

**UNIVERSIDADE ESTADUAL PAULISTA**  
**FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS**  
**CAMPUS DE JABOTICABAL**

**MODELAGEM PARA AUXILIAR NA OTIMIZAÇÃO  
DO SISTEMA “CLIMATE-SMART-AGRICULTURE”  
PARA CULTIVO DE CANA-DE-AÇÚCAR**

**Victor Brunini Moreto**

Engenheiro Agrônomo Ms. Agronomia (Produção Vegetal)

**2019**

**UNIVERSIDADE ESTADUAL PAULISTA**  
**FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS**  
**CAMPUS DE JABOTICABAL**

**MODELAGEM PARA AUXILIAR NA OTIMIZAÇÃO DO  
SISTEMA “CLIMATE-SMART-AGRICULTURE” PARA  
CULTIVO DE CANA-DE-AÇÚCAR**

**Discente: Victor Brunini Moreto**

**Orientador: Prof. Dr. Glauco de Souza Rolim**

**Tese apresentada à Faculdade de  
Ciências Agrárias e Veterinárias –  
Unesp, Campus de Jaboticabal,  
como parte das exigências para  
obtenção do título Doutor em  
Agronomia (Produção Vegetal)**

M845m      Moreto, Victor Brunini  
Modelagem para auxiliar na otimização do sistema  
"Climate-Smart-Agriculture" para cultivo de cana-de-açúcar :  
modelagem para cana-de-açúcar / Victor Brunini Moreto. --  
Jaboticabal, 2019  
96 p.

Tese (doutorado) - Universidade Estadual Paulista (Unesp),  
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal  
Orientador: Glauco de Souza Rolim

1. Agricultura Previsão. 2. Eficiência do uso da água. 3.  
Computer software. 4. Agroindústria canavieira. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da  
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo  
autor(a).

Essa ficha não pode ser modificada.

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO DA TESE:** MODELAGEM PARA AUXILIAR NA OTIMIZAÇÃO DO SISTEMA "CLIMATE-SMART-AGRICULTURE" PARA CULTIVO DE CANA-DE-AÇÚCAR

**AUTOR:** VICTOR BRUNINI MORETO

**ORIENTADOR:** GLAUCO DE SOUZA ROLIM

Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA (PRODUÇÃO VEGETAL), pela Comissão Examinadora:

  
Prof. Dr. GLAUCO DE SOUZA ROLIM  
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal

  
Prof. Dr. JOSÉ RICARDO MACEDO PEZZOPANE  
Centro de Pesquisa de Pecuária do Sudeste-EMBRAPA / São Carlos/SP

  
Prof. Dr. JERRY ADRIANI JOHANN - Participação por videoconferência  
Centro de Ciências Exatas e Tecnológicas-UNIOESTE / Cascavel/PR

  
Prof. Dr. MARCÍLIO VIEIRA MARTINS FILHO  
Departamento de Solos e Adubos / FCAV / UNESP - Jaboticabal

  
Prof. Dr. NEWTON LA SCALA JUNIOR  
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal

Jaboticabal, 03 de maio de 2019

## **DADOS CURRICULARES DO AUTOR**

Victor Brunini Moreto, nascido em 29 de abril de 1988 no município Ribeirão Preto, Estado de São Paulo. Ingressou no curso de Engenharia Agrônômica na Faculdade de Ciências Agrárias e Veterinárias da Universidade Estadual Paulista “Júlio de Mesquita Filho” (FCAV-UNESP), Campus de Jaboticabal, em março de 2007. No mesmo campus, participou do Grupo integração Empresa Universidade (GIEU) durante a gestão 2009-2010. Foi bolsista do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), na modalidade de iniciação científica de 2010 a 2011. Em novembro de 2012 obteve o título de Engenheiro Agrônomo. Logo após iniciou o curso de mestrado no Campus de Jaboticabal, onde no final de 2014 obteve o título de mestre em Agronomia (Produção Vegetal). Em agosto de 2015 ingressou no programa de doutorado em Agronomia (Produção Vegetal) do Campus de Jaboticabal, onde aproximadamente quatro anos depois, defende sua tese para obtenção do título de doutor em Agronomia (Produção Vegetal). Durante o período de doutoramento desenvolveu a pesquisa em parceria com a Universidade Católica de Leuven na Bélgica, onde residiu entre setembro de 2017 a agosto de 2018 como bolsista da fundação de Coordenação de Aperfeiçoamento de Nível Superior (CAPES). Ao longo de sua trajetória acadêmica seguiu as linhas de pesquisa em agrometeorologia e modelagem de cultivos agrícolas; formou parcerias com empresas privadas e órgãos públicos para o desenvolvimento de trabalhos com objetivo de atender necessidades da sociedade na busca de novas tecnologias para agricultura e o agronegócio brasileiro.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## SUMÁRIO

