



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE AGRONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

**AVALIAÇÃO DE ESTAÇÕES CLIMÁTICAS VIRTUAIS E DO
MODELO ORYZAv3 PARA A REGIÃO DE ARROZ TROPICAL
IRRIGADO**

CAIO TEODORO MENEZES

Orientador:

Dr. Alexandre Bryan Heinemann

Goiânia, GO

Fevereiro - 2021



UFG

UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE AGRONOMIA

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

☒ [x] Dissertação ☐ [] Tese

2. Nome completo do autor

Caio Teodoro Menezes

3. Título do trabalho

Avaliação de estações climáticas virtuais e do modelo ORYZAv3 para a região de arroz tropical irrigado

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento ☒ [x] SIM ☐ [] NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

- a)** consulta ao(à) autor(a) e ao(à) orientador(a);
- b)** novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Alexandre Bryan Heinemann, Usuário Externo**, em 05/03/2021, às 15:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **CAIO TEODORO MENEZES, Discente**, em 29/03/2021, às 14:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1887858** e o código CRC **5900E627**.

Referência: Processo nº 23070.009312/2021-93

SEI nº 1887858

CAIO TEODORO MENEZES

**AVALIAÇÃO DE ESTAÇÕES CLIMÁTICAS VIRTUAIS E DO
MODELO ORYZAv3 PARA A REGIÃO DE ARROZ TROPICAL
IRRIGADO**

Dissertação apresentada ao Programa de Pós-Graduação em Agronomia, da Universidade Federal de Goiás, como requisito parcial à obtenção do título de Mestre em Agronomia.

Área de concentração: Produção Vegetal.

Orientador:

Dr. Alexandre Bryan Heinemann

Goiânia, GO – Brasil

2021

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Menezes , Caio Teodoro

Avaliação de estações climáticas virtuais e do modelo ORYZAv3
para a região de arroz tropical irrigado [manuscrito] / Caio Teodoro
Menezes . - 2021.

LXXXII, 82 f.

Orientador: Prof. Dr. Alexandre Bryan Heinemann.

Dissertação (Mestrado) - Universidade Federal de Goiás, Escola
de Agronomia (EA), Programa de Pós-Graduação em Agronomia, Goiânia,
2021.

1. Grãos. 2. modelos de simulação de cultura. 3. Oryza sativa L.. 4.
produtividade. I. Heinemann, Alexandre Bryan , orient. II. Título.

CDU 631/635



UNIVERSIDADE FEDERAL DE GOIÁS

ESCOLA DE AGRONOMIA

ATA DE DEFESA DE DISSERTAÇÃO

Ata Nº 46/2021 da sessão de Defesa de Dissertação de **Caio Teodoro Menezes** que confere o título de Mestre em Agronomia, na área de concentração em Produção Vegetal.

Aos 25/02/2021, vinte e cinco dias do mês de fevereiro do ano de dois mil e vinte e um, a partir das 14:00, catorze horas, por videoconferência, realizou-se a sessão pública de Defesa de Dissertação intitulada “Avaliação de estações climáticas virtuais e do modelo ORYZAv3 para a região de arroz tropical irrigado”. Os trabalhos foram instalados pelo Orientador e Presidente da Banca Examinadora, **Dr. Alexandre Bryan Heinemann (Embrapa Arroz e Feijão)** com a participação dos demais membros da Banca Examinadora: **Prof. Henrique Fonseca Elias de Oliveira (IFGoiano)**, membro titular externo; **Dr. João Rodrigo de Castro (Climatempo)**, membro titular externo. Durante a arguição, os membros da banca não fizeram sugestão de alteração do título do trabalho. Após a arguição, a Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação tendo sido o candidato **APROVADO** pelos seus membros. Proclamados os resultados pelo Presidente da Banca Examinadora, **Dr. Alexandre Bryan Heinemann**, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos 25/02/2021, vinte e cinco dias do mês de fevereiro do ano de dois mil e vinte e um.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Alexandre Bryan Heinemann, Usuário Externo**, em 25/02/2021, às 20:30, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **JOÃO RODRIGO DE CASTRO, Usuário Externo**, em 25/02/2021, às 21:09, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1887837** e o código CRC **60C4A97D**.

AGRADECIMENTOS

A Deus por tudo.

À minha família e amigos próximos, por sempre estarem dispostos a me ajudar e incentivar.

À Universidade Federal de Goiás (UFG) e à Escola de Agronomia, pela oportunidade da realização da Pós-Graduação.

À Embrapa Arroz e Feijão, pela infraestrutura disponibilizada para o desenvolvimento deste trabalho.

Ao Dr. Alexandre B. Heinemann, pela orientação.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de Mestrado.

Às pessoas que me ajudaram neste trabalho.

SUMÁRIO

RESUMO	9
ABSTRACT	10
1 INTRODUÇÃO	11
2 APLICAÇÕES DE MODELOS DE SIMULAÇÃO DE CULTURA	13
2.1 AMBIENTES DE POPULAÇÃO ALVO (TPE-"TARGET POPULATION OF ENVIRONMENT").....	13
2.2 ANÁLISE ECONÔMICA.....	14
2.3 LACUNA DE PRODUTIVIDADE (YIELD GAP).....	14
2.4 PRODUÇÃO VERDE.....	15
2.5 PROJEÇÕES AGROCLIMÁTICAS E ENOS.....	15
2.6. ORYZA v3.....	16
3 CARACTERÍSTICAS DOS CULTIVARES ESTUDADOS	16
3.1 BRS CATIANA.....	16
3.2 BRS PRIMAVERA.....	17
3.3 IRGA 424.....	17
4 THE IMPACT OF GRIDDED WEATHER DATABASE ON SOIL WATER AVAILABILITY IN RICE CROP MODELING	19
4.1 INTRODUCTION.....	19
4.2 MATERIAL AND METHODS.....	21
4.2.1 Locations and weather databases.....	21
4.2.2 Crop model simulations.....	22
4.2.3 Statistical analyses.....	22
4.3 RESULTS.....	22
4.3.1 Descriptive statistics to measured and gridded weather data.....	22
4.3.2 Crop modeling outputs.....	26
4.4 DISCUSSION.....	29
4.4.1 Weather variables.....	29
4.4.2 Simulated yield and phenology.....	29
4.4.3 Soil water availability effect on attainable yield.....	30

4.4.4. Limitations and future work.....	34
4.5 CONCLUSION.....	34
4.6 REFERENCES.....	34
5 PARAMETRIZAÇÃO E VALIDAÇÃO DO MODELO ORYZAv3 PARA DOIS CULTIVARES DE ARROZ TROPICAL IRRIGADO.....	39
5.1 INTRODUÇÃO.....	41
5.2 MATERIAL E MÉTODOS.....	42
5.2.1 Experimentos de campo.....	42
5.2.2 ORYZA (v3)	43
5.2.3 Parametrização e validação.....	45
5.3 RESULTADOS E DISCUSSÃO.....	48
5.3.1 Fotoperíodo.....	48
5.3.2 Parametrização e validação do ORYZA v3.....	49
5.3.3 Esterilidade da espiguetta.....	54
5.3.4 Validação.....	55
5.4 CONCLUSÕES.....	60
5.5 LITERATURA CITADA.....	61
6 CONSIDERAÇÕES FINAIS.....	66
7 REFERÊNCIAS.....	67
APÊNDICE.....	73

RESUMO

MENEZES, C. T. **Avaliação de estações climáticas virtuais e do modelo ORYZAv3 para a região de arroz tropical irrigado.** 2021. 81 f. Dissertação (Mestrado em Agronomia: Produção Vegetal) – Escola de Agronomia, Universidade Federal de Goiás, Goiânia, 2021.¹

No Brasil, o arroz é produzido em ambiente subtropical e tropical, no ambiente subtropical a produção está mais consolidada, ao passo que no ambiente tropical ainda há uma maior instabilidade na produção, por conta de fatores ambientais e socioeconômicos. Uma forma de sanar essa instabilidade é através de estudos com modelos de simulação de culturas, uma vez que estes são sensíveis às condições ambientais e de manejo. Desta forma, esse estudo objetivou primeiro avaliar bancos de dados climáticos utilizados em modelos de simulação de cultura, bem como a interação desses dados com o solo e, posteriormente, avaliar a possibilidade de uso do modelo ORYZA (v3) para a região de arroz tropical. No primeiro capítulo são avaliados os bancos de dados de estações meteorológicas virtuais DailyGridded e NASA/POWER, bem como a sua aplicação no modelo ORYZA (v3), utilizando arroz de sequeiro na região tropical simulado em solo arenoso e argiloso. No segundo capítulo, é feita a calibração e parametrização de dois cultivares de arroz irrigado para a região tropical de modo a checar a viabilidade do modelo ORYZA (v3) para estudos na região tropical. Verifica-se no primeiro capítulo que as estações virtuais são confiáveis apenas para condições em que não há déficit hídrico, devido às incertezas geradas pela interpolação da variável precipitação. Esse erro aparenta ser maior quando as simulações ocorreram em solos arenosos. No segundo capítulo é feita a calibração de dois cultivares de arroz irrigado, BRS Catiana e IRGA 424, utilizando dados de ensaios conduzidos em Goianira-GO, mostrando um bom ajuste do modelo aos ensaios utilizados na calibração. Na etapa da validação observa-se um viés do modelo em função da latitude, com tendência de subestimar resultados em estados mais ao norte e superestimar próximo ao ponto de calibração. Esse viés torna incerto a aplicação do modelo em toda a região tropical.

Palavras-chave: Grãos, modelos de simulação de cultura, *Oryza sativa* L., produtividade.

¹Orientador: Dr. Alexandre Bryan Heinemann. Embrapa Arroz e Feijão.

ABSTRACT

MENEZES, C. T. **The evaluation of gridded weather datasets and ORYZAv3 model for tropical rice in Brazil.** 2021. 81 f. Dissertation (Master in Agronomy: Plant Production) - School of Agronomy, Federal University of Goiás, Goiânia, 2021.¹

In Brazil, there are two main rice producing regions, subtropical and tropical. In the subtropical region, production is more stable whereas in the tropical region it is still unstable. This difference is caused by environmental and social factors. One way to improve this situation is by using crop models since they can capture environmental and management interactions. This study aims to assess, first, the gridded weather database (GWD) used as an input in crop modelling. Verifying the feasibility of DailyGridded and NASA/POWER datasets in ORYZA (v3) crop model, using upland rice in the tropical region considering sandy and clay soil conditions. In the second phase, we calibrate and validate two rice crops for the tropical region so their feasibility in studies on tropical region could be checked. In the first chapter, it is observed that both GWD are more reliable only when there is no drought stress, due to uncertainties created by GWD-based rainfall. This error is higher in sandy soil conditions. In the second chapter, two rice crops, BRS Catiana and IRGA 424, are calibrated using data from two trials carried out in Goianira-GO, showing a good agreement in this step. On the validation step, we observe a yield bias as a function of latitude, with a tendency to overestimate results in places nearby the calibration area and underestimate them on locations further north. For those reasons these calibrated crops are not indicated to be used in studies regarding the tropical region.

Key words: Grains, crop simulation models, *Oryza sativa* L., productivity.

¹Orientator: Dr. Alexandre Bryan Heinemann. Embrapa Rice and Beans.

1 INTRODUÇÃO

O arroz (*Oryza sativa* L.) está entre as mais importantes culturas graníferas modernas. Como alimento básico, é responsável por alimentar aproximadamente 3,5 bilhões de pessoas (Muthayya et al., 2014; Statistica 2020). No Brasil, o sistema de produção de arroz pode ser dividido em dois tipos: arroz irrigado e de sequeiro (terras altas).

O arroz irrigado é produzido em dois diferentes ecossistemas: subtropical e tropical. O arroz irrigado subtropical, produzido nos estados de Santa Catarina e Rio Grande do Sul, foi responsável por 76% da safra nacional em 2017/2018, tendo como produtividade média 7,7 Mg ha⁻¹. Já o arroz tropical irrigado, produzido nos estados de Tocantins, Mato Grosso do Sul, Goiás, Maranhão, Ceará, Pernambuco, Sergipe, Alagoas, Piauí, Rio Grande do Norte e Roraima, é responsável por somente 6% da produção nacional, tendo como produtividade média valores inferiores a 5,0 Mg ha⁻¹ (CONAB, 2018).

Os modelos de simulação são uma ferramenta viável para avaliar recursos já existentes. Por meio destes podem ser analisados um grande número de fatores, que estão relacionados à interação planta-ambiente-gestão. Ainda, facilita na tomada de decisão quantificando o risco de produção por meio de uma análise de probabilidade, baseando-se no histórico de uma série de dados climáticos diários e características do solo (Rodríguez-González et al., 2020).

Contudo, conforme os autores supracitados é importante ressaltar que o uso bem sucedido do modelo de cultura é dependente de calibrações adequadas dos modelos. Assim, modelos calibrados com parâmetros de cultivo podem ser úteis na análise e interpretação de cenários futuros devido à possibilidade de modificações que podem ser propostas no manejo da cultura, mudanças climáticas e previsão de rendimento.

Segundo Xavier et al. (2016) devido à baixa densidade de estações meteorológicas na região central do Brasil que englobam a região produtora de arroz tropical irrigado, torna-se necessário o uso de estações virtuais devido à sua praticidade, em que é possível obter dados

interpolados em grade para todas as regiões no Brasil em alta resolução. No entanto, existem incertezas associadas a esses dados, principalmente com a estimativa de precipitação (Mourtzinis et al., 2017).

O objetivo deste trabalho foi verificar a possibilidade de utilização do modelo ORYZA (v3) para estudos na região produtora de arroz irrigado tropical. Também foram avaliados bancos de dados climáticos interpolados, conhecidos como estações virtuais, de modo a avaliar o impacto desta quando utilizadas como input em modelo de simulação de cultura, principalmente na interação dos padrões de precipitação interpolados com diferentes tipos de solo.

2 APLICAÇÕES DE MODELOS DE SIMULAÇÃO DE CULTURA

2.1 AMBIENTES DE POPULAÇÃO ALVO (TPE – “TARGET POPULATION OF ENVIRONMENT”)

Compreender a natureza das interações genótipo x ambiente x manejo, bem como identificar características necessárias para um ideótipo de planta, podem ser tarefas complexas. A identificação de ambientes de população alvo (TPE – “Target population of environment”) pode auxiliar o programa de melhoramento genético na escolha de linhagens, pois, neste caso, primeiro busca-se entender o ambiente para depois buscar o ideótipo para o ambiente estudado, possibilitando um aumento da herdabilidade na seleção, bem como um aumento na eficiência do programa de melhoramento (Hernandez-Segundo et al., 2009). TPE é definido como um conjunto de ambientes (locais x manejo), considerando tanto a sua variabilidade espacial (locais) quanto temporal (épocas e ano do plantio), no qual as cultivares gerados por um programa de melhoramento devem apresentar um bom desempenho (Nyquist, 1991; Cooper et al., 1997).

Os modelos de simulação de cultura começaram a ser mais uma opção para estudos de TPE. Muchow et al. (1996) demonstraram o uso de modelos de simulação de cultura para identificar ambientes em termos de estresse hídrico na cultura do sorgo. No Brasil, Heinemann et al. (2008) caracterizaram padrões de estresses hídricos no estado de Goiás para a cultura do arroz e do milho.

Nos últimos anos, devido aos avanços computacionais e tecnológicos, trabalhos que visam definir TPE com modelos de simulação de cultura aumentaram em quantidade e em abrangência territorial. Heinemann et al. (2015) caracterizaram a região produtora de arroz de sequeiro com base nos padrões de estresses hídricos, abrangendo uma extensa área do território brasileiro (Brasil central). Neste estudo foi possível compreender que selecionar variedades apenas em ambientes ideais e com adaptação ampla pode ser um problema para regiões mais restritivas, que neste caso consideram-se tanto as regiões quanto a época de

plantio. Li et al. (2016) caracterizaram a região produtora de arroz irrigado no sul da Ásia, abrangendo uma área do Paquistão até a Indonésia. Nesse caso foram simuladas nove variedades de arroz em duas condições, com e sem déficit hídrico, de modo a caracterizar a região com base no rendimento e na intensidade de estresse hídrico.

2.2 ANÁLISE ECONÔMICA

O manejo adequado de uma cultura agrícola pode gerar ganhos econômicos ao produtor, isso porque pode gerar reduções em perdas por fatores climáticos devido ao uso de datas e densidade de plantio adequada. Modelos de simulação de cultura, por serem aptos a captar a interação genótipo x ambiente x manejo, podem ser ferramentas utilizadas para nortear produtores na tomada de decisão de modo a obter maiores ganhos econômicos.

Justino et al. (2019) mostraram que é economicamente viável irrigar feijão-comum na época das águas em Goiás por meio de simulações em diversos manejos de irrigação com pivô central, mostrando uma opção interessante para os produtores, uma vez que as águas nos rios estarão em níveis mais altos nessa época, assegurando a estabilidade na produção. Battisti et al. (2020) mostraram que plantios de soja realizados no começo da janela de plantio trazem maior retorno econômico no sistema soja-milho na região central do Brasil.

2.3 LACUNA DE PRODUTIVIDADE (YIELD GAP)

A diferença entre duas produtividades para uma condição específica, considerando tanto a variação temporal quanto espacial, determina a lacuna de produtividade (Yield Gap), bem como os fatores determinantes. Lobell et al. (2009) usaram a produtividade máxima como a definição de produtividade potencial (PP). Bathia et al. (2008) e Battisti et al. (2012) classificaram os níveis de produtividade em potencial (PP), atingível (PA) e real (PR). Em condições irrigadas, sem danos por pragas, doenças e deficiência nutricional, PP é o máximo teórico que o produtor pode atingir, ao passo que em condições de sequeiro é a PA.

Sentelhas et al. (2015) realizaram um estudo do *Yield Gap* da soja nas principais regiões produtoras, mostrando que a principal causa da diferença de produtividade é devida ao déficit hídrico, diferença que chega a valores de 1.6 Mg ha⁻¹ na região sul. Battisti et al. (2018) demonstraram que é possível dobrar a produção atual de soja considerando a

tecnologia disponível atualmente. Santos et al. (2021) também mostraram que é possível dobrar o rendimento da soja através da otimização do manejo atual, de modo a atingir o PA.

