRISE, R.; MIRSCHEL, W.; SAYLAN, L.; SISKÁ, B.; ROTTER, R. Simulation of winter wheat yield and its variability in diferente climates of Europe: a comparison, of eigth crop growth models. **European Journal Agronomy**, Amsterdam, v.35, p. 103-114, 2011.
- PANAGOPOULOS, T.; JESUS, J.; ANTUNES, M.D.C.; BELTRÃO, J. Analysis of spatial interpolation for optimising management of a salinized field cultivated with lettuce. **European Journal Agronomy**, Amsterdam, v. 24, p. 1-10, 2006.
- ROSENZWEIG, C.; JONES, J.W.; HATFIELD, J.L.; RUANE, A.C.; BOOTE, K.J.; THORBURN, P.; ANTLE, J.M.; NELSON, G.C.; POTER, C.; JANSSEN, S.; ASSENG, S.; BASSO, B.; EWERT, F.; WALLACH, D.; BAIGORRIA, G.; WINTER, J.M. The agricultural model intercomparison and improvement project (AgMIP): Protocols and pilot studies. **Agricultural and Forest Meteorology**, Amsterdam, v.170, p. 166-182, 2013.

- ROSENZWEIG, C.; JONES, J.W.; ANTLE, J.M.; HATFIELD, J.L. Protocols for AgMIP regional integrated assessments. **The Agricultural Model Intercomparison and Improvement Project**, New York, v.6, p. 1-63, 2015.
- SENTELHAS, P. C.; BATISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A. C.; NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **Journal of Agricultural Science**, Cambridge, p.1-18, 2015.
- SOUZA, E.G.; BAZZI, C.L.; KHOLSA, R.; URIBE-OPAZO, M.A.; REICH, R.M. Interpolation type and data computation of crop yield maps is important precision crop production. **Journal of Plant Nutrition**, New York, v. 39, p. 531-538, 2016.
- VAN ITTERSUM, M.K., CASSMAN, K.G., GRASSINI, P., WOLF, J., TITTONELL, P., HOCHMAN, Z., Yield gap analysis with local to global relevance—a review. **Field Crops Research**, Amsterdam, v.143, p.4–17, 2013.
- WALLACH, D.; MEARNS, L. O.; RUANE, A. C.; ROTTER, R. P.; ASSENG, S. Lessons for climate modeling on the design and use of ensembles for crop modeling. **Climatic Change**, Van Godewijckstraat, v.139, p. 551-564, 2016.
- XAVIER, A. C., KING, C. W., SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, Austin, 2015.
- YAMADA, T. O nitrogênio e o potássio na adubação da cultura do milho. **Informações Agronômicas**, Piracicaba, n. 78, p. 1-4, jun. 1997.

ANEXO A. Perfis dos solos utilizados nas simulações

Tabela A.1. Perfis dos solos utilizados no Modelo da Zona Agroecológica da FAO (MZA-FAO)

Tipo de solo	Capacidade de água disponível (CAD)
	mm
Argiloso	100
Médio	75
Arenoso	50

Tabela A.2. Perfil do solo argiloso utilizado no modelo CSM DSSAT Ceres-Maize

Camada	LLL	DUL	SAT	RGF	SKS	BDM	LOC	LCL	LSI	LNI	LHW	LHB	CEC
0-10	0,225	0,385	0,522	1,00	0,64	1,17	2,65	58,3	12,6	0,18	4,90	4,30	9,25
10-20	0,207	0,340	0,507	0,97	3,42	1,21	2,28	45,9	22,7	0,17	5,30	4,40	12,2
20-40	0,228	0,356	0,510	0,74	3,10	1,20	1,42	56,6	20,6	0,13	5,20	4,40	8,14
40-60	0,242	0,364	0,522	0,48	3,78	1,22	1,39	57,8	19	0,11	5,40	4,50	9,16
60-80	0,237	0,352	0,503	0,29	0,79	1,26	0,90	57,9	15,5	0,08	5,30	4,40	8,03
80-100	0,249	0,375	0,499	0,24	0,95	1,26	0,72	57,2	18,5	0,05	5,50	4,70	5,49

LLL= ponto de murcha permanente ($\text{cm}^3 \text{cm}^{-3}$); DUL= capacidade de campo ($\text{cm}^3 \text{cm}^{-3}$); SAT= saturação ($\text{cm}^3 \text{cm}^{-3}$); RGF= fator de crescimento radicular (%); SKS= condutividade hidráulica (cm hr^{-1}); BDM= densidade do solo (g cm^{-3}); LOC= carbono orgânico (%); LCL= argila (%); LSI= silte (%); LNI= concentração de nitrogênio (%); LHW= pH em água; LHB= pH em solução tampão e CEC= capacidade de troca de cátions (cmol kg^{-1}).