|                                                                                                                     |    |
|---------------------------------------------------------------------------------------------------------------------|----|
| <b>CAPÍTULO 1 – Considerações Gerais</b> .....                                                                      | 1  |
| 1.1. O modelo AquaCrop da FAO .....                                                                                 | 3  |
| 1.2. REFERÊNCIAS .....                                                                                              | 5  |
| <b>CAPÍTULO 2 - Suporte à gestão do canavial com uso de previsões de precipitação do modelo Eta</b> .....           | 8  |
| 2.1. INTRODUÇÃO .....                                                                                               | 9  |
| 2.2. MATERIAL E MÉTODOS.....                                                                                        | 11 |
| 2.2.1. Área de estudo e observações meteorológicas .....                                                            | 11 |
| 2.2.2. O modelo Eta .....                                                                                           | 11 |
| 2.2.3. Avaliação das previsões do modelo Eta.....                                                                   | 13 |
| 2.2.4. Limiares de Precipitação .....                                                                               | 16 |
| 2.3. RESULTADOS E DISCUSSÃO .....                                                                                   | 17 |
| 2.3.1. Limiar PREC > 0 mm .....                                                                                     | 20 |
| 2.3.2. Outros Limiares .....                                                                                        | 23 |
| 2.3.3. ORSS - probabilidade de o desempenho não ser ao acaso .....                                                  | 24 |
| 2.4. CONCLUSÕES .....                                                                                               | 26 |
| 2.5. REFERÊNCIAS.....                                                                                               | 26 |
| <b>CAPÍTULO 3 – Modelo AquaCrop: parametrização e conversão de biomassa para o cultivo de cana de açúcar.</b> ..... | 30 |
| 3.1. INTRODUÇÃO .....                                                                                               | 31 |
| 3.2. MATERIAL E MÉTODOS.....                                                                                        | 33 |
| 3.2.1. Área de estudo e dados observados .....                                                                      | 33 |
| 3.2.2. Cálculo de biomassa do modelo AquaCrop .....                                                                 | 36 |
| 3.2.3. Parametrização do modelo AquaCrop .....                                                                      | 37 |
| 3.2.4. Adaptação do cálculo de biomassa do AquaCrop para cana .....                                                 | 38 |
| 3.2.5. Avaliação do desempenho do modelo.....                                                                       | 38 |
| 3.3. RESULTADOS.....                                                                                                | 40 |
| 3.3.1. Parametrização .....                                                                                         | 40 |
| 3.3.2. Coeficientes de conversão de biomassa .....                                                                  | 40 |
| 3.3.3. Calibração .....                                                                                             | 42 |
| 3.3.4. Validação.....                                                                                               | 43 |
| 3.3.5. Resposta das simulações às estações úmidas e secas .....                                                     | 45 |
| 3.4. DISCUSSÃO .....                                                                                                | 47 |
| 3.4.1. Coeficientes de crescimento e declínio (CGC e CDC, respectivamente...)                                       | 47 |
| 3.4.2. Coeficiente de estresse para expansão do dossel ( $K_{s_{exp}}$ ).....                                       | 47 |
| 3.4.3. Transpiração do cultivo .....                                                                                | 48 |