2.4 PRODUÇÃO VERDE

Aumentar a produção agrícola mundial reduzindo a poluição é um grande desafio. Um meio de se fazer isso é por meio do uso eficiente do nitrogênio na agricultura. Por ser um macronutriente, este é utilizado em altas quantidades nas lavouras. No entanto, o nitrogênio pode causar danos ambientais, como a contaminação de lençóis freáticos, eutrofização da água doce e poluição atmosférica (Galloway et al., 2003; Reay et al., 2012; Steffen et al., 2015). Algumas dessas poluições podem ser prejudiciais para as culturas agrícolas (Avnery et al., 2011), bem como para seres humanos (Jerrett et al., 2009).

A otimização do uso de fertilizantes nitrogenados pode trazer grandes benefícios ambientais e econômicos. Modelos de simulação de cultura servem como ferramentas para simular o desenvolvimento e a produtividade de culturas agrícolas em função de diferentes manejos de nitrogênio (Jones et al., 2003). Malik et al. (2018) demonstraram que os produtores de milho na região mediterrânea podem reduzir as doses aplicadas de nitrogênio, levando a uma redução na lixiviação de 33 a 53%. Zhang et al. (2018) constataram que o modelo CERES-Rice é uma ferramenta confiável para os produtores de arroz do nordeste da China simularem o manejo de nitrogênio de suas lavouras.

2.5 PROJEÇÕES AGROCLIMÁTICAS E ENOS

Estudos envolvendo projeções climáticas têm se tornado recorrentes nos últimos anos, de modo a saber o impacto de possíveis alterações no clima nos cultivos agrícolas. Os modelos de simulação de cultura podem ser empregados utilizando-se os dados climáticos gerados por essas projeções.

Ramirez-Villegas et al. (2018) mostraram que as mudanças climáticas podem reduzir a produtividade do arroz de sequeiro em até 20% por volta de 2050 em grande parte da região central do Brasil. Martins et al. (2019) avaliaram o potencial impacto das mudanças climáticas no rendimento do milho na região nordeste do Brasil, mostrando que as reduções podem chegar a 60% até o final do século em condições de sequeiro. Abera (2019) relata o

impacto das mudanças climáticas na produção de trigo na região noroeste da Etiópia, tendo encontrado um aumento na produtividade em simulações até 2080 na maioria das condições.

Os modelos também têm sido aplicados de modo a avaliar o impacto do fenômeno ENOS (El Nino Oscilação Sul) nos cultivos agrícolas. No Brasil, Junior & Sentelhas (2019) mostraram o efeito do ENOS no cultivo de soja-milho. Heinemann et al. (2020) obtiveram o efeito do ENOS no cultivo de arroz de sequeiro na região central do Brasil. Silva et al. (2020) constatarem a influência do ENOS nas principais regiões produtoras de café do Brasil. Qian et al. (2020) também observam a influência do ENOS em quatro das principais culturas cultivadas em diversos países ao redor do mundo.

2.6 ORYZA v3

O modelo ORYZA v3 é um modelo de processos biofísicos que simula o crescimento, desenvolvimento e produtividade da cultura de arroz (Li et al., 2017). Desenvolvido para aplicações na pesquisa agrícola, este modelo tem sido utilizado com sucesso na avaliação do desempenho de linhagens de cruzamento em ambientes distintos (Li et al., 2013; Heinemann et al., 2015) e sob diferentes sistemas de manejo de água e nitrogênio (Stone & Heinemann, 2012; Wang et al., 2012; Tayefe, 2013; Li et al., 2015). O modelo ORYZA (v3) é uma versão melhorada do modelo ORYZA2000, com funções adicionais para quantificar os efeitos da deficiência de nitrogênio e hídrica (Irroriya, 2021). Ao contrário do modelo ORYZA2000, a maioria dos parâmetros que descrevem as variedades utilizadas pelo modelo ORYZA (v3) são considerados genéticos, e os efeitos do ambiente na fotossíntese, partição de assimilados, crescimento de órgãos, desenvolvimento da área foliar e absorção de água e nitrogênio foram acoplados (Li et al., 2017).

3 CARACTERÍSTICAS DOS CULTIVARES ESTUDADOS

3.1 BRS CATIANA

O BRS Catiana é um cultivar de arroz desenvolvido pela Embrapa, caracterizada principalmente por sua adaptação ampla e alta produtividade. Embora tenha sido desenvolvida na região tropical, o BRS Catiana pode ser cultivada em toda a região produtora de arroz irrigado, desde o Rio Grande do Sul até Roraima.

Seu ciclo é considerado médio, podendo ter este aumentado em torno de 15 dias quando cultivada nos estados da região sul. Apresenta massa de mil grãos em torno de 28g. Em relação à resistência às doenças, esta possui resistência moderada à Brusone, considerada um dos principais fatores na redução da produtividade na área tropical (Morais et al., 2016). O potencial produtivo do BRS Catiana varia entre 8,8 a 10,8 Mg ha⁻¹ e 9 a 11,5 Mg ha⁻¹ quando cultivada no ambiente subtropical e tropical, respectivamente (Santos et al., 2017).

3.2 BRS PRIMAVERA

O cultivar BRS Primavera é um cultivar de arroz desenvolvido pela Embrapa Arroz e feijão, apresenta ciclo de maturação precoce (~100 dias), variando em função das condições climáticas durante o cultivo (Soares et al., 2001; Soares et al., 2008). O BRS Primavera é indicado para áreas de abertura e áreas de fertilidade baixa ou média, devido a sua tendência de acamamento (Soares et al., 2001). Este cultivar alcançou 4,3 Mg ha⁻¹ com irrigação complementar (Soares et al., 2001).

3.3 IRGA 424

O IRGA 424 é um cultivar de arroz desenvolvido pelo Instituto Rio Grandense de Arroz, lançado no ano de 2007, inicialmente desenvolvido para as regiões mais frias do Rio Grande do Sul (IRGA, 2007). O cultivar destaca-se pelo alto potencial produtivo também na região tropical, alcançando produtividades de 11 Mg ha⁻¹ na região tropical e 13 Mg ha⁻¹ na região subtropical (Santos et al., 2017).

CAPÍTULO 1

THE IMPACT OF GRIDDED WEATHER DATABASE ON SOIL WATER AVAILABILITY IN RICE CROP MODELING¹

Caio Teodoro Menezes²; Derblai Casaroli²; Alexandre Bryan Heinemann³; Vinicius
Cintra Moschetti⁴; Rafael Battisti⁵

¹Capítulo elaborado conforme as normas do periódico científico (Theoretical and Applied Climatology).

²Escola de Agronomia, Universidade Federal de Goiás, Goiânia, GO, Brasil.

³Embrapa Arroz e Feijão, Santo Antônio de Goiás, GO, Brasil.

⁴Jundiaí, SP, Brasil.

⁵Escola de Agronomia, Universidade Federal de Goiás, Goiânia, Go, Brasil.

Abstract

In recent years, there has been an increase in studies suggesting that gridded weather database (GWD) is a suitable source for simulating crop yield. Brazil has low geospatial coverage by measured weather database (MWD). Based on that, this study aimed to compare two different GWD sources, Daily Gridded (DG) and NASA/POWER (NP), on the simulated yield of upland rice (UR) against the MWD input. The GWD and MWD were obtained for seven locations across UR Brazilian region, considering a period ranging from 1984 to 2016. GWD and MWD were used to estimate rice potential (Y_p) and attainable yield (Y_a), in clay soil and sandy soil, using ORYZA (v3) model. DG had the best performance for all variables. GWD-based yields had a reasonable performance. However, DG had a slightly better performance than NP in all conditions, DG-based yields showed RMSE values of 0.57, 0.71 and 0.52 for Y_p and Y_a in clay and sandy soil, whereas NP showed RMSE values of 0.86, 0.91 and 0.64. DG also showed higher R^2 and d values for yields assessed. Both GWD overestimated Y_a , these overestimations in DG-based yield were 3.54, 9.61, and 21.35% for Y_p and Y_a in clay and sandy soil respectively, in NP-based yield were 13.67, 18.45, 29.11%, showing that for both GWD-based yield increased as the soil type texture as well as water storage decreased. As a consequence, we do not recommend the use of precipitation data in daily time-step crop modeling.

Keywords: ORYZA (v3), Daily Gridded, Virtual weather station, NASA/POWER, Crop modeling

4.1 Introduction

Useful and reliable weather datasets are a time-saving tool for crop modeling purposes. The absence of measured weather data (MWD) and a proper spatial resolution are impediments to predicting both, current and future effect of climate on crop yields. Therefore, gridded weather data (GWD) has become a welcomed alternative weather data source for agricultural purposes. GWD has the advantage of complete geospatial cover, thus becoming an option for regions where the MWD has a lower spatial distribution or incomplete data.

There are two main sources of MWD in Brazil, the Brazilian National Institute of Meteorology (INMET), which provides MWD from automatic and conventional weather stations, and the Brazilian Water Agency (ANA), which has a rainfall station network across Brazilian territory. Both sources are available in low spatial resolution (Xavier et al. 2016). Central Brazil, the main region for grains and pulses farming (CONAB 2020), is situated in three river basins: Tocantins, Amazon, and Paraná. MWD resolutions are lower for Amazon and Tocantins river basins when compared with other parts of Brazil (Xavier et al. 2016). Currently, this is the greatest limitation for crop modeling in upland rice region (Heinemann et al. 2008).

Crop model simulation for application and agrometeorological purposes is made easier by GWD. It has been applied worldwide to simulate crop yields (Wart et al. 2013; Ruane et al. 2015; Mourtzinis et al. 2017; Müller et al. 2019). Amongst worldwide available GWD for crop modeling purposes, it can be pointed out the NASA/POWER (NP). This dataset has a $0.5^\circ \times 0.5^\circ$ spatial resolution at a daily temporal resolution comprising most variables used in crop modeling. This dataset is updated weekly with a time series available since 1983.

In Brazil, there is an interpolated weather database denominated Daily Gridded (DG) (Xavier et al. 2016), which provides an agrometeorological daily and monthly grid data with two spatial resolution for the years 1980 until 2017. The highest resolution available – $0.1^\circ \times 0.1^\circ$, contains data for maximum and minimum air temperature, and the lowest resolution – $0.25^\circ \times 0.25^\circ$, contains data for the other variables: reference evapotranspiration, global solar radiation, rainfall, relative humidity, and wind speed. DG has been applied for wide variety of crops, such as soybean (Battisti and Sentelhas 2019; Junior and Sentelhas 2019; Teixeira et al. 2019), sugarcane (Monteiro et al. 2017; Cesconetto et al. 2018; Perin et al. 2019; Paixão et al. 2020), maize (Andrea et al. 2019), and bamboo (Battisti et al. 2019).

Nevertheless, there are still uncertainties related to the accuracy for its application in crop model simulation. GWD has been accurate in applications related to temperature, but uncertain in estimates related to precipitation. Those uncertainties may generate misleading water deficit and crop yield outcomes (Mourtzinis et al. 2017).

For this study, we selected ORYZA (v3) crop model (Li et al. 2017). The model predicts rice growth and yield as influenced by local environmental conditions, agronomic practices, and cultivar traits. Its strong ability to quantify the influence of soil water on rice growth and yield (Bouman and Laar 2006; Feng et al. 2007), allows the evaluation of rice cultivars' response under drought stress (Li et al. 2013). ORYZA (v3) has been used to quantify rice yield gaps at global, national, and regional scales (Boling et al. 2010; Laborte et al. 2012; Espe et al. 2016), to provide a cost-effective method for drought-tolerance screening (Li et al. 2013), and for determining drought-stress profiles for upland rice in Brazil under current (Heinemann et al. 2015) and future climates (Ramirez-Villegas et al. 2018).

Based on the current literature, we hypothesizes that GWD can be used for simulating rice yield using crop growth models in the areas of upland rice. This way, the study aims: (1) to compare measured weather data with two sources of gridded weather data (Daily Gridded and NASA/POWER); and (2) to evaluate the impact of measured and gridded weather data on the potential (Y_p) and attainable (Y_a) in upland rice yield, considering two soil types – clay and sandy.

4.2 Material and methods

4.2.1 Locations and weather databases

The measured weather data was obtained from seven locations (Table 1) across upland rice production region in Brazil. The data for six weather stations were obtained from the Brazilian Meteorological Service (INMET) and one from the Brazilian Agricultural Research Corporation (EMBRAPA). Missing data in the MWD was filled out using the day of year from the climate normal. The percentage of missing data for each weather station is in Table 1. The locations are classified as tropical by Köppen-Geiger method, where Porto Nacional and Altamira are classified as Am climate type, and the other five locations as Aw (Alvares et al. 2013).

Table 1 Brazilian measured weather data (MWD) locations

ID*	Location	State	Latitude (°)	Longitude (°)	Elevation (m ASML)	Weather station	**Missing data (%)
s1	Altamira	PA	-3.21	-52.21	74	INMET	1.68%
s2	Alto Parnaíba	MA	-9.1	-45.93	285	INMET	3.00%
s3	Jatáí	GO	-17.91	-51.71	662	INMET	0.87%
s4	Paracatu	MG	-17.24	-46.88	712	INMET	2.01%
s5	Porto Nacional	TO	-10.71	-48.41	239	INMET	9.10%
s6	Rio Branco	AC	-9.96	-67.8	160	INMET	4.05%
s7	Santo Antônio de Goiás	GO	-16.28	-49.17	823	EMBRAPA	0.95%

*ID - weather station identification; **Percentage of missing data set considering maximum and minimum air temperature, precipitation, and solar radiation from 1984 to 2016

The two gridded weather databases (GWD) and its variables applied in this study are: i) Daily Gridded (Xavier et al. 2016), which has daily variables at $0.1^\circ \times 0.1^\circ$ for maximum and minimum air temperature, and $0.25^\circ \times 0.25^\circ$ spatial resolution for rainfall and solar radiation; and ii) NASA/POWER (National Aeronautics and Space Administration's POWER, 2020) which has daily variables, including maximum and minimum air temperature, rainfall and solar radiation at scale of $0.5^\circ \times 0.5^\circ$ horizontal resolution.

A historical daily weather data of maximum and minimum air temperature, incoming solar radiation ($\text{MJ m}^{-2} \text{ d}^{-1}$), and precipitation (mm d^{-1}) was obtained for the years 1984 until 2016 from both gridded datasets. The solar radiation of measured dataset was estimated by Angstrom-Prescott (Angstrom 1924; Prescott 1940) from sunshine hours because only weather station S7 contains a radiometer (Table 1).

4.2.2 Crop model simulations

The rice crop modeling ORYZA (v3) (Bouman et al. 2001) was used to assess the potential (Y_p) and attainable (Y_a) upland rice yield. ORYZA (v3) operates on a daily time-step; hence, it requires as input daily weather data such as rainfall, global solar radiation, and maximum and minimum air temperature. ORYZA (v3) is a process-based rice simulation model developed for a wide variety of applications in rice research (Bouman and Laar 2006; Li et al. 2013) e.g., puddled or non-puddled, with free or impeded drainage at a given depth in the soil profile. The ‘PADDY’ module is described in detail by Boling et al. (2007). The same study demonstrated that it is suitable for rainfed conditions.

The cultivar crop model parameters were taken from upland rice BRS Primavera cultivar. This is a short-cycle cultivar, with cycle 100 days from emergence to physiological maturity, and it is still used as cultivar check in the upland rice breeding program. Its parameters were obtained from a previous study (Heinemann et al. 2015) and they have been applied in many upland rice crop modeling applications in Brazil (Heinemann et al. 2015; Ramirez-Villegas et al. 2018; Heinemann et al. 2019). For all locations (see Table 1), the simulation start date was set 225 days prior to the sowing date in order to establish realistic soil water profiles and the sowing date was set in November 1st. Seed density was set at 200 seeds m^{-2} . A sandy and a clay soil type were used in the simulation. Classified as oxisol on the American classification system, both are predominant in the study region (Heinemann et al. 2015). Further parameters are described in Table S1.

4.2.3 Statistical analysis

The statistical indices used were mean error (ME), mean absolute error (MAE), root mean square error (RMSE), agreement index (d) (Willmot 1981), Pearson’s correlation coefficient (r), and coefficient of determination (R^2). This was applied to compare minimum e maximum air temperature, rainfall, solar radiation in the crop cycle as well as potential (Y_p) and attainable (Y_a) yield.

The sequence of graphics used in this study were empirical cumulative probability function (ECDF), scatter plot, regression lines, violin plot and line chart.

4.3 Results

4.3.1 Descriptive statistics to measured and gridded weather data

An empirical cumulative probability function (ECDF) was plotted (Fig. 1) to assess the four variables from the datasets in the crop cycle. ECDF for daily solar radiation (Sr) and maximum air temperature (Tmax) in Daily Gridded (DG) data showed a higher similarity to the measured weather data (MWD) than NASA/POWER (NP)

(Fig. 1a and c). NP only exhibits a higher similarity to MWD regarding minimum air temperature (Tmin) (Fig. 1d). Both gridded weather data (GWD) had similar distributions to each other but with a higher degree of distinction to MWD (Fig. 1b). NP underestimates Tmax in the range of 24.5°C to 35.8°C in about 95% of the times, which represents 6% of underestimation in this range; meanwhile DG Tmax data is more similar to MWD for the ECDF (Fig. 1a). NP overestimated Sr in the range of 11 to 32 MJ m⁻² d⁻¹ in about 89% of the cases (Fig. 1d), it represents 5% of overestimation.




Fig. 1 Empirical cumulative probability function (ECDF) plot for maximum and minimum air temperature (Tmax and Tmin) (a and b), Rainfall (c), and solar radiation (RS) (d) for all three datasets, measured weather database (MWD) in purple, and two gridded data (GWD) sources, Daily Gridded in green and NASA/POWER in orange.

*Precipitation was cut off at 60 mm (c) to provide better visual effect.

DG overestimates MWD rainfall in 73% for the cumulative events in the range of 0.1 to 13.36 mm; from 8% to 81% of measured events (Fig. 1c), it represents 84.6% of overestimation in this range. On average, this overestimation is about 163 mm cycle⁻¹. NP overestimates MWD rainfall in 73.7% of cumulative events in the range of 0.1 to 11.8 mm – from 5.4 to 79.1% of measured events (Fig. 1c), which results in a 95% of overestimation in this range. On average, this overestimation is about 160 mm cycle⁻¹. This trend takes place in both GWD from all assessed municipalities (Fig. 2).

In comparison, MWD precipitation starts after about 38% of the cumulative events. From 80 and 79% of the events onwards, for DG and NP, respectively, GWD underestimates extreme rainfall events (Fig. 1c). On average, it represents 27 and 31% of underestimation. This underestimation is about 165 and 196 mm cycle⁻¹ for DG and NP, respectively. DG underestimates total rainfall by 1.6 mm cycle⁻¹ (0.2%), whereas NP underestimates it by 36 mm cycle⁻¹ (4.5%).