Tabela A.3. Perfil do solo médio utilizado no modelo CSM DSSAT Ceres-Maize

Camada	LLL	DUL	SAT	RGF	SKS	BDM	LOC	LCL	LSI	LNI	LHW	LHB	CEC
0-10	0,112	0,251	0,456	1,00	4,04	1,29	1,95	22,0	23,0	0,13	5,45	4,70	12,7
10-20	0,071	0,167	0,425	1,00	3,68	1,37	1,74	9,25	11,2	0,10	6,05	5,10	4,10
20-40	0,175	0,302	0,471	0,67	1,72	1,34	1,25	30,3	20,7	0,10	5,47	4,40	7,40
40-60	0,179	0,279	0,465	0,44	1,39	1,36	0,94	29,6	14,9	0,08	5,64	4,60	10,0
60-80	0,238	0,337	0,431	0,31	0,23	1,51	0,32	33,0	24,5	0,07	6,55	4,80	12,1
80-100	0,185	0,303	0,446	0,20	1,72	1,41	0,46	26,1	22,3	0,08	5,74	4,46	6,98

LLL= ponto de murcha permanente ($\text{cm}^3 \text{cm}^{-3}$); DUL= capacidade de campo ($\text{cm}^3 \text{cm}^{-3}$); SAT= saturação ($\text{cm}^3 \text{cm}^{-3}$); RGF= fator de crescimento radicular (%); SKS= condutividade hidráulica (cm hr^{-1}); BDM= densidade do solo (g cm^{-3}); LOC= carbono orgânico (%); LCL= argila (%); LSI= silte (%); LNI= concentração de nitrogênio (%); LHW= pH em água; LHB= pH em solução tampão e CEC= capacidade de troca de cátions (cmol kg^{-1}).

Tabela A.4. Perfil do solo arenoso utilizado no modelo CSM DSSAT Ceres-Maize

Camada	LLL	DUL	SAT	RGF	SKS	BDM	LOC	LCL	LSI	LNI	LHW	LHB	CEC
0-10	0,073	0,182	0,419	1,00	6,53	1,41	1,23	10,0	11,0	0,10	5,40	4,50	6,00
10-20	0,056	0,144	0,419	0,95	6,65	1,45	0,97	8,20	6,50	0,55	5,50	4,60	3,20
20-40	0,078	0,185	0,402	0,76	5,40	1,51	0,80	13,3	10,6	0,05	5,52	4,30	2,78
40-60	0,081	0,166	0,404	0,48	4,80	1,49	0,36	12,2	6,10	0,04	5,56	4,50	1,70
60-80	0,103	0,202	0,424	0,35	4,26	1,53	0,37	16,3	6,60	0,04	5,89	4,60	1,50
80-100	0,095	0,163	0,374	0,20	2,90	1,59	0,27	14,1	6,10	0,03	6,35	5,36	3,20

LLL= ponto de murcha permanente ($\text{cm}^3 \text{ cm}^{-3}$); DUL= capacidade de campo ($\text{cm}^3 \text{ cm}^{-3}$); SAT= saturação ($\text{cm}^3 \text{ cm}^{-3}$); RGF= fator de crescimento radicular (%); SKS= condutividade hidráulica (cm hr^{-1}); BDM= densidade do solo (g cm^{-3}); LOC= carbono orgânico (%); LCL= argila (%); LSI= silte (%); LNI= concentração de nitrogênio (%); LHW= pH em água; LHB= pH em solução tampão e CEC= capacidade de troca de cátions (cmol kg^{-1}).

Tabela A.5. Perfil do solo argiloso utilizado no modelo APSIM-Maize

Camada	BD	AD	LL15	DUL	SAT	OC	pH	CL	KL	XF
0-10	1,17	0,015	0,225	0,385	0,522	2,65	6	58,3	0,11	1,00
10-20	1,21	0,012	0,207	0,340	0,507	2,28	6	45,9	0,11	1,00
20-40	1,20	0,011	0,228	0,356	0,510	1,42	6	56,6	0,11	1,00
40-60	1,22	0,011	0,242	0,364	0,522	1,39	6	57,8	0,09	1,00
60-80	1,26	0,079	0,237	0,352	0,503	0,90	6	57,9	0,09	1,00
80-100	1,26	0,044	0,249	0,375	0,499	0,72	6	57,2	0,07	1,00

BD= densidade do solo (g cm^{-3}); AD= porosidade (%); LL15= ponto de murcha permanente ($\text{cm}^3 \text{ cm}^{-3}$); DUL= capacidade de campo ($\text{cm}^3 \text{ cm}^{-3}$); SAT= saturação ($\text{cm}^3 \text{ cm}^{-3}$); OC= carbono orgânico (%); pH= pH em água; CL= argila (%); KL= fração de água disponível para a planta (%) e XF= fator de exploração do solo pela raiz (%).