|                                                                                                                   |           |
|-------------------------------------------------------------------------------------------------------------------|-----------|
| 3.4.4. Coeficientes de conversão de biomassa .....                                                                | 48        |
| 3.4.5. Calibração .....                                                                                           | 49        |
| 3.4.6. Validação .....                                                                                            | 50        |
| 3.5. CONCLUSÕES .....                                                                                             | 52        |
| 3.6. REFERÊNCIAS .....                                                                                            | 53        |
| <b>CAPÍTULO 4 - Modelo AquaCrop: influência de estresses hídricos e térmicos no<br/>acúmulo de sacarose .....</b> | <b>60</b> |
| 4.1. INTRODUÇÃO .....                                                                                             | 61        |
| 4.2. DADOS E MÉTODOS .....                                                                                        | 63        |
| 4.2.1. Área de estudo e dados observados .....                                                                    | 63        |
| 4.2.2. Partição de biomassa em sacarose pelo índice de colheita .....                                             | 66        |
| 4.2.3. Determinação de fatores influentes no acúmulo de sacarose .....                                            | 68        |
| 4.2.4. Ajuste do $HI_0$ sob influência do estresse hídrico .....                                                  | 69        |
| 4.2.5. Método dos graus-dias negativos (NDD) .....                                                                | 69        |
| 4.2.6. Ajuste do $HI_0$ sob influência do estresse térmico .....                                                  | 70        |
| 4.2.7. Avaliação de desempenho das simulações .....                                                               | 71        |
| 4.3. RESULTADOS .....                                                                                             | 72        |
| 4.3.1. Análise de componentes principais e regressões lineares múltiplas .....                                    | 72        |
| 4.3.2. Ajustes dos estresses térmicos e hídricos no índice de colheita .....                                      | 74        |
| 4.3.3. Desempenho das simulações para acúmulo de sacarose e ATR .....                                             | 76        |
| 4.4. DISCUSSÃO .....                                                                                              | 79        |
| 4.4.1. Efeitos estresse hídrico e térmico no acúmulo de sacarose .....                                            | 79        |
| 4.4.2. Desempenho das simulações do acúmulo de sacarose .....                                                     | 80        |
| 4.5. CONCLUSÕES .....                                                                                             | 83        |
| 4.6. REFERÊNCIAS .....                                                                                            | 84        |

## MODELAGEM PARA AUXILIAR NA OTIMIZAÇÃO DO SISTEMA “CLIMATE-SMART-AGRICULTURE” PARA CULTIVO DE CANA-DE-AÇÚCAR

**RESUMO:** A agricultura no mundo caminha em alta velocidade para a próxima revolução verde, a chamada revolução da agricultura digital, que combina outras grandes áreas que revolucionaram a agricultura, como as técnicas de biotecnologia e agricultura de precisão. Estas técnicas foram essenciais para aumento da produtividade agrícola no mundo. Em adição, a agricultura digital pode otimizar ainda mais a associação dos dados climáticos no planejamento de safras e no manejo de cultivos agrícolas. O conceito “Climate-Smart-Agriculture” (CSA) está inserido no universo da agricultura digital como uma linha promissora e necessária para o futuro sustentável da agricultura. Este trabalho apresenta técnicas para auxiliar na adoção de estratégias CSA para áreas produtoras de cana-de-açúcar, como (i) verificação da acurácia do modelo de previsão de tempo Eta (INPE) para áreas de cultivo de cana-de-açúcar no Brasil, visando auxiliar na tomada de decisão de operações no campo; (ii) parametrização do modelo AquaCrop-FAO para estimação de produtividade e qualidade da produção, colaborando com planejamento e sustentabilidade do setor; (iii) proposta de modificação nos cálculos do modelo AquaCrop-FAO para estimar concentração de sacarose. As técnicas propostas neste trabalho mostraram-se eficientes e promissoras para aplicação prática. Foi possível avaliar e identificar a acurácia do modelo de predição de tempo (Eta) das áreas canavieiras, com previsões confiáveis até quatro dias e probabilidade de acerto na detecção de chuvas de 70%. O uso do modelo AquaCrop apresentou acurácia nas estimações de biomassa na calibração e validação, com MAPE de, 7,65% e 13,45%, respectivamente. Para sacarose, as estimações do modelo apresentaram valores de MAPE menores do que 5,0% na calibração e validação.

**Palavras-Chave:** agricultura digital, modelo de cultivos agrícolas, *Sacharum ssp.*, condições climáticas, AquaCrop-FAO, previsão de precipitação.