Fig. 2 Empirical cumulative probability function (ECDF) plot for all municipalities assessed considering only rainfall, measured weather database (MWD) in purple, and two gridded data (GWD) sources, Daily Gridded in green and NASA/POWER in orange. *Precipitation was cut off at 60 mm (c) to provide better visual effect

Scatter plot with commonly employed indexes were also employed for comparison to other studies. DG data shows superior performance against NP data for all weather variables assessed (Fig. 3). Tmax is the variable

with best agreement and fit to MWD in DG dataset, showing coefficient of determination (R^2), root mean square error (RMSE) and agreement index (d) of 0.77, 1.34, and 0.93 against 0.46, 2.87, and 0.74 from NP, respectively (Fig. 3a and b). NP shows a tendency to underestimate T_{max} , thus exhibiting higher ME value than DG, -1.84 against -0.3, respectively (Fig. 1a and 3b).

T_{min} shows overall lower agreement with MWD from both GWD when compared to T_{max} . In this case, DG also shows better agreement and fit than NP, with R^2 , RMSE and d values of 0.6, 1.19, and 0.86 against 0.47, 1.49, and 0.83 from NP (Fig. 3c and d). Rainfall has the worst performance amongst all variables in both GWD when compared with MWD. DG shows R^2 , RMSE, and d values of 0.42, 10.7, and 0.75 whereas NP showed 0.11, 13.67, and 0.53, respectively.




Fig. 3 Relationship between gridded weather (GWD) and measured data (MWD) for the following variables: minimum and maximum air temperature (a, b, c and d), precipitation (e and f) and solar radiation (g and h), considering two sources of GWD, Daily Gridded (GD) with 1:1 green line (a, c, e and g) and NASA/POWER with 1:1 orange line (b, d, f and h). ME - mean error, MAE - mean absolute error, RMSE - root mean square error, d - agreement index, r - Pearson coefficient, R^2 - coefficient of determination

4.3.2 Crop modeling outputs

All locations are assessed as an aggregate for statistical analysis (Fig. 4 and 5) and each location is assessed individually in Table 2. GWD show a better performance simulating Y_p than Y_a , but NP only exhibited better performance when all locations were aggregated (Table 2). Both GWD-based physiological maturity simulated days showed good agreement, with R^2 of 0.66 and 0.74, and RMSE of 1.93 and 2.85 for DG and NP respectively (Fig. 5).




Fig. 4 Relationship between upland rice yield simulated with MWD (x axis) and GWD (y axis), using two GWD sources, Daily Gridded (DG) with 1:1 green line (a, c and e) and NASA/POWER (NP) with 1:1 orange line (b, d and f) database, for potential (a and b) and attainable yield in clay soil condition (c and d) and attainable yield in sandy soil condition (e and f). ME - mean error, MAE - mean absolute error, RMSE - root mean square error, d - agreement index, r - Pearson coefficient, R^2 - coefficient of determination




Fig. 5 Relationship between upland rice physiological maturity in days simulated with MWD (x axis) and GWD (y axis), using two GWD sources, Daily Gridded (DG) with 1:1 green line (a) and NASA/POWER (NP) with 1:1 orange line (b) database. ME - mean error, MAE - mean absolute error, RMSE - root mean square error, d - agreement index, r - Pearson coefficient, R² - coefficient of determination

Porto Nacional is the location with overall better performance for both GWD, R² of 0.65, 0.59 and 0.61, RMSE 0.29, 0.73 and 0.57 for each DG condition (Yp, Ya clay and Ya sandy) respectively, and R² of 0.17, 0.67 and 0.67 and RMSE of 0.63, 0.79 and 0.60 for each NP condition respectively. The worse agreement in NP Yp condition in relation to Ya condition also strengthens the fact of lower NP agreement in Tmax, Tmin and RS (Fig. 1 and 2) since these variables define Yp. Rio Branco is the city with worse performance in both GWD, except for DG Ya clay soil condition.

Table 2 Mean potential and attainable upland rice yield for both soil conditions simulated by ORYZAv3, using MWD and two GWD sources, Daily Gridded (DG) and NASA/POWER (NP), totalizing 32 crop seasons for seven locations in Brazil

Data	Cond	Site	Yield Mg ha ⁻¹		ME	MAE	RMSE	d	r	R ²
			MWD	GWD						
DG	Yp	Altamira	2.92	3.11	0.19	0.31	0.39	0.75	0.66	0.43
		Alto Parnaíba	3.76	4.05	0.29	0.38	0.44	0.72	0.65	0.42
		Jataí	4.40	5.04	0.63	0.63	0.69	0.65	0.83	0.69
		Paracatu	4.89	4.88	-0.01	0.34	0.60	0.74	0.50	0.25
		Porto Nacional	3.45	3.63	0.18	0.24	0.29	0.84	0.81	0.65
		Rio Branco	3.19	3.00	-0.19	0.25	0.34	0.62	0.41	0.17
		S. A. Goiás	5.04	4.95	-0.09	0.74	0.96	0.63	0.42	0.18
	Ya clay soil	Altamira	2.53	2.87	0.34	0.48	0.64	0.53	0.27	0.07
		Alto Parnaíba	2.15	2.33	0.18	0.45	0.58	0.90	0.83	0.68
		Jataí	3.00	3.69	0.69	0.79	0.91	0.67	0.68	0.46
		Paracatu	2.00	1.89	-0.12	0.50	0.85	0.84	0.71	0.51
		Porto Nacional	2.44	2.92	0.49	0.57	0.73	0.80	0.77	0.59
		Rio Branco	2.87	2.83	-0.04	0.23	0.30	0.73	0.53	0.28
		S. A. Goiás	3.22	3.41	0.19	0.63	0.78	0.74	0.58	0.33
	Ya sandy soil	Altamira	1.73	2.15	0.42	0.48	0.56	0.52	0.40	0.16
		Alto Parnaíba	1.25	1.49	0.24	0.38	0.46	0.82	0.76	0.57
		Jataí	1.69	2.27	0.58	0.59	0.66	0.61	0.74	0.54
		Paracatu	1.09	1.16	0.06	0.28	0.48	0.84	0.71	0.50
		Porto Nacional	1.47	1.93	0.46	0.50	0.57	0.76	0.78	0.61
		Rio Branco	1.84	2.06	0.22	0.31	0.36	0.68	0.60	0.36
		S. A. Goiás	1.75	2.12	0.37	0.45	0.53	0.71	0.69	0.48
NP	Yp	Altamira	2.92	3.22	0.30	0.38	0.47	0.53	0.37	0.13
		Alto Parnaíba	3.76	4.24	0.49	0.53	0.65	0.58	0.48	0.24
		Jataí	4.40	5.37	0.96	1.00	1.06	0.46	0.59	0.34
		Paracatu	4.89	5.51	0.62	0.83	1.02	0.51	0.34	0.11
		Porto Nacional	3.45	3.87	0.42	0.51	0.63	0.55	0.41	0.17
		Rio Branco	3.19	3.50	0.31	0.40	0.53	0.39	-0.05	0.00
		S. A. Goiás	5.04	5.72	0.68	1.09	1.30	0.47	0.19	0.03
	Ya clay soil	Altamira	2.53	2.80	0.27	0.38	0.46	0.82	0.77	0.59
		Alto Parnaíba	2.15	2.37	0.22	0.67	0.87	0.75	0.58	0.33
		Jataí	3.00	3.89	0.89	1.06	1.19	0.63	0.65	0.42
		Paracatu	2.00	2.20	0.20	0.61	0.90	0.84	0.72	0.52
		Porto Nacional	2.44	3.01	0.58	0.63	0.79	0.82	0.82	0.67
		Rio Branco	2.87	3.20	0.33	0.41	0.51	0.48	0.20	0.04
		S. A. Goiás	3.22	4.08	0.87	1.12	1.29	0.58	0.48	0.23
	Ya sandy soil	Altamira	1.73	2.03	0.30	0.32	0.41	0.75	0.79	0.63
		Alto Parnaíba	1.25	1.55	0.30	0.45	0.53	0.76	0.69	0.48
		Jataí	1.69	2.39	0.69	0.76	0.86	0.49	0.50	0.25
		Paracatu	1.09	1.41	0.32	0.50	0.63	0.76	0.67	0.45
		Porto Nacional	1.47	1.95	0.48	0.52	0.60	0.77	0.82	0.67
		Rio Branco	1.84	2.16	0.32	0.39	0.45	0.61	0.52	0.27
		S. A. Goiás	1.75	2.47	0.72	0.77	0.84	0.51	0.57	0.33

Data – datasets, Cond – soil condition, ME - mean error, MAE - mean absolute error, RMSE - root mean square error, d - agreement index, r - Pearson coefficient, R² - coefficient of determination, Yp – potential yield, Ya – attainable yield

4.4 Discussion

4.4.1 Weather variables

This is the first study to evaluate the rainfall distribution pattern created by gridded weather database (GWD) considering its impact on soil condition in crop modeling. These patterns of GWD rainfall are of critical importance, prone to generate mistaken attainable yields. There are studies related to GWD rainfall estimation uncertainties in amount and distribution, such as Ruane et al. (2015), Xavier et al. (2016) and Mourtzinis et al. (2017). Battisti et al. (2019) showed that Daily Gridded (DG) underestimated rainfall by 21.17 mm cycle⁻¹ in the soybean crop, they also found good agreements between DG and MWD for Tmax and Tmin, reporting an r of 0.92 and RMSE of 0.72 for Tmax, and r of 0.87 and RMSE of 1.05 for Tmin.

The RMSE observed in DG rainfall data (Fig. 3) agrees with the ones reported by Xavier et al. (2016) for Amazon and Tocantins river basins, with values of 13.17 and 10.54, respectively. Lower ME values from DG agrees with previous statements, given that the dataset has a lower underestimation of total rainfall than NASA/POWER (NP). Both GWD has a good RS, agreement with MWD, DG has a slightly better agreement, showing R², RMSE, and d of 0.65, 3.09, and 0.9, respectively, against 0.52, 4.09, and 0.84 from NP.

4.4.2 Simulated yield and phenology

Battisti et al. (2019) found a better performance at simulating attainable (Ya) and potential (Yp) yield using DG datasets for simulating soybean crop modeling. In our study, we found that DG has a better performance when simulating Yp and Ya than NP (Table 2, Fig. 4 and 5). Since potential yield depends only on maximum (Tmax) and minimum (Tmin) air temperature, as well as solar radiation (Sr), DG also showed better agreement than NP. Because Ya has rainfall as input, the most uncertain variable, it is expected a reduction in its agreement to MWD ones.

The ORYZA (v3) crop model phenology is defined by air temperature and photoperiod (Bouman et al. 2001). Errors in GWD-based simulations for these variables are low enough not to cause high-magnitude errors for this estimation (Fig. 2 and 5). In this case the phenology is the same for all soil conditions, since drought don't change rice phenology in the simulation.

Weather variables play an important role in growth and crop yield (Sridevi and Chellamuthu 2015). Tropical rice has an optimal temperature range between 25 and 35°C. High temperatures, above 35°C (Hussain et al. 2019) for most cultivars or 36.6°C for the studied cultivar (Heinemann et al. 2015), have a negative impact on growth and pollination, leading to spikelet sterility. Likewise, low temperature, below 25°C, may cause delays in phenological stages (Hussain et al. 2019). Both situations decrease productivity.

4.4.3 Soil water availability effect on attainable yield

In our study, it is observed that GWD-based simulations have a closer result to Y_p , meanwhile GWD overestimates Y_a , when compared to MWD-based simulations (Fig. 4). GWD overestimates Y_a as a consequence of misestimating the daily rainfall amount and distribution (Fig. 1 and 3) (Wart et al. 2013; Mourtzinis et al. 2015; Xavier et al. 2016).

In general, this overestimation took place mainly in the distribution range of 0.1 to 12 mm, which accounts for around of 70% of the times observed (Fig. 3). On the other hand, extreme rainfall events ($> 50 \text{ mm d}^{-1}$) are underestimated by GWD (Fig. 1, 2 and 3). Therefore, gridded weather data ends up simulating an irrigation-sheet-like rainfall pattern in the range of 0.1 to 12mm, an overestimation by GWD based rainfall. This rainfall pattern is incompatible with measured weather data, resulting in increased productivity for all soils. As a consequence of soil characteristics, its overestimations increase as soil textures become coarser. It is possible to visualize this difference in the cumulative evapotranspiration (ETCUM) (Fig. 6).

Both regression lines from GWD and MWD showed that in both soil conditions, GWD overestimates MWD ETCUM, with higher overestimations in sandy soil condition (Fig. 4e and f). It is noticeable that cumulative evapotranspiration (ETCUM) from GWD tends to have increased overestimation in sandy soils, even though the accumulated rain is similar (Fig. 6e, f, i, and j). The violinplot (Fig. 4i and j) shows MWD ETCUM values ranging at lower values than GWD ones. The opposite pattern is seen in accumulated drainage (DRAIN) (Fig. 6k and l). In this regard, GWD DRAIN values are ranging in values lower than MWD ones, showing that irrigation-sheet-like rain pattern generated by GWD reduces total drainage, a consequence of an underestimation of high-precipitation events and an overestimation of precipitation values in the range of 0.1 to 12 mm.




Fig. 6 Regression lines (a, b, c, d, e, f, g and h) and violin plots (I, j, k and l) assessing both clay and soil conditions for the following datasets and variables: Daily Gridded (DG) in green, NASA/POWER (NP) in orange and Measured Weather Database (MWD) in purple. TMAXC - Accumulative maximum air temperature from emergence (a and b), PARCUM - Photosynthetic radiation from emergence to maturity (c and d), ETCUM - Accumulative actual evapotranspiration in main field (e, f, I and j), DRAIN - Accumulative drainage in main field (g, h, k and l)

According to Bouman et al. (2001), when drought occurs in the ORYZA (v3) crop model, solar radiation absorption is negatively affected due to leaf rolling, reduced leaf expansion rate, and changed assimilate partitioning. Hence the reduced PARCUM in sandy soil conditions. Li et al. (2017) stated that photosynthesis for non-drought-tolerant cultivars linearly decreases as the soil water content decreases, the yield for drought-tolerant cultivars would be mildly impacted in a mild drought.

It is observed that DG and NP-based crop simulations overestimation YP in 3.5% and 13.7%, respectively. Meanwhile, for Ya in clay soil condition, there was 9.6% and 18.4% yield overestimation, with 67% and 75% of total events overestimating MWD, for DG and NP respectively. The widest differences between GWD and MWD-based simulations are observed for Ya in sandy soil condition, where there are 21.3% and

29.1% yield overestimation, with 84% and 85% of total events overestimating MWD for DG and NP datasets. These overestimation percentages are based on the mean errors and the average yield (Table 2, Fig. 4 and 7).

In Yp conditions, NP-based simulations overestimate MWD-based simulations in a wider productivity range, from 2.5 to 6.5 Mg ha⁻¹ (Fig. 7). NP overestimates MWD in about 20% of the simulations before DG, overestimating MWD ones in the range of 2.5 to 6.5 Mg ha⁻¹, whereas DG overestimates in the range of 3 to 5 Mg ha⁻¹ Fig. 7a. In Ya clay soil condition, both GWD overestimate MWD around the same range, from 2 to 4 Mg ha⁻¹ Fig. 7b. In Ya sandy soil condition as in occurred before, both GWD overestimate in about the same range of conditions, ranging from 1 to about 2.5 Mg ha⁻¹ Fig. 7c. It is noteworthy to point out that the graph curve is further away in relation to the last case (Fig. 7a, b, and c). Overestimation worsens as soil water storage capacity decreases.




Fig. 7 Empirical cumulative probability function (ECDF) (a, b and c) and line chart (d, e and f) showing the performance of measured data (MWD) in purple and gridded data (GWD), Daily Gridded (DG) in green and NASA/POWER (NP) in orange, considering three conditions, potential yield (Yp) (a and d), attainable yield in clay soil (b and e) and attainable yield in sandy soil (c and f). *line charts show the average yield values considering all locations along 32 crop seasons, whereas ECDF considers all values

In clay soil condition, only two DG GWD municipalities show higher values of attainable yield than MWD (Paracatu and Rio Branco), NP did not show any underestimation at clay soil condition, whereas both GWD did not show underestimation at sandy soil conditions (Table 2), which are less prone to happen. We also divided the 32 years' time series in two in order to assess the temporal impact on crop model (Table 3), its possible to notice that DG overestimate even more for all conditions in the second part of time series, in this period DG used more rain gauge in interpolations than the first period assessed (Xavier et al. 2016). NP overestimated more in the second period for Yp condition and underestimated for Ya in sandy soil condition (Table 3).

Table 3 Attainable and potential yield (Ya and Yp) overestimation by GWD for both soil conditions simulated by ORYZAv3, using MWD and two GWD sources, Daily Gridded (DG) and NASA/POWER (NP). 32 crop seasons were assessed, as well as the first half (1984-1999) and the second half (2000-2015).

Time Series	Condition	Datasets Yield Mg ha ⁻¹			Datasets Overestimation	
		MWD	DG	NP	DG	NP
1984 – 2015	Yp	3.95	4.09	4.49	3.54	13.67
	Ya clay soil	2.60	2.85	3.08	9.61	18.45
	Ya sandy soil	1.55	1.88	1.99	21.35	29.11
1984 – 1999	Yp	4.02	4.09	4.46	1.74	10.95
	Ya clay soil	2.71	2.87	3.22	5.90	18.82
	Ya sandy soil	1.60	1.93	2.13	20.63	33.13
2000 – 2015	Yp	3.87	4.08	4.51	5.43	16.54
	Ya clay soil	2.48	2.82	2.93	13.71	18.15
	Ya sandy soil	1.48	1.82	1.85	22.97	25.00

MWD – Measured weather database; DG – Daily Gridded; NP – NASA/POWER; ME – Mean error

Similar yield trends are observed for all simulated conditions along 32 seasons (Fig. 7d, e, and f). Soybean simulations by Battisti et al. (2019), based on GWD and MWD, also found the same trends along sowing years in simulating attainable yield. These similar systematic errors may indicate model sensitivity on capturing climate effects on yield variability (Pirtiojja et al. 2015).