Tabela A.6. Perfil do solo médio utilizado no modelo APSIM-Maize

Camada	BD	AD	LL15	DUL	SAT	OC	pH	CL	KL	XF
0-10	1,29	0,015	0,112	0,251	0,456	1,95	6	22,0	0,11	1,00
10-20	1,37	0,012	0,071	0,167	0,425	1,74	6	9,25	0,11	1,00
20-40	1,34	0,011	0,175	0,302	0,471	1,25	6	30,3	0,11	1,00
40-60	1,36	0,011	0,179	0,279	0,465	0,94	6	29,6	0,09	1,00
60-80	1,51	0,079	0,238	0,337	0,431	0,32	6	33,0	0,09	1,00
80-100	1,41	0,044	0,185	0,303	0,446	0,46	6	26,1	0,07	1,00

BD= densidade do solo (g cm^{-3}); AD= porosidade (%); LL15= ponto de murcha permanente ($\text{cm}^3 \text{ cm}^{-3}$); DUL= capacidade de campo ($\text{cm}^3 \text{ cm}^{-3}$); SAT= saturação ($\text{cm}^3 \text{ cm}^{-3}$); OC= carbono orgânico (%); pH= pH em água; CL= argila (%); KL= fração de água disponível para a planta (%) e XF= fator de exploração do solo pela raiz (%).

Tabela A.7. Perfil do solo arenoso utilizado no modelo APSIM-Maize

Camada	BD	AD	LL15	DUL	SAT	OC	pH	CL	KL	XF
0-10	1,41	0,015	0,073	0,182	0,419	1,23	6	10,0	0,11	1,00
10-20	1,45	0,012	0,056	0,144	0,419	0,97	6	8,20	0,11	1,00
20-40	1,51	0,011	0,078	0,185	0,402	0,80	6	13,3	0,11	1,00
40-60	1,49	0,011	0,081	0,166	0,404	0,36	6	12,2	0,09	1,00
60-80	1,53	0,079	0,103	0,202	0,424	0,37	6	16,3	0,09	1,00
80-100	1,59	0,044	0,095	0,163	0,374	0,27	6	14,1	0,07	1,00

BD= densidade do solo (g cm^{-3}); AD= porosidade (%); LL15= ponto de murcha permanente ($\text{cm}^3 \text{ cm}^{-3}$); DUL= capacidade de campo ($\text{cm}^3 \text{ cm}^{-3}$); SAT= saturação ($\text{cm}^3 \text{ cm}^{-3}$); OC= carbono orgânico (%); pH= pH em água; CL= argila (%); KL= fração de água disponível para a planta (%) e XF= fator de exploração do solo pela raiz (%).

ANEXO B. Influência das épocas de semeadura na produtividade da cultura do milho em diferentes localidades do Brasil

Figura B.1. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo arenoso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.1. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo arenoso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.1. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo arenoso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.1. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo arenoso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.1. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo arenoso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.2. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo argiloso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.2. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo argiloso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.2. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo argiloso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.2. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo argiloso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

Figura B.2. Variabilidade da produtividade atingível (PA) da cultura do milho, semeado em solo argiloso, ao longo do período analisado para cada decêndio de semeadura nas localidades estudadas

ANEXO C. Previsão da produtividade da cultura do milho safrinha para diferentes localidades do Brasil

Figura C.1. Variabilidade e comparação de médias da estratégia 1 (E1), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.1. Variabilidade e comparação de médias da estratégia 1 (E1), usando 5 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.2. Variabilidade e comparação de médias da estratégia 2 (E2), usando 25 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.2. Variabilidade e comparação de médias da estratégia 2 (E2), usando 25 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.3. Variabilidade e comparação de médias da estratégia 3 (E3), usando 45 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.3. Variabilidade e comparação de médias da estratégia 3 (E3), usando 45 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.4. Variabilidade e comparação de médias da estratégia 4 (E4), usando 65 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.4. Variabilidade e comparação de médias da estratégia 4 (E4), usando 65 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.5. Variabilidade e comparação de médias da estratégia 5 (E5), usando 85 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas

Figura C.5. Variabilidade e comparação de médias da estratégia 5 (E5), usando 85 dias de dados históricos médios para a previsão da produtividade do milho em relação às produtividades simuladas com dados climáticos observados para as cidades estudadas