## MODELS TO AUXILIATE THE OPTIMIZATION OF "CLIMATE-SMART-AGRICULTURE" SYSTEM FOR SUGARCANE CULTIVATION

**ABSTRACT:** Agriculture in the world is moving at a rapid pace to the next green revolution, the so-called digital agriculture revolution, which combines other major areas that have revolutionized agriculture, such as biotechnology and precision agriculture. These techniques were essential for increasing agricultural productivity in the world. Digital agriculture can now further optimize the association of climatic data in crop planning and crop management. The concept "Climate-Smart-Agriculture" (CSA) is inserted in the digital agriculture universe as a promising and necessary line for the sustainable future of agriculture. This paper presents techniques to assist in the adoption of CSA strategies for sugarcane producing areas, such as (i) verification of the accuracy of the Eta (INPE) weather forecast model for important sugarcane producing areas in Brazil, aiming at assisting in the decision making of operations in the field; (ii) parameterization of the AquaCrop-FAO model for the estimation of productivity and quality of production, collaborating with planning and sustainability of the sector; (iii) proposal for modification in the calculations of the AquaCrop-FAO model to estimate sucrose concentration. The techniques proposed in this work prove to be efficient and promising for practical application. It was possible to evaluate and to identify the accuracy of the time prediction model (Eta) of the sugarcane areas, with reliable predictions up to four days and probability of detection of rainfall of 70%. The use of the AquaCrop model presented accuracy in the estimations of biomass in the calibration and validation, with MAPE of, 7.65% and 13.45%, respectively. For the sucrose estimation the MAPE values were lower than 5.0% in the calibration and validation of the model.

**KEY-WORDS:** digital agriculture, crop models, *Sacharum* ssp, weather conditions, AquaCrop-FAO, precipitation forecasts.

## **CAPÍTULO 1 – Considerações Gerais**

A agricultura é umas das atividades humanas mais sensíveis ao clima onde variações nas temperaturas e no regime de precipitação pluvial impactam em todas as etapas da produção. Compra de insumos, plantio, operações no campo, irrigação, adubação, colheita e o planejamento econômico de safras, são exemplos de atividades da cadeia agrícola que são diretamente dependentes dos fatores climáticos e do ambiente (Ackerman e Santon, 2013).

O aumento populacional e a demanda por alimentos incentivam cada vez mais a busca dos pesquisadores, dos profissionais da área e de investidores, no entendimento das relações entre o clima e a produção agrícola. Nesse âmbito surgem novos conceitos e tecnologias para ajudar na busca do melhor atendimento das interações climáticas, agronômicas, econômicas e de sustentabilidade para o agronegócio.

A agricultura digital ou “*smart farming*” (agricultura inteligente – tradução livre) é combinação de ciência de dados e a agricultura para relacionar grande quantidade de dados e informações pertinentes na gestão antecipada e automatizada das atividades agrícolas (Prototop e Shanoyan, 2016; Bertschi, 2018).

Associado ao conceito de agricultura digital está a abordagem “*Climate-Smart Agriculture (CSA)*” (agricultura inteligente adequada ao clima – tradução livre). CSA baseia-se em integrar estratégias para melhorar o planejamento, adaptação e manejo da atividade agrícola, trabalhando com três objetivos simultâneos: (i) aumentar a produtividade e renda de forma sustentável, (ii) aumentar a capacidade de adaptação às mudanças climáticas, e (iii) reduzir as emissões de gases do efeito estufa (Rao, 2018; FAO, 2019).

A maneira mais conhecida para aplicação de estratégias CSA é pelo uso de modelos de cultivos (“*crop models*”). Modelo por definição é uma representação de um sistema. Os modelos podem ser (i) matemáticos, quando o sistema é descrito por meio de equações, (ii) empíricos ou estatísticos, quando descrevem correlações entre variáveis sem necessariamente se referir ao processo modelado, e (iii) mecanísticos ou explicativos, que expressam as relações de causa e efeito entre as variáveis (Dourado Neto et al., 1998).

Os modelos de cultivos são importantes ferramentas para simular o crescimento e desenvolvimento das plantas. Na atualidade a modelagem de cultivos é uma ferramenta poderosa, considerada como a melhor forma de transferir o conhecimento da pesquisa para o produtor ou profissional da área (Zhao et al., 2019; Sihag e Prakash, 2019).

As técnicas de modelagem de cultivos podem simular as interações do sistema solo-planta-atmosfera, avaliar o impacto das mudanças climáticas e realizar a previsão da produção de safras agrícolas. O uso de modelos de previsão de safras pode melhorar a qualidade da produção, aumentar a produtividade, minimizar a incidência de pragas e o custo de produção (Avadhani et al., 2019; Sihag e Prakash, 2019).

São diversos os exemplos de modelos de estimação e/ou previsão de safras agrícolas. Dentre os mais conhecidos encontram-se os modelos mecanísticos: DSSAT - *Decision Support System for Agrotechnology Transfer* (Jones et al., 2003), o modelo AQUACROP-FAO, que relaciona a produtividade da água e a produtividade agrícola (Steduto et al., 2009) e o APSIM – *Agricultural Production System siMulator* (McCown et al., 1996). Estes modelos mecanísticos fazem a representação das relações do sistema solo-planta-atmosfera para vários cultivos agrícolas, e permitem que o usuário adapte seus parâmetros de acordo com sua necessidade.