Ya was overestimated by the model running the GWD, similar to what has been found in other studies. Battisti et al. (2019), simulations of soybean yield with DG dataset, found the ME for Yp and Ya of 69 kg ha⁻¹ and 178 kg ha⁻¹, respectively. It was concluded that the DG data estimates soybean yield within acceptable error boundaries. However, this study used a soil with 0.162 cm³ cm⁻³ soil water storage, classified as high soil water storage (Jensen and Allen 2016), and set the root growth to hit maximum values of 120 cm, possibly smoothing the errors related to GWD precipitation rain pattern. Van Wart et al. (2015) found a ME for Ya of about 10% on

maize, wheat, and rice simulations in several countries using the NP dataset. There is no study that analyzed the interaction between GWD rain pattern and soil water storage.

4.4.4 Limitations and future work

Although current findings point out an acceptable correspondence between GWD and MWD on crop model for rice, several limitations must be considered. GWD are known to be less accurate in regions where MWD are less available or do not exist (Wart et al. 2013; Xavier et al. 2016). These uncertainties increase as virtual weather stations get further away from measured weather stations (Van Wart et al. 2015). Second, GWD does not estimate daily MWD rainfall distribution with accuracy. Therefore, we suggest caution when using GWD as an input in crop models, especially in sandy soils, since they tend to have lower water storage, which is prone to worse attainable yield overestimation in upland rice. We assume this may happen in other crops as well, but there are no studies supporting this hypothesis. Third, studies comparing crop performance among different regions with distinct soil profiles may generate misleading results. Lastly, according to Li et al. (2017), ORYZA (v3) crop model has coupled nitrogen uptake with water uptake, hence affecting nitrogen studies with ORYZA (v3) that relies on GWD.

4.5 Conclusion

This study has shown that both Daily Gridded and NASA/POWER may be suitable weather data sources for simulating upland rice (UR) potential yield (Y_p). Despite this accuracy, attainable yield (Y_a) modeling should be avoided, especially short-cycle cultures on daily-step model simulations. These uncertainties are even higher at sandy soil conditions since it has lower soil water storage. Further studies using the GWD dataset for other crops in a wide range of locations and soils could improve its estimation capabilities while defining its acceptable use range.

Acknowledgments

The authors would like to thank: The National Council for Scientific and Technological Development (CNPq) for the support to this study through a research fellowship for the first author. The authors declare no conflicts of interest.

4.6 References

Alvares CA, Stape JL, Sentelhas PC, de Moraes Gonçalves JL, Sparovek G (2013) Köppen's climate classification map for Brazil. *Meteorol Z* 22:711–728

- Andrea MSC, Dallacort R, Barbieri JD, Tieppo RC (2019) Impactos de Predições Climáticas Futuras sobre o Milho de Segunda Safra em Agrossistema em Região de Transição de Bioma no Estado do Mato Grosso. *Rev bras meteorol* [online]. 34:335–347. <https://doi.org/10.1590/0102-77863340241>
- Angstrom A (1924) Solar and terrestrial radiation. *Q J R Meteorol Soc* 50: 121–125. <https://doi.org/10.1002/qj.49705021008>
- Battisti R, Bender FD, Sentelhas PC (2019) Assessment of different gridded weather data for soybean yield simulations in Brazil. *Theor Appl Climatol*. 135:237–247. <https://doi.org/10.1007/s00704-018-2383-y>
- Battisti R, Casaroli D, Júnior JA, Evangelista AWP, Mesquita M (2019) Agro-climatic zoning of bamboo as a support for crop farming in the central-north region of the Brazilian Savannah. *Pesqui Agropecu Trop* 49. <https://doi.org/10.1590/1983-40632019v4952794>
- Battisti R, Sentelhas PC (2019) Characterizing Brazilian soybean-growing regions by water deficit patterns. *Field Crop Res* 240:95–105. <https://doi.org/10.1016/j.fcr.2019.06.007>
- Bouman BAM, Kropff MJ, Tuong TP, Wopereis MCS, Ten Berge HFM, Van Laar HH (2001) *ORYZA2000: Modeling Lowland Rice*. Los Baños (Philippines): International Rice Research Institute, and Wageningen, Netherlands: Wageningen University and Research Centre. 235 pp
- Bouman BAM, Van Laar HH (2006) Description and evaluation of rice growth model ORYZA 2000 under nitrogen limited conditions. *Agric Syst* 87:249–273. <https://doi.org/10.1016/j.agsy.2004.09.011>
- Boling AA, Bouman BAM, Tuong TP, Murty MVR, Jatmiko SY (2007) Modelling the effect of groundwater depth on yield-increasing interventions in rainfed lowland rice in Central Java, Indonesia. *Agric Syst* 92:115–139. <https://doi.org/10.1016/j.agsy.2006.05.003>
- Boling AA, Tuong TP, Keulen H, Bouman BAM, Suganda H, Spiertz JHJ (2010) Yield gap of rainfed rice in farmers' fields in Central Java, Indonesia. *Agric Syst* 103:307–315. <https://doi.org/10.1016/j.agsy.2010.02.003>
- Cesconetto LB, Pruski FF, Rodriguez RDG, Marcatti GE (2019) Potentiality of sugarcane expansion under irrigation conditions considering natural and potential water availability. *Agric Water Manag* 203:162–171. <https://doi.org/10.1016/j.agwat.2018.03.008>
- CONAB (2019) Survey of crop season: rice. <http://www.conab.gov.br/conteudos.php?a=1253&>. Accessed 20 Jun 2019
- Espe MB, Cassman KG, Yang H, Guilpart N, Grassini P, Wart J, Anders M, Beighley D, Harrell D, Linscombe S, McKenzie K, Mutters R, Wilson LT, Linquist BA (2016) Yield gap analysis of US rice production systems shows opportunities for improvement. *Field Crops Res* 196:276–283. <https://doi.org/10.1016/j.fcr.2016.07.011>
- Feng L, Bouman B, Tuong T, Cabangon R, Li Y, Lu G, Feng Y (2007) Exploring options to grow rice using less water in northern China using a modelling approach I. Field experiments and model evaluation. *Agric Water Manag* 88(1–3):1–13. <https://doi.org/10.1016/j.agwat.2006.10.006>

- Heinemann AB, Dingkuhn M, Luquet D, Combres J, Chapman S (2007) Characterization of drought stress environments for upland rice and maize in central Brazil. *Euphytica* 162(3):395-410. <https://doi.org/10.1007/s10681-007-9579-z>
- Heinemann AB, Barrios-Perez C, Ramirez-Villegas J, Arango-Londoño D, Bonilla-Findji O, Medeiros JC, Jarvis A (2015) Variation and impact of drought-stress patterns across upland rice target population of environments in Brazil. *J Exp Bot* 66:3625- 3638. <https://doi.org/10.1093/jxb/erv126>
- Heinemann AB, Ramirez-Villegas J, Rebolledo MC, Neto GMFC, Castro AP (2019) Upland rice breeding led to increased drought sensitivity in Brazil. *F Crop Res* 231:57-67. <https://doi.org/10.1016/j.fcr.2018.11.009>
- Heinemann AB, Ramirez-villegas J, Stone LF; Silva AP, Matta DH, Diaz MEP (2020) The impact of El Niño Southern Oscillation on cropping season rainfall variability across Central Brazil. *Int J Climatol* 1:1-22. <https://doi.org/10.1002/joc.6684/joc.6684>
- Hussain S, Khaliq A, Ali B, Hussain S (2019) Temperature extremes: impact on rice growth and development. In: *Plant abiotic stress tolerance agronomic, molecular and biotechnological approaches*. Springer, Berlin, pp 153-171. <https://doi.org/10.9787/PBB.2018.6.1.1>
- INMET. The Brazilian National Institute of Meteorology (2019) Available at: <<http://www.inmet.gov.br/portal/>> Accessed 20 may 2019
- Laborte AG, de Bie KC, Smaling EM, Moya PF, Boling AA, Van Ittersum MK (2012) Rice yields and yield gaps in Southeast Asia: past trends and future outlook. *Eur J Agron* 36:9-20. <https://doi.org/10.1016/j.eja.2011.08.005>
- Li T, Raman AK, Marcaida M III, Kumar A, Angeles O, Radanielson M (2013) Simulation of genotype performances across a larger number of environments for rice breeding using ORYZA2000. *Field Crops Res* 149:312–321. <https://doi.org/10.1016/j.fcr.2013.05.006>
- Li T, Angeles O, Marcaida M III, Manalo E, Manalili MP, Radanielson A, Mohanty S (2017) From ORYZA2000 to ORYZA (v3): an improved simulation model for rice in drought and nitrogen-deficient environments. *Agric For Meteorol* 237:246–256. <https://doi.org/10.1016/j.agrformet.2017.02.025>
- Monteiro LA, Sentelhas PC, Pedra GU (2018) Assessment of NASA/ POWER satellite-based weather system for Brazilian conditions and its impact on sugarcane yield simulation. *Int J Climatol* 38: 1571–1581. <https://doi.org/10.1002/joc.5282>
- Mourtzinis S, Edreira JIR, Conley SP, Grassini P (2017) From grid to field: assessing quality of gridded weather data for agricultural applications. *Eur J Agron* 82:163–172. <https://doi.org/10.1016/j.eja.2016.10.013>
- Paixão JS, Casaroli D, Battisti R, Evangelista AWP, Alves Júnior J, Mesquita M (2020) Characterizing Sugarcane Production Areas Using Actual Yield and Edaphoclimatic Condition Data for the State of Goiás, Brazil. *Int J Plant Prod* 14:511–520. <https://doi.org/10.1007/s42106-020-00101-9>
- Perin V, Sentelhas PC, Dias HB, Santos EA (2019) Sugarcane irrigation potential in Northwestern São Paulo, Brazil, by integrating Agrometeorological and GIS tools. *Agric Water Manag* 220:50–58. <https://doi.org/10.1016/j.agwat.2019.04.012>

- Pirttioja N, Carter TR, Fronzek S, et al (2015) Temperature and precipitation effects on wheat yield across a European transect: a crop model ensemble analysis using impact response surfaces. *Clim Res* 65:87–105. <https://doi.org/10.3354/cr01322>
- Prescott JA (1940) Evaporation from a water surface in relation to solar radiation. *Trans Roy Soc Sci Austr* 64:114–118. <https://doi.org/10.1155/2013/168048>
- Ramirez-Villegas J, Heinemann AB, Pereira de Castro A, Breseghello F, Navarro-Racines C, Li T, Rebolledo MC, Challinor AJ (2018) Breeding implications of drought stress under future climate for upland rice in Brazil. *Glob Chang Biol* 24:2035–2050. <https://doi.org/10.1111/gcb.14071>
- Ruane AC, Goldberg R, Chrysanthacopoulos J (2015) Climate forcing datasets for agricultural modeling: merged products for gap-filling and historical climate series estimation. *Agric For Meteorol* 200: 233–248. <https://doi.org/10.1016/j.agrformet.2014.09.016>
- Sparks A (2018) nasapower: A NASA POWER Global Meteorology, Surface Solar Energy and Climatology Data Client for R. *J Open Source Softw* 3(30):1035. <https://doi.org/10.21105/joss.01035>
- Sridevi V, Chellamuthu V (2015) Impact of weather on rice-a review. *Int J Appl Res* 1:825–831
- Teixeira WR, Battisti R, Sentelhas PC, Moraes MF, Oliveira Junior A (2019) Uncertainty assessment of soya bean yield gaps using DSSAT-CSM-CROPGRO-Soybean calibrated by cultivar maturity groups. *J Agron Crop Sci* 205:533–544. <https://doi.org/10.1111/jac.12343>
- van Wart J, Grassini P, Cassman KG (2013) Impact of derived global weather data on simulated crop yields. *Glob Chang Biol* 19:3822– 3834. <https://doi.org/10.1111/gcb.12302>
- van Wart J, Grassini P, Yang H, Claessens L, Jarvis A, Cassman KG (2015) Creating long-term weather data from thin air for crop simulation modeling. *Agr Forest Meteorol* 209-210:49–58. <https://doi.org/10.1016/j.agrformet.2015.02.020>
- Willmott CJ (1981) On the validation of models. *Phys Geogr* 2:184–194
- Xavier AC, King CW, Scanlon BR (2015) Daily gridded meteorological variables in Brazil (1980–2013). *Int J Climatol* 36(6):2644–2659. <https://doi.org/10.1002/joc.4518>

CAPÍTULO 2

PARAMETRIZAÇÃO E VALIDAÇÃO DO MODELO ORYZAv3 PARA DOIS CULTIVARES DE ARROZ TROPICAL IRRIGADO ¹

Caio Teodoro Menezes²; Alexandre Bryan Heinemann³

¹Capítulo elaborado conforme as normas do periódico científico (Revista Brasileira de Ciências Agrárias).

²Escola de Agronomia, Universidade Federal de Goiás, Goiânia, GO, Brasil.

³Embrapa Arroz e Feijão, Santo Antônio de Goiás, GO, Brasil.

5 Parametrização e validação do modelo ORYZAv3 para dois cultivares de arroz irrigado tropical

Caio Teodoro Menezes; Alexandre Bryan Heinemann

Resumo: Objetivou-se parametrizar e validar o modelo ORYZA (v3) para a região produtora de arroz irrigado tropical utilizando o BRS Catiana e IRGA 424 como cultivares. Inicialmente verificou-se a sensibilidade das duas cultivares ao fotoperíodo pelo método de Fukay. A calibração da fenologia foi feita com ensaios de Goianira-GO e Lagoa da Confusão-TO a fim de se obter melhor ajuste na área tropical, ao passo que a parametrização do particionamento e área foliar foram realizados apenas com ensaios realizados em Goianira-GO. Obteve-se que não há sensibilidade ao fotoperíodo para ambos os cultivares na região tropical, avaliando ensaios de Goiás e Roraima. Ambos os cultivares apresentaram desempenho satisfatório na etapa de parametrização. Entretanto, este desempenho não repercutiu em estados mais ao norte do ponto de calibração, principalmente no estado de Roraima na etapa de validação, gerando um viés de comportamento do modelo em função da latitude, com subestimativa de produtividade em latitudes mais próximas da linha do Equador (Roraima) e superestimativa em latitudes mais próximas do Trópico de Capricórnio. Este padrão ocorreu para os dois cultivares. A amplitude dos valores simulados foi maior próxima à localidade de calibração, indicando uma maior sensibilidade do modelo em regiões próximas a calibração.

Palavras-Chave: ORYZA; modelos de simulação; arroz irrigado.

Calibration and validation of the ORYZAv3 model for two tropical irrigated rice cultivars

Abstract: The aim of this study was to calibrate and validate ORYZA (v3) crop model for tropical irrigated rice using the cultivars BRS Catiana and IRGA 424. First, we verified there is no photoperiod sensitivity for both crops in tropical region, considering trials in Goiás and Roraima. Phenology calibration was made using trials carried out in Goianira-GO and Lagoa da Confusão-TO to get a better fit for the tropical area. Crop biomass and leaf area index calibration was done considering only trials carried out in Goianira-GO. Both crops showed reasonable performance in calibration step. Nevertheless, it did not perform well on validation step, showing a bias as a function of latitude, in which further north latitudes yield simulations showed a tendency to underestimate measured ones, whereas lower latitudes showed a tendency to overestimate. This biased pattern occurred in both crops. The simulated yield range was higher near to calibration location, showing more crop sensibility in locations near the calibration. Therefore, it's not safe to use only one calibration for all tropical irrigated rice region.

Key words: ORYZA; crop model; irrigated rice.

5.1 INTRODUÇÃO

O arroz (*Oryza sativa* L.) é um dos alimentos básicos mais importantes do mundo, responsável pela alimentação de mais da metade da população global (Fan et al., 2016). O aumento na produtividade de arroz deve ser um objetivo a ser perseguido a fim de aumentar a

segurança alimentar. Ganhos de produtividade provenientes de fatores genéticos e da aplicação de tecnologia no manejo têm contribuído significativamente para aumentar a produção do arroz no Brasil e no mundo nas últimas décadas (Gregory & George, 2011; Moraes et al., 2016).

Para garantir a segurança alimentar e a logística de abastecimento da população, o Brasil não pode depender somente da produção de arroz no ecossistema subtropical, localizado no extremo sul do país. Um exemplo dessa vulnerabilidade é o efeito deletério que o fenômeno “El Niño” causou sobre a produtividade do arroz subtropical nas safras de 1982/1983, 1997/1998 e 2015/2016 no Rio Grande do Sul por excesso de chuva (Carmona, 2001; Arsego et al., 2020). Em relação à logística do abastecimento de arroz para as regiões Centro-Oeste, Norte e Nordeste, é importante ressaltar que este deve se dar por meio do aumento da produtividade da cultura e consequente fortalecimento da indústria de beneficiamento do arroz localizada nessa região. Logo, o aprimoramento da produtividade do arroz irrigado tropical é estratégico para a segurança alimentar dessas regiões.

No ambiente tropical, o arroz apresenta menor produtividade em relação ao ambiente subtropical devido aos riscos agroclimáticos serem mais intensos. Parte desse risco agroclimático está relacionado com a adoção de cultivares não adaptados ao ambiente tropical. Identificar linhagens promissoras e adaptadas a um específico ambiente tropical é um desafio que demanda esforço contínuo dos melhoristas. Mesmo assim, há um considerável progresso realizado pelo programa de melhoramento genético no desenvolvimento de linhagens com alto potencial produtivo e tolerantes/resistentes a múltiplos estresses abióticos e bióticos (Magalhães Júnior et al., 2017; Moraes et al., 2016).

Visando gerar mais eficiência nestes estudos de melhoramento, modelos de simulação do crescimento, desenvolvimento e produtividade são ferramentas úteis para extrapolar resultados de experimentos de campo. Tais modelos permitem o exame do efeito de diferentes práticas de manejo em diferentes épocas e ambientes, pois tem a capacidade de representar complexas interações entre genótipo x ambiente (condições edafoclimáticas) x manejo (data de plantio, densidade etc.) (Amiri et al., 2011). Logo, quando adequadamente parametrizados e validados, modelos de simulação de cultura se tornam uma rápida alternativa para manejos que possam requerer o uso de tecnologias avançadas para produção agrícola (Saseendran et al., 2008).

Dos modelos disponíveis atualmente destacam-se CERES-Rice (Jones et al., 2003), e ORYZA (v3) (Li et al., 2017). Para a cultura do arroz, o modelo de simulação ORYZA (v3) tem sido amplamente utilizado para prever o crescimento do arroz e a produtividade de grãos (Heinemann et al., 2015; Li et al., 2016; Ramirez-Villegas et al., 2018; Heinemann et al., 2020). Desta forma, assume-se que o modelo ORYZA (v3) é capaz de simular o desenvolvimento e rendimento do arroz irrigado tropical no Brasil.

Tendo em vista a importância de um meio de predição da produção para a região de arroz irrigado tropical, o objetivo deste estudo foi parametrizar e validar o modelo ORYZA (v3) para dois cultivares presentes em ambiente tropical, de modo a otimizar ao máximo a sua capacidade preditiva para toda a região de arroz irrigado tropical, permitindo o seu uso em projetos de segurança alimentar no Brasil.

5.2 MATERIAL E MÉTODOS

5.2.1 Experimentos de campo

Foram selecionadas os cultivares BRS Catiana e IRGA 424. A BRS Catiana é um cultivar de ciclo médio, com alto potencial produtivo, lançada em 2006 pela EMBRAPA (Rangel et al., 2019). O IRGA 424 foi desenvolvido pelo Instituto Rio-Grandense do Arroz (IRGA), é um cultivar de ciclo médio, inicialmente desenvolvido para regiões frias, no entanto esse cultivar apresenta bom desempenho em regiões tropicais também (Santos et al, 2017).

Para a parametrização dos cultivares BRS Catiana e IRGA 424 foram utilizados um conjunto de experimentos já realizados em campos experimentais de arroz irrigado da Embrapa (Goianira, GO, lat = -16.41, long = -49,38) Santos et al. (2017). Esses experimentos possuem dados de desenvolvimento fenológico, dinâmica de biomassa (massa seca total, massa seca de folhas verdes, de folhas mortas, de caule e panícula), dinâmica da área foliar e dados climáticos diários de precipitação, temperatura máxima e mínima, e radiação global durante os períodos de experimento.

5.2.2 ORYZA (v3)

Informações detalhadas sobre o ORYZA (v3) estão descritos em Bouman et al. (2001). O modelo assume que o arroz não sofrerá danos por doenças, pragas e plantas daninhas,

consequentemente o modelo não considera redução no rendimento devido a esses fatores. Ele utiliza equações matemáticas empíricas e fisiológicas para descrever a fisiologia, fenologia e crescimento da planta.

Os dados climáticos de entrada do modelo incluem radiação solar, temperatura máxima e mínima, pressão de vapor, velocidade do vento e precipitação durante o período de cultivo. Os parâmetros do modelo incluem desenvolvimento fenológico e vários outros relacionados ao processo de crescimento da cultura, no entanto, muitos podem ser valores fixos (padrões). De forma geral, os valores que não são fixos, são aqueles relacionados às características da cultura, como taxas de desenvolvimento e particionamento de assimilados, taxa de crescimento de folhas, área específica de folha, taxa de senescência de folha e a taxa de armazenamento.

O ORYZA (v3) segue um esquema de cálculo diário das taxas de produção de matéria seca e taxas de desenvolvimento fenológico. Integrando todos esses processos ao longo do tempo, a produção de matéria seca é simulada por todo o período de cultivo. A taxa total de absorção de CO_2 é calculada pela radiação incidente, temperatura e índice de área foliar. Após o cálculo da taxa diária de absorção de CO_2 por várias sub-rotinas descritas por Bouman et al. (2001) é subtraída a parte que é gasta na respiração, obtendo-se o ganho líquido diário de matéria seca em quilogramas.

Essa matéria seca é particionada entre as diversas partes da planta. Para a parte aérea, a matéria seca acumulada é distribuída para colmos, folhas e panícula, em função do estágio de desenvolvimento fenológico, este por sua vez é regido por temperatura máxima, temperatura mínima e fotoperíodo (quando há sensibilidade). A área foliar aumenta exponencialmente em função do período térmico enquanto o dossel não está fechado, então a área foliar cresce linearmente e é calculada pelo produto do aumento no peso foliar e a área específica foliar.

Dados climáticos e de solo

Para elaborar a base de dados históricos climáticos diários, isto é, precipitação, temperatura máxima e mínima do ar e radiação global, dados de entrada do modelo de simulação da cultura do arroz, foram utilizadas a base de dados climáticos da EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária), INMET (Instituto Nacional de Meteorologia, 2020) e estações virtuais da NASA/POWER (National Aeronautics and Space Administration's Power, 2020) (Tabela 1).

Tabela 1. Localidades dos ensaios de valor de cultivo e uso (VCU)

Localização	State	Latitude (°)	Longitude (°)	Altitude (m ASML)	Estação meteorológica	Número de Ensaios – CAT/IRGA
Flores de Goiás	GO	-14,43	-47,04	434	NASA/POWER	4/5
Goianira	GO	-16,50	-49,42	749	EMBRAPA	13/16
Luiz Alves	GO	-13,15	-50,56	354	NASA/POWER	1/1
Itapecuru Mirim	MA	-3,39	-44,36	35	NASA/POWER	1/0
São Mateus	MA	-4,04	-44,46	41	NASA/POWER	1/0
Buriti dos Lopes	PI	-3,17	-41,87	16	NASA/POWER	2/2
Teresina	PI	-5,03	-42,80	72	EMBRAPA	2/2
Campos dos Goytacazes	RJ	-21,75	-41,32	11	NASA/POWER	1/1
Canta	RR	-2,62	-60,6	285	NASA/POWER	19/16
Formoso do Araguaia	TO	-11,88	-49,6	240	INMET	1/1
Lagoa da Confusão	TO	-10,82	-49,84	200	INMET	3/5

Estações meteorológicas observadas (EMBRAPA e INMET) e virtuais próximas aos ensaios de VCU da BRS Catiana e IRGA 424 em diferentes regiões

A validação foi realizada ao comparar o desempenho dos ensaios de VCU com as simulações considerando séries históricas de 36 anos, utilizando dados provenientes das estações virtuais DailyGridded (Xavier et al., 2016). Neste caso, a janela de plantio foi baseada na janela de plantio de cada região. Essas janelas de plantio, bem como práticas de manejo nas diferentes regiões de cultivo do arroz tropical irrigado, foram obtidas de agricultores, extensionistas e consultores das respectivas regiões de produção. As épocas de plantio para cada região estão descritas na Tabela 3 (Anexo). Foi assumido o valor de 400 plantas por m². Para as simulações, houve irrigação plena em todo o ciclo, isto é, sem penalidade por déficit hídrico.

Os principais tipos de solos das regiões de estudo, baseados na classificação Americana (textura), foram selecionados da base brasileira de dados de solos (RADAMBRASIL, 1983) e de análises obtidas pelo Departamento de Solos da Escola de Agronomia da Universidade Federal de Goiás (UFG). As propriedades hidrológicas dos diferentes tipos de solos foram obtidas por equações de pedotransferência descritas em Medrado & Lima (2014).

5.2.3 Parametrização e validação

Após a organização dos dados observados, foram calibrados os coeficientes fenológicos por meio de um algoritmo genético em R desenvolvido na Embrapa. Este algoritmo calcula o período térmico para cada fase fenológica do arroz: da emergência a V6, de V6 a R1, de R1 a R4 e de R4 a R9, simulando taxas de desenvolvimento para cada uma delas considerando as temperaturas cardinais. Neste caso, as temperaturas cardinais foram fixadas em: temperatura basal = 12°C; temperatura ótima = 30°C; e temperatura máxima = 42°C. A média das taxas (DVS) dos experimentos para cada fase fenológica é obtida como resultado. Além disso, foram utilizados dados de fenologia obtidos de experimentos realizados no estado do Tocantins para aumentar a precisão na modelagem da fenologia. Também foram realizadas análises de sensibilidade ao fotoperíodo de acordo com o método de Fukay (1999), utilizando ensaios de VCU realizados nos estados de Goiás e Roraima, pois nesses estados há uma maior disponibilidade de ensaios.

Os coeficientes genéticos de particionamento, índice de área foliar e produtividade do modelo de simulação ORYZA (v3) foram parametrizados seguindo o boletim disponível em IRRORYZA (2021). O objetivo da parametrização é definir a diferença entre os dados observados (medidos no campo) e simulados ORYZA (v3) em um patamar máximo de 5%, 10% e 15% para a produtividade, dinâmica de biomassa de folha e total e índice de área foliar, respectivamente. O cultivar padrão para a realização da calibração das duas cultivares foi a IR72. As taxas descrevem o crescimento vegetativo em três fases distintas: desenvolvimento vegetativo (DVRv), desenvolvimento reprodutivo (DVRr), e por fim a taxa relacionada à fase de enchimento de grãos. Menores valores nas taxas de desenvolvimento indicam maior período térmico, uma vez que para cada taxa, a quantidade de graus dias acumulados (GDA) é o denominador, ao passo que a etapa da fenologia é o numerador. Mais detalhes estão disponíveis em Bouman et al. (2001).

$$DVRv = \frac{(0,65-0)}{GDAv} \quad (1)$$

$$DVRr = \frac{(1-0,65)}{GDAr} \quad (2)$$

$$DVRe = \frac{(2-1)}{GDAe} \quad (3)$$

Os valores no numerador das equações indicam o estágio de desenvolvimento (DVS), que corresponde a cada estágio fenológico. Desta forma, $0 < DVS < 0,65$ equivale à idade fisiológica durante a fase vegetativa; $0,65 < DVS < 1$ equivale à idade fisiológica na fase reprodutiva, com o final desse período indicado pela data de florescimento, e $1 < DVS < 2$ equivale à idade fisiológica durante a fase de enchimento de grãos, com o seu final indicado pela maturação fisiológica. Quando o cultivar for sensível ao fotoperíodo é necessário dividir a fase de desenvolvimento vegetativo em duas fases distintas: fase de desenvolvimento juvenil (DVRj) e fase indutiva (DVRi). A DVRj é período em que o desenvolvimento fenológico ocorre somente devido à influência da temperatura do ar. A DVRi considera o desenvolvimento fenológico a partir do momento em que as plantas de arroz passam a ser sensíveis ao fotoperiodismo, o que ocorre por volta de 15 dias antes da iniciação da panícula, e tem duração até 3 dias após a diferenciação da panícula (Streck et al., 2006). As equações correspondentes ao DVRj e DVRi estão apresentadas abaixo:

$$DVRj = \frac{(0,4-0)}{GDAj} \quad (4)$$

$$DVRi = \frac{(0,65-0,4)}{GDAi} - FSPP \quad (5)$$

$$FSPP = 1 - (DL - MOPP) \times FSPP \quad (6)$$

FSPP é o fator de sensibilidade ao fotoperíodo e é obtido pela equação abaixo:

$$FSPP = 1 - (DL - MOPP) \times FSPP \quad (7)$$

MOPP é o fotoperíodo máximo (em horas) na iniciação da panícula, e é obtido por meio de equações astronômicas. DL representa o fotoperíodo ótimo e é obtido por $MOPP + 0,9$ para ajustar o fotoperíodo máximo ao efeito da radiação solar antes do nascer e pôr do sol (Bouman et al., 2001). Os parâmetros fenológicos dos dois cultivares estão descritos na Tabela 2.

Tabela 2. Coeficientes fenológicos utilizados para a calibração do particionamento de fotoassimilados para os cultivares BRS Catiana e IRGA 424. TB é a temperatura basal; TO é a temperatura ótima (°C); TM é a temperatura máxima (°C). DVRj é a taxa de desenvolvimento da fase de desenvolvimento juvenil (°C d⁻¹); DVRi

é a taxa de desenvolvimento na fase sensível ao fotoperíodo ($^{\circ}\text{C d}^{-1}$); DVRr é a taxa de desenvolvimento na fase reprodutiva ($^{\circ}\text{C d}^{-1}$); e DVRe é a taxa de desenvolvimento na fase de enchimento de grãos ($^{\circ}\text{C d}^{-1}$). PPSE é o parâmetro de sensibilidade ao fotoperíodo

Cultivar	Parâmetros							
	TB	TO	TM	DVRj	DVRi	DVRr	DVRe	PPSE
BRS Catiana	12	30	42	0,001443	0,000842	0,000799	0,002423	0
IRGA 424	12	30	42	0,001313	0,000924	0,000931	0,002781	0

A esterilidade de espiguetas também foi calibrada para os dois cultivares, onde foram utilizados os ensaios de VCU usados na validação. Como a esterilidade de espiguetas é um índice fixo no ORYZA (v3), os dois cultivares foram simulados considerando esterilidade de espiguetas de 35°C até 40°C . Foram selecionados apenas dois estados em que houve perda de produtividade a partir de 35°C , o caso de Piauí e Roraima. As simulações pararam de sofrer penalidades por conta da esterilidade de espiguetas em valores iguais a 40°C . Desta forma, definiu-se este valor como o valor máximo em que a planta não sofre esterilidade de espiguetas. É importante salientar não foram considerados efeitos microclimáticos.

A avaliação do modelo ORYZA (v3) deve ser realizada por meio de dados observados de maneira independente antes que este seja utilizado em simulações em diferentes ambientes. Para certificar a capacidade preditiva do modelo de simulação ORYZA (v3) para a simulação do crescimento, desenvolvimento e produtividade do arroz, para os cultivares IRGA 424 e BRS Catiana, foram utilizados dados observados provenientes dos ensaios de valor de cultivo (VCU) em diversos locais do programa de melhoramento do arroz irrigado (Tabela 1).

Esses dados observados em VCU foram organizados em dados de clima referentes a esses ensaios coletados de forma a poderem ser inseridos no modelo. Para quantificar as diferenças entre os valores observados (X) e simulados (Y) para produtividade e fenologia (florescimento), os seguintes parâmetros estatísticos foram calculados: Coeficiente de correlação de Pearson (r), Coeficiente de determinação (R^2), Erro médio absoluto (MAE), Erro médio (ME), erros da raiz quadrada (RMSE) e raiz quadrada normalizada (RMSEn).

5.3 RESULTADOS E DISCUSSÃO

5.3.1 Fotoperíodo

Ambos os cultivares não apresentaram sensibilidade ao fotoperíodo em Goiás e Roraima de acordo com o método de Fukay (1999). De acordo com essa metodologia, quando o coeficiente angular (β) for $<0,3$ é um indício de que não há sensibilidade ao fotoperíodo, nessa

escala, quanto maior o coeficiente angular, maior a sensibilidade. Castro (2020) mostrou que apenas em ambiente subtropical o BRS Catiana e IRGA 424 apresentaram sensibilidade ao fotoperíodo, com valores de β de -0,38 e -3,5, respectivamente. Santos et al. (2017) constatou que ambas os cultivares não apresentaram sensibilidade ao fotoperíodo tanto no ambiente tropical quanto no subtropical.




Figura 1. Relação entre comprimento da fase Emergência (EM) - Floração (eixo y) e data de Emergência (eixo x) indicando o grau de sensibilidade ao fotoperíodo da cultivar BRS Catiana e IRGA 424, determinado pelo método de Fukay. O formato do ponto indica o local dos experimentos, o formato redondo é referente a Goiás, o triangular a Roraima

5.3.2 Parametrização e validação do ORYZA v3

Foi observado que a BRS Catiana apresentou menor período térmico na fase de desenvolvimento juvenil, ao passo que a IRGA 424 apresentou menor período térmico nas outras três fases (Tabela 2). No total, o GDA da BRS Catiana foi ligeiramente maior do que o da IRGA 424, 1399 contra 1310 GDA. Santos et al. (2017), avaliando ensaios da BRS

Catiana, estimou em 1328 GDA a necessidade média para a área tropical (Goianira – GO) e em 1639 GDA em ensaios na região subtropical (Cachoeirinha - RS). Este mesmo estudo mostrou que a IRGA 424 necessitou de 1238 GDA para a região tropical e 1501 GDA para a região subtropical.

As representações gráficas mostrando a comparação entre o particionamento observado e simulado são demonstradas nas Figuras 2 e 3 para o BRS Catiana e nas Figuras 4 e 5 para IRGA 424. Houve um desempenho satisfatório para ambos os cultivares, como BRS Catiana mostrando um desempenho levemente superior. No entanto, deve levar-se em conta que o ensaio 1 do IRGA 424 possui apenas resultados em 4 dias durante todo o ciclo, o que pode ter afetado a precisão na calibração do particionamento.

O desempenho do particionamento simulado foi bom em todas as situações para o BRS Catiana, com todas as comparações possuindo $R^2 > 0,81$. Houve uma superestimativa de área foliar (IAF) no segundo ensaio (E2) (Figura 2B), no entanto o padrão ao longo do ciclo foi semelhante ao observado, resultando em $R^2 = 0,9$, superior ao do primeiro ensaio (E1), este por sua vez teve melhor ajuste $RMSE = 1,44$ (Figura 2A). Essa superestimativa no IAF não gerou o mesmo comportamento na massa seca de folhas (MSF). No entanto, observa-se que no E1 o simulado subestimou em todas as avaliações, ao passo que no E2 superestimou em quatro avaliações (Figura 2C e D).




Figura 2. Índice de Área Foliar (IAF) e massa seca de folhas verdes (Mg ha⁻¹) observados (linhas alaranjadas) e estimados (pontilhados azuis) pelo modelo ORYZA (v3) para o cultivar BRS Catiana. No eixo x temos o tempo cronológico dos experimentos em dias julianos

No E1 houve uma subestimativa de massa seca de panículas (MSP) nas últimas quatro avaliações, ao passo que no E2 observou-se o mesmo comportamento $R^2 = 0,99$, bem como um ótimo ajuste (Figura 3A e B). Essa subestimativa pode ter resultado em menor rendimento simulado (Y_p) no E1, no entanto, devido ao menor número de avaliações em E2, não é possível comparar os valores nos estágios finais de MSP. Também houve uma tendência do E1 em subestimar a matéria seca de colmos (MSC) por quase todo o ciclo (Figura 3C), o que pode estar relacionado com o atraso na emissão de folhas e subestimativa inicial de MSF

(Figura 2A e C). O mesmo padrão também foi observado em massa total (MT) para E1 (Figura 3E e F).




Figura 3. Dinâmica da partição de assimilados nos colmos, panículas e massa seca total (eixo y), observados (linhas alaranjadas) e simulados ao longo dos ensaios (pontilhado azul) pelo modelo ORYZA (v3) para o cultivar BRS Catiana. No eixo x temos o tempo cronológico de duração do ciclo observado em dias julianos

O IRGA 424 apresentou desempenho satisfatório na maioria dos casos, entretanto, neste caso houve limitações decorrentes do E1 ter apenas 4 amostras ao longo do ciclo. Ademais, o ciclo total simulado terminou antes do observado, impossibilitando a comparação na última amostragem de E1.