Em relação ao cultivo da cana-de-açúcar, o DSSAT-Canegro e o APSIM-Sugarcane são os mais usados. A maior dificuldade no uso de modelos de cultivos está no elevado número de parâmetros de entrada, normalmente trabalhosos e difíceis de serem mensurados no campo (Marin et al., 2011; Pagani et al., 2017; Carvalho et al., 2018; Dias e Sentelhas 2018).

O modelo AquaCrop, muito usado pela sua simplicidade, tem foco principal para cultivos anuais, como milho, trigo e soja. A calibração do modelo para o cultivo da cana-de-açúcar é recente, com poucos trabalhos usando o AquaCrop para previsão de safras de cana-de-açúcar no mundo (Bello et al., 2013; Bahmani e Eghbalian, 2018) e no Brasil (Alencar, 2014).

O cultivo da cana-de-açúcar é de importância mundial, seja para produção de açúcar ou ainda com mais peso no mercado atual para a indústria de

biocombustíveis. O Brasil é o maior produtor de cana-de-açúcar do mundo e o segundo maior produtor de bioetanol, com a maior frota de carros de combustível flex (Souza et al., 2015; Oliveira et al., 2019).

A elevada demanda dos produtos derivados do cultivo da cana-de-açúcar estabelece uma necessidade para o setor sucroalcooleiro em acompanhar os novos aspectos da agricultura. De acordo com o Fórum de Economia Mundial - *World Economic Forum* (2016) a agricultura digital e o sistema CSA são potencialmente os maiores aceleradores de tecnologias de produção agrícola. Esta fusão da ciência de dados e agricultura poderá ajudar produtores, pesquisadores e profissionais do setor, a tomar decisões baseadas na otimização da produtividade, aumento da receita e minimização de custos (Rosenzweig et al., 2013; Capalbo et al., 2017, Antle et al., 2017; Rao, 2018).

Este estudo busca apresentar técnicas para abordagem CSA com foco em áreas de cultivo da cana-de-açúcar. Nos próximos capítulos serão apresentadas ferramentas de suporte para auxílio na gestão do setor canavieiro, com os objetivos de: (i) avaliar a qualidade das previsões de precipitação feitas pelo modelo Eta em regiões produtoras de cana-de-açúcar; (ii) parametrizar o modelo AquaCrop-FAO para estimação de biomassa ( $t\ ha^{-1}$ ), teor de sacarose ( $t\ ha^{-1}$ ) e açúcar total recuperável (ATR,  $kg\ t^{-1}\ ha^{-1}$ ).

### **1.1. O modelo AquaCrop da FAO**

O AquaCrop é um modelo de cultivos agrícolas desenvolvido pela divisão de manejo do solo e da água da Organização das Nações Unidas para a Alimentação e a Agricultura (*Food and Agriculture Organization of the United Nations* - FAO) para abordar a segurança alimentar e avaliar o efeito do ambiente e da gestão na produção de cultivos agrícolas.


Derivado do relatório 33 da FAO, Irrigação e Drenagem (Doorembos e Kassam, 1979), o modelo AquaCrop é baseado na água efetivamente usada pelas plantas e nos processos do sistema solo-planta-atmosfera. Simula a resposta da planta à água e é particularmente adequado para abordar condições em que a água é um fator limitante fundamental na produção dos cultivos.

O AquaCrop usa um número relativamente pequeno de parâmetros explícitos e variáveis de entrada na maioria intuitivas que podem ser

determinados por métodos simples. As quatro etapas de funcionamento do modelo são sequenciais e seus cálculos na escala diária. Primeiro é simulado o desenvolvimento da planta até o fechamento do dossel. No modelo o fechamento do dossel é representado pela fração da superfície do solo coberta pelas plantas.

Na segunda etapa são calculadas as taxas de transpiração das plantas em função da evapotranspiração de referência e um coeficiente de cultivo proporcional a vegetação que constitui o dossel. Por fim, terceira e quarta etapa simulam o acúmulo de biomassa e a produtividade, respectivamente (Figura 1).