O IAF apresentou comportamento semelhante entre o observado e simulado, com tendência de subestimativa em todos os casos para os dois ensaios (Figura 4A e B). O mesmo padrão aconteceu com a MSF (Figura 4C e D).




Figura 4. Índice de Área Foliar (IAF) e massa seca de folhas verdes ($Mg\ ha^{-1}$), observados (linhas alaranjadas) e estimados (pontilhados azuis) pelo modelo ORYZA (v3) para o cultivar IRGA 424. No eixo x temos o tempo cronológico dos experimentos em dias julianos

A MSP simulada de E2 apresentou um comportamento semelhante ao observado resultando em um ajuste bom. O E1 necessitou da criação de dois pontos interpolados, pois o MSP simulado no dia 2 era zero e, como dito anteriormente, o ciclo do simulado foi menor, não havendo correspondente no dia 66. Desta forma, dois pontos interpolados foram criados nos dias 32 e 49, de modo a facilitar a visualização da comparação. Mesmo assim, devido às diferenças nos padrões dos gráficos (Figura 5A) 3, obteve-se $R^2 = 0$, com baixo ajuste, e $RMSE = 6,33 \text{ Mg ha}^{-1}$. O mesmo padrão de subestimativa ocorreu para MSC e MT no E1 (Figura 5C e 5E), ao passo que houve um desempenho satisfatório em E2 (Figura 5D e F).




Figura 5. Dinâmica da partição de assimilados nos colmos, panículas e massa seca total (eixo y), observados (linhas alaranjadas) e simulados ao longo dos ensaios (pontilhado azul) pelo modelo ORYZA (v3) para o cultivar IRGA 424. No eixo x temos o tempo cronológico de duração do ciclo observado em dias julianos

Yuan et al. (2017) mostrou que o ORYZAv3 foi relativamente preciso em simular a produtividade em cultivares com alto rendimento na região central da China, no entanto foi preciso em simular massa seca de folhas verdes, colmos e panículas.

Tabela 3. Valores observados e simulados nos ensaios de campo. CICLO_sim (em dias) é o comprimento do ciclo simulado pelo ORYZA (v3) para cada ensaio; CICLO_obs (em dias) é o comprimento do ciclo observado em cada ensaio; Yp (em Mg ha⁻¹) é a produtividade potencial simulada pelo modelo ORYZA (v3) para cada ensaio; Ye (em Mg ha⁻¹) é a produtividade obtida em cada ensaio; e DP (em %) é o desvio da produtividade potencial simulada em relação à produtividade observada em cada ensaio. Dados relativos os cultivares BRS Catiana e IRGA 424

Cultivar	CICLO_sim	CICLO_obs	Yp	Ye	DP%
BRS Catiana_E1	121	116	10,381	10,140	2,376726
BRS Catiana_E2	122	127	10,889	10,855	0,31322
IRGA 424_E1	113	X	10,274	X	X
IRGA 424_E2	109	X	10,028	X	X

5.3.3 Esterilidade de espiguetas

Temperaturas elevadas próximas ao período de floração podem ocasionar esterilidade de espiguetas, resultando em perdas em produtividade (Yoshida, 1981). Para estimar a temperatura mínima em que se inicia a esterilidade de espiguetas para os dois cultivares calibrados, foram realizadas simulações em diversas faixas de temperatura, variando de 35 a 40°C. Ambos os cultivares mostraram rendimentos estáveis em valores superiores a 40°C (Figura 6) quando comparados aos resultados validados. Desta forma, definiu-se como 40°C o valor acima do qual começa a ocorrer penalidade na produtividade por esterilidade de espiguetas.




Figura 6. Boxplot mostrando a produtividade simulada da BRS Catiana e IRGA 424 sob diferentes valores de esterilidade de espiguetas. *Ensaio proveniente dos estados de Piauí e Roraima

Apenas Piauí e Roraima apresentaram redução na produtividade nas faixas de temperaturas testadas, um indicativo de que nos outros estados não houve temperaturas elevadas próximas à data de florescimento durante o período de cultivo dos ensaios. É importante ressaltar que esta faixa de temperatura representa a temperatura medida na estação meteorológica mais próxima, seja ela virtual (Roraima) ou observada (Piauí). A temperatura máxima no microclima presente em uma lavoura de arroz pode chegar a valores muito maiores. Santos et al. (2003) verificaram que a temperatura da água pode chegar a índices térmicos de 42°C. Na maioria dos casos, a temperatura da água será superior à do ar (Santos & Santiago, 2014).

5.3.4 Validação

Após a etapa de calibração, é necessário checar se o cultivar calibrado é capaz de reproduzir o desempenho em outros lugares e épocas de plantio. Para avaliar a capacidade preditiva do modelo ORYZA (v3) foram comparados os dados simulados com observados provenientes de ensaios de VCU (Valor de cultivo e uso). Na Figura 7 são apresentados ensaios de VCU de quatro estados, Goiás, Piauí, Roraima e Tocantins.

É possível notar que em Goiás, para ambos os cultivares, há uma tendência de superestimar a produtividade dos dados observados, o que é considerado normal, uma vez que nas simulações não há penalidade por fatores bióticos. Também é possível observar que a amplitude dos dados simulados em Goiás é mais próxima à amplitude dos observados (Figura 7A e B), mostrando uma resposta do modelo às interações ambientais. Em Goiás, a amplitude dos dias necessários para o florescimento foi menor para os dois cultivares. No caso do BRS Catiana, os valores simulados concentraram-se na faixa entre o segundo e terceiro quartis (Q_2 e Q_3) ao passo que para o IRGA 424 os valores simulados concentraram entre Q_1 e Q_2 (Figura 7C e D).

No estado do Piauí houve uma similaridade maior entre os dados observados e simulados. Neste estado, o BRS Catiana apresentou uma amplitude dos dados simulados de produtividade mais parecida com os observados do que o IRGA 424 (Figura 7A e B). Para os dois cultivares, houve uma tendência de superestimar os valores de simulados de florescimento (Figura 7B e D).

No estado de Roraima houve uma baixa resposta do modelo. É possível constatar que a estreita amplitude dos dados simulados, bem como sua tendência de subestimar os observados, são indícios de que o modelo não está captando as interações para este local. Em relação à produtividade, a faixa de valores simulados do BRS Catiana situa-se entre Q_1 e Q_2 dos valores observados e valores entre Q_1 e Q_2 para o IRGA 424 (Figura 7A e B).

Para os dois cultivares também houve uma tendência de superestimar o florescimento (Figura 7C e D). Vale a pena ressaltar que para Roraima e uma cidade do Piauí foram utilizados dados provenientes de estações virtuais da NASA/POWER, no entanto, como foram realizadas apenas simulações sem penalidade por déficit hídrico, a precisão desses dados é maior, devido ao fato das maiores incertezas de estações virtuais estarem relacionadas à precipitação (Xavier et al., 2016; Mourtzinis et al., 2017)

Em Tocantins houve baixa resposta das produtividades simuladas para ambos os cultivares, no caso do BRS Catiana os valores simulados situaram-se na faixa entre Q_2 e Q_3 dos observados ao passo que no IRGA 424 estes ficaram entre Q_3 e o limite superior (Figura 7A e B). Ambos os cultivares subestimaram os valores de florescimento, sendo que do IRGA424 foi maior.




Figura 7. Boxplot mostrando a produtividade e os dias para o florescimento observados e simulados (em Mg ha⁻¹) dos cultivares BRS Catiana e IRGA 424 em diferentes épocas de plantio nos estados de Goiás, Piauí, Roraima e Tocantins . *Neste caso foram considerados apenas estados com mais de quatro ensaios

Na Figura 8 são apresentadas as comparações entre produtividades simuladas e observadas da BRS Catiana e IRGA 424, bem como entre os dias para o florescimento. Neste caso foram considerados todos os municípios descritos na tabela 1. De forma geral, o BRS Catiana apresentou melhor performance para o florescimento, obtendo uma correlação maior (r), 0,63 contra 0,4 da IRGA 424, bem como menores valores de MAE e RMSE, indicando um melhor ajuste. O IRGA 424, no entanto, apresentou melhor performance para a produtividade, obtendo uma correlação maior, 0,47 contra 0,27, e apresentou melhor ajuste (RMSE e MAE).

Conforme analisado anteriormente, é possível notar que os pontos referentes às maiores latitudes – mais próximas à zero – representam quase a totalidade dos pontos abaixo da linha 1:1 (pontilhada), indicando que o modelo tende a subestimar a produtividade nesses locais. Este padrão é maior no BRS Catiana do que no IRGA 424 (Figura 8A e B). Deve ser ressaltado que quase todos os pontos próximos à latitude zero são referentes aos ensaios de VCU realizados no município de Canta, em Roraima. Esse comportamento demonstra que a localidade dos ensaios utilizados na parametrização impacta na validação, uma vez que os ensaios utilizados para a parametrização estão entre as latitudes -10,8 e -16,5 (Tabela 1).




Figura 8. Relação entre os dados observados (eixo x) e simulados (eixo y) considerando a produtividade (A e B), florescimento (C e D) para os cultivares BRS Catiana (A e C) e IRGA 424 (B e D). Diferentes épocas e regiões foram considerados, a cor dos pontos representa a latitude do ensaio de VCU

Na Figura 9 foi comparado o desempenho dos ensaios de VCU com simulações realizadas em toda a janela de cultivo para a localidade do VCU, em 36 anos. De modo geral, observa-se um comportamento parecido com o que foi mostrado na Figura 7. Algumas diferenças foram notadas, como um aumento da amplitude dos valores de produtividade simulada para PI, TO e RR, o que é justificado pelo fato de estarmos considerando várias datas de plantio em vários anos. Para o florescimento não houve muita diferença na amplitude dos dados.




Figura 9. Boxplot mostrando a produtividade e o florescimento observados e simulados (em Mg ha^{-1}) dos cultivares BRS Catiana e IRGA 424 em diferentes épocas de plantio nos estados de Goiás, Piauí, Roraima e Tocantins *Neste caso foram considerados apenas estados com mais de quatro ensaios, para melhor visualização em boxplot, também foram feitas simulações em toda a época de plantio de cada estado, não apenas na data do VCU

O modelo ORYZA (v3) já foi utilizado em regiões tropicais próximos à linha do Equador. Agustiani et al. (2018) mostrou que o modelo é confiável para simular o rendimento do arroz irrigado no sudeste asiático. Outro estudo na Colômbia relatou a aplicabilidade do modelo (Fernandes et al., 2020) em uma faixa de latitude similar à de Roraima. Li et al. (2016) caracterizou a região produtora de arroz irrigado no sul da Ásia, abrangendo uma área do Paquistão até a Indonésia, no entanto, a parametrização e a validação foram realizadas apenas

nas Filipinas, o que não possibilita a avaliação da capacidade preditiva do modelo para as outras regiões, como a Indonésia, que se situa na mesma faixa de latitude que Roraima.

É relevante destacar, que mesmo os estudos que mostram a aplicabilidade do ORYZA (v3) para regiões tropicais, estes não possuem dados comparativos com outras regiões para a mesma calibração, ou com outras calibrações. Desta forma, é incerto o uso deste modelo para grandes regiões, principalmente com grande variação na latitude. Podendo afetar diversos estudos, uma vez que o maior potencial produtivo simulado de uma região quando comparada com a outra pode ser apenas por erros do modelo.

O ORYZA (v3) é um modelo de simulação de cultura com muitos parâmetros (Li et al., 2017). Portanto, está sujeito a diversas interações com o ambiente em que será realizada a simulação. Isto pode ocasionar erros devido a interações que o modelo faz, as quais podem ocorrer de outra forma ou em outra magnitude na realidade. Por isso, modelos simples, com menos parâmetros e menos interações também devem ser testados para estudos em vastas regiões, uma vez que estes podem ser úteis para essas aplicações (Confalonieri & Bechini, 2004).

5.4 CONCLUSÕES

O ORYZA (v3) não foi sensível às interações genótipo x ambiente em vários pontos validados, principalmente em Tocantins e Roraima.

O BRS Catiana teve um melhor ajuste na fenologia, mas, isso não resultou em melhor desempenho na produtividade simulada.

São necessários mais pontos de calibração para a fenologia do IRGA 424 no ambiente tropical.

O modelo teve uma tendência de superestimar mais as produtividades no estado de Goiás, enquanto as subestimava em Roraima. Esse padrão foi mais acentuado com o BRS Catiana.

Não é recomendado o uso dessa parametrização para estudos que comparem uma área com a outra dentro da região tropical, pois o modelo mostrou um viés em função da latitude, o que pode gerar resultados não condizentes com a realidade.

Para mostrar a viabilidade do uso do ORYZA (v3) para a região tropical, é necessária uma parametrização em algum local próximo à linha do Equador (como Roraima, por exemplo), de modo a checar a resposta do modelo.

5.5 LITERATURA CITADA

Agustiani, N.; Denf, N.; Edreira, J. I. R.; Girsang, S. S.; Sitaresmi, T.; Pasuquin, J. M.; Agus, F.; Grassini, P. Simulating rice and maize yield potential in the humid tropical environment of Indonesia. *European Journal of Agronomy*, v.101, p.10-19, 2018. <https://doi.org/10.1016/j.eja.2018.08.002>.

Amiri, E.; Razavipour, T.; Farid, A.; Bannayan, M. Effects of Crop Density and Irrigation Management on Water Productivity of Rice Production in Northern Iran: Field and Modeling Approach. *Communications in Soil Science and Plant Analysis*, v.42, n.17, p.2085-2099, 2011. <https://doi.org/10.1080/00103624.2011.596238>.

Arsego, D. A. et al. Índices climáticos associados a variabilidade interanual da produtividade de arroz no Rio Grande do Sul. *Revista Brasileira de Meteorologia*, v.35, n.2, p.209-218, 2020. <https://doi.org/10.1590/0102-7786351033>.

Bouman, B. A. M.; Kropff, M. J.; Wopereis, M. C. S.; Ten Berge, H. F. M.; Van Laar, H. H. ORYZA2000: Modeling lowland rice. Los Baños (Philippines): International Rice Research Institute, and Wageningen: Wageningen University and Research Centre, 2001. 235p.

Carmona, L. C. Efeitos associados aos fenômenos El niño e La Niña no rendimento do arroz irrigado no Estado do Rio Grande do Sul. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2011. 77p. Dissertação de Mestrado.

Castro, J. R. Avaliação de métodos de calibração do modelo ORYZA para estimar produtividade do arroz irrigado. Goiânia: Universidade Federal de Goiás, 2020. 90p. Tese de Doutorado.

Confalonieri, R.; Bechini, L. A preliminary evaluation of the simulation model CropSyst for alfalfa. *European Journal of Agronomy*, v.21, n.2, p.223– 237, 2004.

Fan, X.; Tang, Z.; Tan, Y.; Zhang, Y.; Luo, B.; Yang, M.; Lian, X.; Shen, Q.; Miller, A. J.; Xu, G. Overexpression of a pH-sensitive nitrate transporter in rice increases crop

yields. *Proceedings of the National Academy of Sciences of the United States of America*, v. 113, n.26, p.7118–7123, 2016. <https://doi.org/10.1073/pnas.1525184113>.

Fernandes, K.; Muñoz, A.G.; Ramirez-Villegas, J.; Agudelo, D.; Llanos-Herrera, L.; Esquivel, A.; Rodriguez-Espinoza, J.; Prager, S. D. Improving Seasonal precipitation forecasts for agriculture in the Orinoquía Region of Colombia. *Weather Forecast*, v.35 , p.437-449, 2020. <https://doi.org/10.1175/WAF-D-19-0122.1>.

Fukay, S. Phenology in rainfed lowland rice. *Field Crops Research*, v.64, n.1, p.51-60, 1999.

Gregory, P. J.; George, T. S. Feeding nine billion: the challenge to sustainable crop production, *Journal of Experimental Botany*, v.62, Issue 15, p.5233–5239, 2011. <https://doi.org/10.1093/jxb/err232>.

Heinemann, A. B.; Barrios-Perez, C.; Ramirez-Villegas, J.; Arango-Lon-Dono, D.; Bonilla-Findji, O.; Medeiros, J. C.; Jarvis, A. Variation and impact of drought-stress patterns across upland rice target population of environments in Brazil. *Journal of Experimental Botany*, v.66, n.12, p.3625–3638, 2015. <https://doi.org/10.1093/jxb/erv126>.

Heinemann, A. B.; Ramirez-Villegas, J.; Stone, L. F.; Silva, A. P.; Matta, D. H.; Diaz, M. E. The impact of El Niño Southern Oscillation on cropping season rainfall variability across Central Brazil. *International Journal of Climatology*, v.1, p. joc.6684, 2020. <https://doi.org/10.1002/joc.6684>.

INMET. Instituto Nacional de Meteorologia. 2020. <http://www.inmet.gov.br/portal/>. 29 Out. 2020.

IRRIORYZA. Transferências (Modelo Oryza). 2021. <https://sites.google.com/a/irri.org/oryza2000/downloads/>. 28 Mar. 2021.

Jones, J. W.; Hoogenboom, G.; Porter, C. H.; Boote, K. J.; Batchelor, W. D.; Hunt, L. A.; Wilkens, P. W.; Singh, U.; Gijsman, A. J.; Ritchie, J. T. The DSSAT cropping system model. *European Journal of Agronomy*, v.18, p.235-265, 2003.

http://www.uwyo.edu/plantsciences/afri-cap-legumeadoption/_files/pdfs/dssat.pdf. 14 Dez. 2020.

Li, T.; Angeles, O.; Marcaida III, M.; Manalo, E.; Manalili, M. P.; Radanielson, A.; Mohanty, S. From ORYZA2000 to ORYZA (v3): an improved simulation model for rice in drought and nitrogen-deficient environments. *Agricultural and Forest Meteorology*, v.237/238, p.246–256, 2017. <https://doi.org/10.1016/J.AGRFORMET.2017.02.025>.

Li, T.; Marcaida III, M.; Angeles, O.; Franje, N. J.; Revilleza, J. E.; Manalo, E.; Redoña, E.; Xu, J.; Li, Z. Combining limited multiple environment trials data with crop modeling to identify widely adaptable rice varieties. *PLoS ONE*, v.11, n.10, p. e0164456, 2016. <https://doi.org/10.1371/journal.pone.0164456>.