A biomassa simulada é proporcional a transpiração acumulada no decorrer do ciclo e a eficiência da água efetivamente utilizada pelas plantas. O cálculo de biomassa integra todos os produtos fotossintéticos assimilados pela planta durante ciclo. A produtividade é calculada multiplicando o valor final de biomassa por um coeficiente de colheita, resultando na fração de biomassa que é produto da colheita do cultivo.



**Figura 1.** Esquema de cálculo do AquaCrop com a indicação das 4 etapas, e os processos (setas pontilhadas) afetados pelo estresse hídrico (a, b, c, d, e) e estresse de temperatura (f, g).

CC é a fração de superfície do solo coberta pela vegetação (fechamento do dossel). Zr é profundidade de raízes, ETo evapotranspiração de referência; WP\* é água efetivamente utilizada pela planta; HI é o índice de colheita e GDD é o acúmulo de graus-dia.

Possíveis efeitos em ocorrência de estresse hídrico: (a) diminui a expansão do dossel, (b) acelera a senescência do dossel, (c) diminui o aprofundamento radicular, (d) reduz a abertura estomática e a transpiração, e (e) afeta o índice de colheita.

Possíveis efeitos do estresse térmico: (f) reduz a transpiração da cultura, (g) inibe a polinização e reduz o HI.

Outras informações e detalhes sobre o funcionamento do modelo AquaCrop são encontradas nos manuais de referência da FAO: Steduto et al., 2009 e Raes et al., 2017, e no site do modelo: <http://www.fao.org/aquacrop/>.

## 1.2. REFERÊNCIAS

Ackerman F., Santon, E. A. Climate Impacts on Agriculture: A Challenge to Complacency? Global Development and Environment institute, Working Paper, n 13-01. 2013.

Alencar, L.P. Parametrização e validação do modelo AquaCrop para cultura da cana-de-açúcar – TESE – Universidade Federal de Viçosa, Minas Gerais, 2014.

Antle JM, Jones JW, and Rosenzweig CE. Next generation agricultural system data, models and knowledge products: Introduction, *Agricultural Systems*, 155: 179–185, 2017.

Avadhani S.S., Arun A.B., Govinda V., Inamdar J.S.I. Crop Prediction Models—A Review. In: Abraham A., Dutta P., Mandal J., Bhattacharya A., Dutta S. (eds) *Emerging Technologies in Data Mining and Information Security. Advances in Intelligent Systems and Computing*, vol 755. Springer, Singapore, 2019

Bahmani, O., Eghbalian, S. Simulating the Response of Sugarcane Production to Water Deficit Irrigation Using the AquaCrop Model. *Agric Res*, 7(2):158–166. 2018, <https://doi.org/10.1007/s40003-018-0311-0>.

Bello, CAC. Uso del modelo Aquacrop para estimar rendimientos para el cultivo de caña de azúcar en el departamento del valle del Cauca. 66p. 2013. ISBN I3427S/1/08.13.

Capalbo SM, Antle JM, Seavert C. Next generation data systems and knowledge products to support agricultural producers and science-based policy decision making, *Agricultural Systems*, 155, 191-99, 2017.

Dias, H.B., Sentelhas, P.C. Sugarcane yield gap analysis in Brazil – A multi-model approach for determining magnitudes and causes. *Sci of Total Environment*. 637(638):1127-1136, 2018.

Dourado Neto, D., Teruel, D. A., Reichardt, K., Nielsen, D.R., Frizzzone, J.A., Bacchi, O.O.S. Principles of crop modeling and simulation: I. Uses of mathematical models in agriculture science, *Sci. Agric. Piracicaba*, 55, p.46-50, 1998.

FAO, Food and Agriculture Organization of the United Nations – Climate-Smart Agriculture, 2019 <http://www.fao.org/climate-smart-agriculture/en/>

Jones, J.W., G. Hoogenboom, C.H. Porter, K.J. Boote, W.D. Batchelor, L.A. Hunt, P.W. Wilkens, U. Singh, A.J. Gijsman, and J.T. Ritchie. DSSAT Cropping System Model. *European Journal of Agronomy* 18:235-265, 2003

Carvalho, A.L. et al. Sugarcane Productivity Simulation under Different Planting Times by DSSAT/CANEGRO Model in Alagoas, Brazil. *Emirates Journal of Food and Agriculture*.30(3),190-198, 2018.

Marin, F. R. ,et al. Parameterization and Evaluation of Predictions of DSSAT/CANEGRO for Brazilian Sugarcane. *Agron. J.* 103:304-315, 2011. doi:10.2134/agronj2010.0302

McCown, R.L., Hammer, G.L., Hargreaves, J.N.G., Holzworth, D.P., Freenairn, D.M. APSIM: a novel software system for model development, model testing and simulation in agricultural systems research. *Agricultural Systems*, 50(3), 255-271, 1996.

Oliveira, D.M.S. et al., Is the expansion of sugarcane over pasturelands a sustainable strategy for Brazil's bioenergy industry? *Renewable and Sustainable Energy Reviews*. 102, 346-355, 2019.

Pagani V. et al. Forecasting sugarcane yields using agro-climatic indicators and Canegro model: A case study in the main production region in Brazil. *Agricultural Systems*, 154, 45-52, 2017

Protopop, I., Shanoyan, A. Big Data and Smallholder Farmers: Big Data Applications in the Agri-Food Supply Chain in Developing Countries. *International Food and Agribusiness Management Review* 19 (A): 173–90. 2016

Raes, D.; Steduto, P.; Hsiao, T.C.; Fereres, E. AquaCrop version 6.0 reference manual. Rome: FAO, 2017.

Rao, N. H. Big Data and Climate Smart Agriculture - Status and Implications for Agricultural Research and Innovation in India, *Proceedings of the Indian National Science Academy*. 2018

Rosenzweig C. et al. The Agricultural Model Intercomparison and Improvement Project (AgMIP): Protocols and pilot studies, *Agricultural and Forest Meteorology* Vol 170, 166–182, 2013.

Sihag J., Prakash D. A Review: Importance of Various Modeling Techniques in Agriculture/Crop Production. In: Ray K., Sharma T., Rawat S., Saini R., Bandyopadhyay A. (eds) *Soft Computing: Theories and Applications. Advances in Intelligent Systems and Computing*, vol 742. Springer, Singapore, 2019

Souza et al. Sugarcane processing for ethanol and sugar in Brazil. *Environmental Development*, 15, 35-51, 2015.

Steduto, P., Hsiao, T.C., Fereres, E. AquaCrop-the FAO crop model to simulate yield response to water: I. Concepts and underlying principles. *Agronomy Journal*, 101(3), 426-437, 2009.

World Economic Forum. The Global Risks Report, 2016; 11th Edition, World Economic Forum, Geneva, Switzerland, 103 pp. 2016

Zhao C. et al. A SIMPLE crop model. *European Journal of Agronomy* 104, 97-106, 2019.

## **CAPÍTULO 2 - Suporte à gestão do canavial com uso de previsões de precipitação do modelo Eta**

**RESUMO:** A precisão das previsões meteorológicas costumam ser motivo de crítica pelos agricultores, devido principalmente às eventuais falhas na previsão de eventos de precipitação e consequentes perdas ambientais e de produtividade. Eventos de precipitação podem interferir no preparo do solo, plantio, aplicação de pesticidas e colheita. Modelos de previsão de precipitação são ferramentas que facilitam a tomada de decisões em atividades agrícolas, portanto, alta precisão é desejável. Neste estudo, foram avaliadas as previsões de precipitação do modelo Eta sobre 28 áreas de produção de cana-de-açúcar do Brasil, considerando uma malha de 15 x 15 km. Foram usadas tabelas de contingência de verificação dicotômica na comparação dos dados de precipitação observados por estações meteorológicas e previstos pelo modelo Eta, num período de seis anos. Foram usados índices de desempenho para avaliar as previsões do modelo e sua robustez. As previsões de precipitação do Modelo Eta apresentaram precisão geral superior a 55% e 71%, para as regiões de Mata Atlântica (Noroeste e Sudeste de São Paulo) e Cerrado (Estado de Goiás e Centro-Norte de São Paulo), respectivamente. As previsões são na maior parte confiáveis até quatro dias, com uma precisão de 60%. As previsões para períodos de mais de quatro dias têm uma precisão média de 40 a 50%. A probabilidade em detectar corretamente a ocorrência de precipitação é a característica mais forte do Modelo Eta, com mais de 70% de acurácia.