Magalhães Júnior, A. M. M.; Morais, O. P.; Fagundes, P. R. R.; Colombari, J. M.; Franco, D. F.; Cordeiro, A. C. C.; Pereira, J. A.; Rangel, P. H. N.; Moura-Neto, F. P.; Streck, E. A.; Aguiar, G. A.; Facchinello, P. H. K. BRS Pampeira: new irrigated rice cultivar with high yield potential. *Crop Breeding and Applied Biotechnology*, v.17, p. 78-83, 2017. <https://dx.doi.org/10.1590/1984-70332017v17n1c13>.

Medrado, E.; Lima, J. E. F. W. Development of pedotransfer functions for estimating water retention curve for tropical soils of the Brazilian savanna. *Geoderma Regional*, v. 1, p. 59-66, 2014.

Morais, O. P.; Torga, P. P.; Cordeiro, A. C. C.; Pereira, J. A.; Magalhães Júnior, A. M. M.; Colombari, J. M. F. BRS Catiana: cultivar de arroz irrigado de elevada produtividade e ampla adaptação. Santo Antônio de Goiás: Embrapa Arroz e Feijão, 2016. 6 p. (Embrapa Arroz e Feijão. Comunicado técnico, 233). <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/139116/1/CNPAF-ComTec233.pdf>. 28 Mar. 2021.

Mourtzinis, S.; Edreira, J. I. R.; Conley, S. P.; Grassini, P. From grid to field: Assessing quality of gridded weather data for agricultural applications. *European Journal of Agronomy*, v.82, p.163-172, 2017. <https://doi.org/10.1016/j.eja.2016.10.013>.

NASA-POWER. The National Aeronautics and Space Administration - Nasa Prediction of Worldwide Energy Resources. 2020. <https://power.larc.nasa.gov/data-access-viewer/>. 20 Dez. 2020.

RADAMBRASIL. Levantamento de recursos naturais. Ministério das Minas e Energia, Rio de Janeiro. 1983. <https://biblioteca.ibge.gov.br/bibliotecacatalogo?id=217129&view=detalhes>. 27 Mar. 2021.

Ramirez-Villegas, J.; Heinemann, B. A.; Castro, A. P.; Breseghello, F.; Navarro-Racines, C.; Li, T.; Rebolledo, M.; Challinor, A. Breeding implications of drought stress under future climate for upland rice in Brazil. *Global Change Biology*, v.24, n.5, p.2035-2050, 2018. <https://doi.org/10.1111/gcb.14071>.

Rangel, P. H. N.; Torga, P. P.; Fragoso, D. B.; Filho, J. M. C.; Cordeiro, A. C. C.; Pereira, J. A.; Lobo, V. L. S.; Lacerda, M. C.; Custódio, D. P.; Júnior, A. M. M.; Abreu, A. G.; Santiago, C. M.; Santos, B. M. BRS Catiana: irrigated rice cultivar with high yield potential and wide adaptation. *Crop Breeding and Applied Biotechnology*, v.19, n. 3, p.368-372, 2019. <http://dx.doi.org/10.1590/1984-70332019v19n3c51>.

Santos, A. B.; Santiago, C. M. Informações técnicas para a cultura do arroz irrigado nas regiões Norte e Nordeste do Brasil. Santo Antônio de Goiás: Embrapa Arroz e Feijão, 2014. 150p.

Santos, A. B.; Silva, S. C.; Zimmermann, F. J. P. Efeitos do manejo da irrigação na temperatura da água e no comportamento do arroz irrigado. In: Congresso Brasileiro de Arroz Irrigado, 3.; Reunião da cultura de arroz irrigado, 25., 2003, Balneário Camboriú. Anais... Itajaí: EPAGRI, 2003. p.181-183.

Santos, M. P.; Zanon, A. J.; Cuadra, S. V.; Steinmetz, S.; Castro, J. R.; Heinemann, A. B. Yield and morphophysiological indices of irrigated rice genotypes in contrasting ecosystems. *Pesquisa Agropecuária Tropical*, v.47, n.3, p.253-264, 2017. <http://dx.doi.org/10.1590/1983-40632016v47n3c55>.

Saseendran, S. A.; Ahuja, L. R.; Ma, L.; Timlin, D. J.; Stockle, G. O.; Boote, K. J.; Hoogenboom, G. Current water deficit stress simulations in selected agricultural system simulation models. In: Ahuja, L. R. et al. (Eds.). Response of Crops to limited water: Understanding and modeling water stress effects on plant growth processes. Madison: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, 2008.

Streck, N. A.; Bosco, L. C.; Michelon, S.; Rosa, H. T.; Walter, L. C.; Paula, G. M.; Camera, C.; Lago, I.; Marcolin, E. Avaliação da resposta ao fotoperíodo em genótipos de arroz irrigado. *Bragantia*, v. 65, n. 4, p. 533-541, 2006.

Xavier, A. C.; King, C. W.; Scanlon, B. R. Daily gridded meteorological variables in Brazil (1980–2013). *Int. J. Climatol.*, v.36, p.2644-2659, 2016. <https://doi.org/10.1002/joc.4518>.

Yoshida, S. Fundamentals of rice crop science. Los Baños: IRRI, 1981. 269p.

Yuan, S.; Peng, S.; Li, T. Evaluation and application of the ORYZA rice model under different crop managements with high-yielding rice cultivars in central China. *Field Crops Research*, v.212, p.115–125, 2017. <https://doi.org/10.1016/j.fcr.2017.07.010>.

6 CONSIDERAÇÕES FINAIS

Modelos de simulação é uma importante ferramenta nas ciências agrárias, pois podem auxiliar na tomada de decisões relacionadas ao manejo de uma determinada cultura e também avaliar os impactos de cenários climáticos futuros. Estudos com modelos de simulação de cultura em grandes extensões de área têm se tornado cada vez mais comum, já que este tipo de estudo é norteador para as outras áreas agrícolas.

Diversos estudos demonstram a existência de incertezas com a variável precipitação estimada por estações virtuais, no entanto, não consideram os agravantes da interação desta variável com diferentes tipos de solo, em uma relação solo-planta-atmosfera, em que os erros são maiores em solos arenosos do que em solos argilosos quando esses dados são usados em modelos de simulação de cultura, como mostra o capítulo 1 deste trabalho. Com base nisso, é importante a realização de estudos que explorem os limites aceitáveis de uso desse tipo de dado, considerando vários tipos de solos e plantas. Também é necessário melhorar a interpolação dos dados de precipitação, ou investigar meios mais eficientes para estimar esta variável.

A validação é outra etapa que tem sido negligenciada, quando cultivares calibrados são aplicados em uma grande extensão de área, deve-se haver meios de verificar que estes representem cada região. Apesar disso, em muitos estudos realizados em várias extensões a validação é realizada apenas para um ponto, o que torna incerta a capacidade preditiva do modelo para o restante. No segundo capítulo deste trabalho observou-se um viés do modelo ORYZA (v3) em função da latitude, em que latitudes mais próximas de zero o modelo apresentou uma tendência de subestimar, ao passo que superestimou nos pontos próximos a calibração (Goiás). Nesse contexto, é relevante a realização de pesquisas científicas que investiguem as interações que o modelo não está considerando ou considerando em magnitude diferente nessas regiões. Além disso, é necessário observar se um modelo mais simples seria melhor para as regiões. Portanto, investigar as incertezas neste caso é crucial antes da realização de pesquisas.

7 REFERÊNCIAS

ABERA, E. A. Calibration and validation of CERES-wheat in DSSAT model for yield simulation under future climate in Adet, North Western Ethiopia. **African Journal of Agricultural Research**, v. 14, p. 509–518, 2019.

AVNER, S.; MAUZERALL, D.L.; LIU, J.; HOROWITZ, L.W. Global crop yield reductions due to surface ozone exposure: 1. Year 2000 crop production losses and economic damage. **Atmospheric Environment**, v. 45, p. 2284–2296, 2011.

BATTISTI, R.; FERREIRA, M. D. P.; TAVARES, E. B.; KNAPP, F.M.; BENDER, F. D.; CASAROLI, D.; ALVES JÚNIOR, J. Rules for grown soybean-maize cropping system in Midwestern Brazil: Food production and economic profits. **Agricultural Systems**, v. 182, 2020.

BATTISTI, R.; SENTELHAS, P. C.; PASCOALINO, J. A. L.; SAKO, H.; DANTAS, J. P. S.; MORAES, M. F. Soybean Yield Gap in the Areas of Yield Contest in Brazil. **International Journal of Plant Production**, v. 12, p. 159-168, 2018.

BATTISTI, R.; SENTELHAS, P. C.; PILAU, F. G. Agricultural efficiency of soybean, corn and wheat production in the state of Rio Grande do Sul, Brazil, between 1980 and 2008. **Ciência Rural**, v. 42, n. 1, p. 24–30, 2012.

BHATIA, V. S.; SINGH, P.; WANI, S. P.; CHAUHAN, G. S.; KESAVA RAO, A. V. R.; MISHRA, A. K; SRINIVAS, K. Analysis of potential yields and yield gaps of rainfed soybean in India using CROPGRO-Soybean model. **Agricultural and Forest Meteorology**, v. 148, p. 1252–1265, 2008.

CONAB – Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira de grãos**. v. 11 Safra 2017/18 - Décimo primeiro levantamento. Brasília, p. 1- 148. 2018.

Disponível em: < <http://www.conab.gov.br/>>. Acesso: 01 mar. 2021.

COOPER, M.; STUCKER, R. E.; DELACY, I. H.; HARCH, B. D. Wheat breeding nurseries, target environments, and indirect selection for grain yield. **Crop Science**, v. 37, n. 4, p. 1168–1176, 1997.

GALLOWAY J. N.; ABER J. D.; ERISMAN J. W.; SEITZINGER S.P.; HOWARTH R.W.; COWLING E.B.; AND COSBY B. J. The Nitrogen Cascade. **BioScience**, v. 53, n.4, p. 341-356, 2003.

HEINEMANN, A. B.; BARRIOS-PEREZ, C.; RAMIREZ-VILLEGAS, J.; ARANGO-LONDONO, D.; BONILLA-FINDJI, O.; MEDEIROS, J. C.; JARVIS, A. Variation and impact of drought-stress patterns across upland rice target population of environments in Brazil. **Journal of Experimental Botany**, v. 66, n. 12, p. 3625–3638, 2015.

HEINEMANN, A. B.; DINGHUN, M.; LUQUET, D.; COMBRES, J. C.; CHAPMAN, S. Characterization of drought stress environments for upland rice and maize in central Brazil. **Euphytica**, v. 162, n. 3, p. 395-410, 2008.

HEINEMANN, A. B.; RAMIREZ-VILLEGAS, J.; STONE, L. F.; SILVA, A. P. G. A.; MATTA, D. H.; DIAZ, M. E. P. The impact of El Niño Southern Oscillation on cropping season rainfall variability across Central Brazil. **International Journal of Climatology**, v. 1, p. 6684, 2020.

HERNANDEZ-SEGUNDO, H.; CAPETTINI, F.; TRETHOWAN, R.; VAN GINKEL, M.; MEJIA, A.; CARBALLO, A.; CROSSA, J.; VARGAS, M.; BALBUENA-MELGAREJO, A. Mega-environment identification for barley based on twenty-seven years of global grain yield data. **Crop Science**, v. 49, n. 5, p. 1705-1718, 2009.

IRGA. Novas variedades de arroz obtêm produtividade acima de 10 mil quilos por hectare. 2007. Disponível em: < <https://irga.rs.gov.br/novas-variedades-de-arroz-obtem-produtividade-acima-de-10-mil-quilos-por-hectare>>. Acesso em: 16 nov. 2020.

IRRIORYZA. **Transferências (Modelo Oryza)**. 2021.

<https://sites.google.com/a/irri.org/oryza2000/downloads/>. 28 Mar. 2021.

JERRETT, M.; BURNETT, R. T.; POPE III, C. A.; ITO, K.; THURSTON, G.; KREWSKI, D.; SHI, Y.; CALLE, E.; MD THUN, M. Long-term ozone exposure and mortality. **New England Journal of Medicine**, v. 360, n. 11, p.1085-1095, 2009.

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

JUSTINO, L.F.; ALVES-JÚNIOR, J.; BATTISTI, R.; HEINEMANN, A.B.; LEITE, C.V.; EVANGELISTA, A.W.P.; CASAROLI, D. Assessment of economic returns by using a central pivot system to irrigate common beans during the rainfed season in Central Brazil. **Agricultural Water Management**, v. 224, 2019.

LI, T.; ALI, J.; MARCAIDA III, M.; ANGELES, O.; FRANJE, N. J.; REVILLEZA, J. E.; MANALO, E.; REDOÑA, E.; XU, J.; LI, Z. Combining limited multiple environment trials data with crop modeling to identify widely adaptable rice varieties. **PLoS ONE**, v. 11, n. 10, p. e0164456, 2016.

LI, T.; ANGELES, O.; MARCAIDA III, M.; MANALO, E.; MANALILI, M. P.; RADANIELSON, A.; MOHANTY, S. From ORYZA2000 to ORYZA (v3): an improved simulation model for rice in drought and nitrogen-deficient environments. **Agricultural and Forest Meteorology**, v. 237/238, p. 246–256, 2017.

LI, T.; ANGELES, O.; RADANIELSON, A.; MARCAIDA III, M.; MANALO, E. Drought stress impacts of climate change on rainfed rice in South Asia. **Climatic Change**, v. 133, n. 4, p. 709–720, 2015.

LI, T.; RAMAN, A. K.; MARCAIDA III, M.; KUMAR, A.; ANGELES, O.; RADANIELSON, A. Simulation of genotype performances across a larger number of environments for rice breeding using ORYZA2000. **Field Crops**, v. 149, p. 312–321, 2013.

LOBELL, D. B.; CASSMAN, K. G.; FIELD, C. B. Crop yield gaps: their importance, magnitudes, and causes. **Annual Review of Environment and Resources**, v. 34, p. 179–204. 2009.

MALIK, W.; ISLA, R.; DECHMI, F. DSSAT-CERES-Maize Modelling to Improve Irrigation and Nitrogen Management Practices Under Mediterranean Conditions. **Agricultural Water Management**, v. 213, p. 298–308. 2019.

MARTINS, M. A.; TOMASELLA, J.; DIAS, C. G. Maize yield under a changing climate in the Brazilian Northeast: Impacts and adaptation, **Agricultural Water Management**, v. 216, p. 339-350, 2019.

MOURTZINIS, S. et al. From grid to field: assessing quality of gridded weather data for agricultural applications. **European Journal of Agronomy**, v. 82, n. 1, p. 163-172, 2017.

MUCHOW, R. C.; COOPER, M.; HAMMER, G. L. Characterizing environmental challenge using models. In: Cooper M, Hammer GL (Eds.) **Plant adaptation and crop improvement**. **CABI**, Wallingford, UK, p. 349–364. 1996.

MUTHAYYA, S.; SUGIMOTO, J. D.; MONTGOMERY, S.; MABERLY, G. F. An overview of global rice production, supply, trade, and consumption. **Annals of the New York Academy of Sciences**, v. 1324, n. 1, p. 7-14, 2014.

NÓIA-JÚNIOR, R. G.; SENTELHAS, P. C. Soybean-maize off-season double crop system in Brazil as affected by El Niño Southern Oscillation phases. **Agricultural Systems**, v. 173, p. 254-267, 2019.

NYQUIST, W. E. Estimation of heritability and prediction of selection response in plant population. **Critical Reviews in Plant Sciences**, v. 10, n. 3, p. 235–322, 1991.

QIAN, Y.; ZHAO, J.; ZHENG, S.; CAO, Y.; XUE, L. Risk assessment of the global crop loss in ENSO events. **Data Physics and Chemistry of the Earth**, v. 116, 2020.

RAMIREZ-VILLEGAS, J.; HEINEMANN, B. A.; CASTRO, A. P.; BRESEGHELLO, F.; NAVARRO-RACINES, C.; LI, T.; REBOLLEDO, M.; CHALLINOR, A. Breeding implications of drought stress under future climate for upland rice in Brazil. **Global Change Biology**, v. 24, n. 5, p. 2035-2050, 2018.

REAY, D. S.; DAVIDSON, E. A.; SMITH, K. A.; SMITH, P.; MELILLO, J. M.; DENTENER, F. Global agriculture and nitrous oxide emissions. **Nature Climate Change**, v. 2, p. 1-7, 2012.

RODRÍGUEZ-GONZÁLEZ, O.; BACALLAO, R. F.; NUALLES, M. V.; VIERA, D. G.; MONTENEGRO, R. V.; LÓPEZ, L. A.; RIVERA, R. M. Application of DSSAT crop simulation model to estimate the optimum dose of nitrogen fertilizer for the rice variety J-104. **Cultivos Tropicales**, v. 41, n. 2, 2020.

SANTOS, M. P.; ZANON, A. J.; CUADRA, S. V.; STEINMETZ, S.; CASTRO, J. R.; HEINEMANN, A. B. Yield and morphophysiological indices of irrigated rice genotypes in contrasting ecosystems. **Pesquisa Agropecuária Tropical**, v. 47, n. 3, p. 253-264, 2017.

SANTOS, T. G.; BATTISTI, R.; CASAROLI, D.; ALVES Jr, J.; EVANGELISTA, A. W. P. Assessment of agricultural efficiency and yield gap for soybean in the Brazilian Central Cerrado biome. **Bragantia**, v. 80, p. 1-11, 2021.

SENTELHAS, P.; BATTISTI, R.; CÂMARA, G.; FARIAS, J.; HAMPF, A.; NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **The Journal of Agricultural Science**, v. 153, n. 8, p. 1394-1411, 2015.

SILVA, K. A.; ROLIM, G. S.; VALERIANO, T. T. B.; MORAES, R. S. C. M. Influence of El Niño and La Niña on coffee yield in the main coffee-producing regions of Brazil. **Theoretical and Applied Climatology**, v. 139, p. 1019–1029, 2020.

SOARES, A. A.; CORNÉLIO, V. M. O.; SOARES, P. C.; SANTOS, P. G.; REIS, M. S. Primavera: cultivar de arroz com grãos agulhinha para cultivo em terras altas. **Revista Ceres**, v. 48, n. 277, p. 381-388, 2001.

SOARES, A. A.; SOARES, P. C.; REIS, M. S.; CORNÉLIO, V. M. O.; SILVA, F. L.

Cultivares de arroz de terras altas recomendadas para Minas Gerais. Belo Horizonte, 2008. 5p. (Circular Técnica, 14).

STATISTICA. **World grain production by type**, 2020. Disponível em:

<<https://www.statista.com/statistics/263977/world-grain-production-by-type/>>. Acesso em: 17 nov. 2020.

STEFFEN, W. et al. Planetary boundaries: Guiding human development on a changing planet. **Science**, v. 347, n. 6223, 2015.

STONE, L. F.; HEINEMANN, A. B. Simulação do manejo do nitrogênio em arroz de terras altas com o modelo ORYZA/APSIM 2000. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 6, p. 611-617, 2012.

TAYEFE, M. Calibration and evaluation of ORYZA2000 model under different N options in irrigated rice in Iran. **Journal of Biodiversity and Environmental Sciences**, v. 3, p. 77–82, 2013.

WANG, W. G.; SUN, F. C.; LUO, Y. F.; XU, J. Z. Changes of rice water demand and irrigation water requirement in southeast china under future climate change. **Procedia Engineering**, v. 28, p. 341–345, 2012.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R.. Daily gridded meteorological variables in Brazil (1980–2013). **Int. J. Climatol.**, v. 36, p. 2644-2659, 2016.

ZHANG, J.; MIAO, Y.; BATCHELOR, W.D.; LU, J.; WANG, H.; KANG, S. Improving High-Latitude Rice Nitrogen Management with the CERES-Rice Crop Model. **Agronomy**, v. 8, n. 3, p. 1-14, 2018.

APÊNDICE

Table S1. Physical and hydrological soil attributes used as soil input for the crop model simulations.

Soil Type	Bd	θ_s	FC	θ_r	SOM	CL	S	Ks	LL	DSL
Clay	1.06	0.56	0.33	0.18	4.15	55.24	25.31	107.58	0.25	17
Sandy Loam	1.4	0.42	0.12	0.04	3.12	14.31	70.03	48.7	0.09	15

Bd – bulk density (g cm^{-3}); θ_s - Soil saturation ($\text{m}^3 \text{m}^{-3}$); FC - Field capacity ($\text{m}^3 \text{m}^{-3}$); θ_r - Volumetric water content at air dryness ($\text{cm}^3 \text{cm}^{-3}$); OM – soil organic matter (%); CL - Clay (%); S - Sandy (%); Ks - Saturated hydraulic conductivity (mm dia^{-1}); LL - Soil low limit ($\text{m}^3 \text{m}^{-3}$), DSL: 32 Deep of 1° soil layer (cm).

Tabela 1. Localidades dos ensaios de valor de cultivo e uso (VCU) com as janelas de plantio realizadas pelos agricultores das respectivas regiões.

Localização	State	DP	DF
Flores de Goiás	GO	01-out	31-dez
Goianira	GO	01-out	31-dez
Luiz Alves	GO	01-out	31-dez
Itapecuru Mirim	MA	01-jun	28-fev
São Mateus	MA	01-jun	28-fev
Buriti dos Lopes	PI	01-jun	31-ago
Teresina	PI	01-jun	31-ago
Canta	RR	01-set	30-nov
Formoso do Araguaia	TO	01-out	31-jan
Lagoa da Confusão	TO	01-out	31-jan

Data de plantio das regiões em que foram analisados o desempenho dos ensaios de valor de cultivo e uso (VCU). DP é o começo da janela de plantio e DF o final.

Tabela 2. Épocas de plantio por estado na região de produção de arroz irrigado tropical.

Estado	Sigla UF	DP1	DF1	DP2	DF2
Alagoas	AL	01-Set	31-Out	01-Mar	30-Mai
Ceará	CE	01-Jan	31-Mar	01-Jun	31-Ago
Goiás	GO	01-Out	31-Dez		
Maranhão	MA	01-Jun	28-Fev		
Mato Grosso do Sul	MS	01-Jul	31-Out		
Pernambuco	PE	01-Jan	31-Mar		
Piauí	PI	01-Jun	31-Ago		
Rio Grande do Norte	RN	01-Jan	31-Mar		
Roraima	RR	01-Set	30-Nov		
Sergipe	SE	01-Set	31-Out		
São Paulo	SP	01-Ago	31-Jan		
Tocantins	TO	01-Out	31-Jan		
Paraíba	PB	01-Jan	31-Mar		

UF	Prof.	Argila	Silte	Areia	Ds	SAT	CC	PMP	CAD	KS
	(cm)		(%)		(Mg m ⁻³)			(cm ³ cm ⁻³)		(cm d ⁻¹)
CE	0 – 7	47	44	9	0,91	0,62	0,32	0,26	0,04	374,78
	27-Jul	74	21	5	0,85	0,70	0,37	0,31	0,13	761,59
	27 – 60	72	21	7	0,91	0,63	0,35	0,29	0,21	415,09
	60 – 90	65	23	12	0,94	0,59	0,33	0,27	0,18	307,56
	90 – 140	57	23	20	0,98	0,55	0,30	0,24	0,28	235,47
	140 – 155	43	20	39	1,05	0,48	0,24	0,19	0,07	165,77
	155 – 175	26	6	68	1,15	0,41	0,17	0,14	0,07	279,83
RR	0 – 11	60	38	2	0,85	0,69	0,37	0,30	0,07	590,80
	30-Nov	68	31	1	0,92	0,62	0,36	0,30	0,11	292,09
	30 – 48	68	29	3	0,92	0,62	0,35	0,29	0,11	301,78
	48 – 63	58	38	5	0,96	0,57	0,33	0,27	0,08	188,06
	63 – 82	76	23	1	0,89	0,65	0,38	0,32	0,12	455,95
SP	0 – 75	42	43	15	0,93	0,60	0,29	0,24	0,37	330,45
	75 – 120	52	31	17	1,00	0,54	0,29	0,24	0,25	172,25
TO	0 – 10	35	32	33	0,98	0,56	0,30	0,25	0,05	317,98
	18-	37	30	34	1,07	0,47	0,24	0,19	0,04	116,26
	18 – 29	41	22	37	1,06	0,48	0,24	0,19	0,05	152,25
	29 – 50	47	22	31	1,03	0,51	0,26	0,21	0,11	178,45
	50 – 75	47	19	34	1,03	0,51	0,26	0,21	0,13	194,62
	75 – 104	47	19	34	1,03	0,51	0,26	0,21	0,15	194,62
	104 – 150	47	24	29	1,03	0,51	0,26	0,21	0,24	169,90
	150 – 170	51	26	22	1,01	0,54	0,28	0,23	0,11	184,66

DP1 é o início da primeira janela de plantio, DF1 o final da primeira janela de plantio, DP2 o começo da segunda janela de plantio e DF2 o final da segunda janela de plantio. Ds = Densidade aparente; SAT = Ponto de saturação; CC = Capacidade de campo; PMP = Ponto de murcha permanente; CAD = Capacidade de água disponível; KS = Condutividade hidráulica.

Table 4. TBD = Base temperature for development; TBLV = Base temperature for juvenile

leaf area growth; TMD = Maximum temperature for development; TOD = Optimum temperature for development; DVRJ = Development rate in juvenile phase; DVRI = Development rate in photoperiod-sensitive phase; DVRP = Development rate in panicle development; DVRR = Development rate in reproductive phase; MOPP = Maximum optimum photoperiod; PPSE = Photoperiod sensitivity; SHCKD = Relation between seedling age and delay in phenological development.

Phenological parameters	Cultivars		
	IR72	BRS Catiana	IRGA 424
TBD	8	12	12
TBLV	8	12	12
TMD	42	42	42
TOD	30	30	30
DVRJ	0.000683	0.001323	0.001313
DVRI	0.000758	0.000842	0.000924
DVRP	0.000749	0.000799	0.000931
DVRR	0.001963	0.002423	0.002781
MOPP	11.5	11.5	11.5
PPSE	0	0	0
SHCKD	0.4	0.4	0.4

Table 5. RGRLMX = Maximum relative growth rate of leaf área; RGRLMN = Minimum relative growth rate of leaf area; SHADET = Tolerance index to shading with value 0.1 to 0.99; SHCKL = Relation between seedling age and delay in leaf area; SLA = $ASLA + BSLA \cdot \exp(CSLA \cdot (DVS - DSLA))$; SLAMAX = Maximum value of SLA (ha/kg); FRPAR = Fraction of sunlight energy that is photosynthetically active; SCP = Scattering coefficient of leaves for PAR; CO₂REF = Reference level of atmospheric CO₂; CO₂ = Ambient CO₂ concentration.

Leaf and stem growth parameters	Cultivars		
	IR72	BRS Catiana	IRGA 424
RGRLMX	0.0085	0.0129	0.0129
RGRLMN	0.004	0.0026	0.0028
SHADET	-	0.9	0.9
SHCKL	0.25	0.25	0.25
ASLA	0.0024	0.0024	0.0024
BSLA	0.0025	0.0025	0.0025
CSLA	-4.5	-4.5	-4.5
DSLA	0.14	0.14	0.14
SLAMAX	0.0045	0.0045	0.0045
FRPAR	0.5	0.5	0.5
SCP	0.2	0.2	0.2
CO ₂ REF	340	340	340
CO ₂	340	340	340

Table 6. KDFTB = Table of light extinction coefficient for leaves (-; Y-value) as a function of development stage; KNFTB = Table of extinction coefficient of N profile in the canopy (-; Y-value) as a function of development stage (-; X value); EFFTb = Table of light use efficiency (-; Y-value) as a function of temperature; REDFTT = Table of effect of temperature on AMAX (-; Y-value) as a function of temperature; NFLVTB = Table of N fraction in leaves on leaf area basis (g N m⁻² leaf; Y-value) as a function of development stage.

Leaf growth parameters	Cultivars					
	IR72		BRS Catiana		IRGA 424	
SLATB1	0	0.0045	0	0.0037	0	0.003
SLATB2	0.16	0.0045	0.16	0.0041	0.16	0.004
SLATB3	0.33	0.0033	0.33	0.0042	0.33	0.004
SLATB4	0.65	0.0028	0.65	0.0031	0.64	0.002
SLATB5	0.79	0.0024	0.79	0.0028	0.79	0.003
SLATB6	2.1	0.0023	2.1	0.0018	2.09	0.001
SLATB7	2.5	0.0023	2.5	0.0028	2.5	0.003
SSGATB1	0	0.0003	0	0.0003	0	0.0003
SSGATB2	0.9	0.0003	0.9	0.0003	0.9	0.0003
SSGATB3	2.1	0	2.1	0	2.1	0
SSGATB4	2.5	0	2.5	0	2.5	0
KDFTB1	0	0.4	0	0.4	0	0.4
KDFTB2	0.65	0.4	0.65	0.4	0.65	0.4
KDFTB3	1	0.6	1	0.6	1	0.6
KDFTB4	2.5	0.6	2.5	0.6	2.5	0.6
KNFTB1	0	0.4	0	0.4	0	0.4
KNFTB2	2.5	0.4	2.5	0.4	2.5	0.4
EFFTB1	0	0.54	0	0.54	0	0.54
EFFTB2	10	0.54	10	0.54	10	0.54
EFFTB3	40	0.36	40	0.36	40	0.36
REDFTT1	-10	0	-10	0	-10	0
REDFTT2	10	0	10	0	10	0
REDFTT3	20	1	20	1	20	1
REDFTT4	37	1	37	1	37	1
REDFTT5	43	0	43	0	43	0
NFLVTB1	0	0.54	0	0.54	0	0.54
NFLVTB2	0.16	0.54	0.16	0.54	0.16	0.54
NFLVTB3	0.33	1.53	0.33	1.53	0.33	1.53
NFLVTB4	0.65	1.22	0.65	1.22	0.65	1.22
NFLVTB5	0.79	1.56	0.79	1.56	0.79	1.56
NFLVTB6	1	1.29	1	1.29	1	1.29
NFLVTB7	1.46	1.37	1.46	1.37	1.46	1.37
NFLVTB8	2.02	0.83	2.02	0.83	2.02	0.83
NFLVTB9	2.5	0.83	2.5	0.83	2.5	0.83

Table 7. MAINLV = maintenance respiration coefficient ($\text{kg CH}_2\text{O kg}^{-1} \text{DM d}^{-1}$) of Leaves; MAINST = Stems; MAINSO = Storage organs; MAINRT = Roots; TREF = Reference temperature ($^{\circ}\text{C}$); Q10 = Factor accounting for increase in maintenance; CRGLV = Carbohydrate requirement for dry matter production ($\text{kg CH}_2\text{O kg}^{-1} \text{DM}$ leaf) in leaves; CRGST = Stems; CRGSO = Storage organs; CRGRT = Roots; CRGSTR = Stem reserves; LRSTR = Fraction of allocated stem reserve that is available for growth; FSTR = Fraction of carbohydrates allocated to stems that is stored as reserves; TCLSTR = Time coefficient for loss of stem reserves (1 d^{-1}); SPGF = Spikelet growth factor (no kg^{-1}); WGRMX = Maximum individual grain weight (kg grain^{-1}).

Parameter	IR72	BRS Catiana	IRGA 424
MAINLV	0.02	0.02	0.02
MAINST	0.015	0.015	0.015
MAINSO	0.003	0.003	0.003
MAINRT	0.01	0.01	0.01
TREF	25	25	25
Q10	2	2	2
CRGLV	1.326	1.326	1.326
CRGST	1.326	1.326	1.326
CRGSO	1.462	1.462	1.462
CRGRT	1.326	1.326	1.326
CRGSTR	1.11	1.11	1.11
LRSTR	0.947	0.947	0.947
FSTR	0.2	0.21	0.18
TCLSTR	10	10	10
SPGF	64900	64900	64900
WGRMX	2.49E-05	2.49E-05	2.49E-05

Table 8. FSHTB = Table of fraction total dry matter partitioned to the shoot; FLVTB = to the leaves; FSTTB = to the stems; FSOTB = to the panicles; DRLVT = leaf death coefficient.

Parameter	IR72		BRS Catiana		IRGA 424	
	Stage	Partitioning	Stage	Partitioning	Stage	Partitioning
FSHTB1	0	0.5	0	0.61	0	0.61
FSHTB2	0.43	0.72	0.43	0.93	0.43	0.93
FSHTB3	1	1	1	1	1	1
FSHTB4	2.5	1	2.5	1	2.5	1
FLVTB1	0	0.6	0	0.62	0	0.61
FLVTB2	0.5	0.6	0.61	0.37	0.61	0.37
FLVTB3	0.75	0.3	0.72	0.24	0.72	0.24
FLVTB4	1	0	0.88	0.07	0.88	0.06
FLVTB5	1.2	0	1.23	0	1.23	0
FLVTB6	2.5	0	2.5	0	2.5	0
FSTTB1	0	0.4	0	0.37	0	0.38
FSTTB2	0.5	0.4	0.61	0.62	0.61	0.62
FSTTB3	0.75	0.7	0.72	0.75	0.72	0.75
FSTTB4	1	0.4	0.88	0.45	0.88	0.47
FSTTB5	1.2	0	1.23	0.01	1.23	0.1
FSTTB6	2.5	0	2.5	0.02	2.5	0.02
FSOTB1	0	0	0	0	0	0
FSOTB2	0.5	0	0.61	0	0.61	0
FSOTB3	0.75	0	0.72	0	0.72	0
FSOTB4	1	0.6	0.88	0.4	0.88	0.46
FSOTB5	1.2	1	1.23	0.98	1.23	0.99
FSOTB6	2.5	1	2.5	0.97	2.5	0.97
DRLVT1	0	0	0	0	0	0
DRLVT2	0.6	0	0.6	0	0.6	0
DRLVT3	1	0.015	1	0.02	1	0.01
DRLVT4	1.6	0.025	1.6	0.02	1.6	0.01
DRLVT5	2.1	0.05	2.09	0.03	2.09	0.03
DRLVT6	2.5	0.05	2.5	0.05	2.5	0.06

Table 9. FCLV = Mass fraction carbon (kg C kg⁻¹ DM) in the Leaves; FCST = Stems; FCST = Storage orns; FCRT = Roots; FCSTR = Reserves; GZRT = Growth rate of roots (m d⁻¹); ZRTMCW= Maximum depth of roots if no drought stress (m); ZRTMCD = Maximum depth of roots if drought (m); RMINT = Minimum temperature for root growth; ROPTT = Optimum temperature of root growth; RTBS = Minimum temperature for root to survive; RCNL = Lowest root nitrogen content (residue root N content, kg N kg⁻¹ ROOT DM); SODT = The tolerance index of oxygen deficiency; ULLS = Upper limit leaf rolling (kPa); LLLS = Lower limit leaf rolling (kPa); ULDL = Upper limit death of leaves (kPa); LLDL = Lower limit death of leaves (kPa); ULLE = Upper limit leaf expansion (kPa); LLLE = Lower limit leaf expansion (kPa); ULRT = Upper limit relative transpiration reduction (kPa); LLRT = Lower limit relative transpiration reduction (kPa).

Carbon, root and water stress parameters	Cultivars		
	IR72	BRS Catiana	IRGA 424
FCLV	0.419	0.419	0.419
FCST	0.431	0.431	0.431
FCSO	0.487	0.487	0.487
FCRT	0.431	0.431	0.431
FCSTR	0.444	0.444	0.444
GZRT	0.01	0.01	0.01
ZRTMCW	0.25	0.25	0.25
ZRTMCD	0.4	0.4	0.4
ULLS	74.13	89.51	100
LLLS	794.33	424.89	570
ULDL	630.95	712.89	520
LLDL	1584.89	1268.17	1538
ULLE	1.45	1.33	1
LLLE	1404	1004	1184
ULRT	74.13	74.13	74
LLRT	1584.89	1584	1584

Table 10. NMAXUP = Maximum daily N uptake ($\text{kg N ha}^{-1} \text{ d}^{-1}$); RFNLV = Residual N fraction of leaves (kg N kg^{-1} leaves); FNTRT = Fraction N translocation from roots, as (additonal); RFNST = Residual N fraction of stems (kg N kg^{-1} stems); TCNTRF = Time coefficient for N translocation to grains (d); NFLVI = Initial leaf N fraction (on area basis: g N m^{-2} leaf); FNLVI = Initial leaf N fraction (on weight basis: kg N kg^{-1} leaf); NDSSENS = Nitrogen deficiency sensitivity, 0.5=fair as default; NMAXSO = Maximum N concentration in storage organs (kg N kg^{-1}).

Nitrogen parameters	Cultivars		
	IR72	BRS Catiana	IRGA 424
NMAXUP	8	8	8
RFNLV	0.004	0.004	0.004
FNTRT	0.15	0.12	0.103
RFNST	0.0015	0.0015	0.0015
TCNTRF	10	10	10
NFLVI	0.5	0.5	0.5
FNLVI	0.025	0.025	0.025
NDSSENS	-	1.05	1.05
NMAXSO	-	0.0175	0.0175