**PALAVRAS-CHAVE:** precipitação, clima, cana-de-açúcar, planejamento, safra.

### **SUGARCANE CROP DECISION-MAKING SUPPORT USING ETA MODEL PRECIPITATION FORECASTS**

**ABSTRACT:** The accuracy of weather forecasts is often criticized by farmers, mainly due to possible failures in forecasting precipitation events and consequent environmental and productivity losses. Precipitation events can interfere with soil preparation, planting, pesticide application, and harvesting. Precipitation forecasting models are tools that facilitate decision making in agricultural activities, so high accuracy is desirable. In this study, the Eta model precipitation forecasts were evaluated on 28 sugarcane production areas in Brazil, considering

a 15 x 15 km grid. Dichotomic verification contingency tables were used in the comparison of precipitation data observed by meteorological stations and predicted by the Eta model over a period of six years. Performance indices were used to evaluate the predictions of the model and its robustness. The precipitation forecasts of the Eta model presented general accuracy higher than 55% and 71% for the Atlantic Forest (Northwest and Southeast of São Paulo) and Cerrado (Goiás State and Central-North of São Paulo) regions, respectively. The forecasts are mostly reliable up to four days with an accuracy of 60%. Predictions for periods of more than four days have an average accuracy of 40-50%. The probability of correctly detecting the occurrence of precipitation is the strongest feature of the Eta Model, with more than 70% of accuracy.

**KEY-WORDS:** rainfall, climate prediction, crop management, *Sacharum* ssp.

## 2.1. INTRODUÇÃO

O clima é o principal fator responsável pela variabilidade sazonal na produção agrícola. A previsão do tempo é uma ferramenta importante para lidar com a incerteza relacionada à essa variabilidade e é usada em vários assuntos, incluindo hidrologia, agricultura e economia. Um dos usos das previsões meteorológicas é apoiar as fazendas e a decisão do agronegócio para o manejo da irrigação, plantio, colheita, armazenamento, vendas e seguro da produção (Sonka et al., 1992; Frisvold e Murugesan, 2012).

A falta de precisão dos modelos de previsões de precipitação prejudica o planejamento e gestão das operações e da produção agrícola. Os erros nos modelos de previsão de precipitação estão relacionados a (i) medições pontuais representando grandes áreas, (ii) erros observacionais de medição e (iii) recursos limitados para processamento (IPCC, 2013). Murphy (1993) descreveu três indicadores para descrever a habilidade de um modelo de previsão de precipitação: consistência, qualidade e valor.

*Consistência* é o melhor julgamento do previsor em comparação com os eventos reais. Se não há descrição de incerteza na análise do previsor, não corresponde ao melhor julgamento (Theis et al., 2005). A *qualidade* expressa a relação entre os eventos reais (observados) e as previsões desses eventos.

Depende da correspondência entre as previsões e as observações correspondentes. E, *valor* (ou utilidade) é o grau em que a previsão ajuda um tomador de decisão a realizar algum incremento econômico (Thornes e Stephenson, 2001). Uma maneira de quantificar os erros de um modelo de previsão se dá atribuindo índices de desempenho ao comparar múltiplas observações com as previsões do modelo (Wilks, 2011).

Os índices de desempenho são importantes para avaliar a precisão dos modelos de previsão e gerenciar incertezas de previsões (Hansen, 2002). Klemm e McPherson (2017) declaram que mais pesquisas interdisciplinares são necessárias para melhorar e testar a precisão dos modelos de previsão e facilitar a tomada de decisões nas áreas de produção agrícola.

O Brasil é o maior produtor de cana-de-açúcar (*Sacharum ssp*) no mundo, seguido pela Índia e China. Em 2015/2016, os agricultores brasileiros colheram mais de 665 milhões toneladas de cana-de-açúcar, fazendo com que a produção brasileira superasse seus seis concorrentes mais próximos (WORDATLAS; ÚNICA, 2017). Eventos de precipitação influenciam na gestão econômica da cultura da cana-de-açúcar representando um papel importante no planejamento e gestão das áreas de cana-de-açúcar.

O modelo Eta, é um modelo de previsão de tempo amplamente utilizado em vários países europeus, africanos, asiáticos e da América do Sul (Muller e Miguel, 2016). Operando desde 1993 no Centro Nacional de Previsão Ambiental (NCEP) nos EUA (Black, 1994), e sendo o modelo oficial de previsão de tempo usado pelo Centro de Previsão do Tempo e Estudos Climáticos - Instituto Nacional de Pesquisas Espaciais (CPTEC-INPE), o modelo Eta é usado para previsões de precipitações em todo o Brasil dividido em grids de 40 x 40 km e 15 x 15 km (Chou et al. 2005).

Neste estudo, propomos avaliar as previsões de precipitação do modelo Eta, verificando sua consistência, qualidade e utilidade para as áreas de produção de cana-de-açúcar do Brasil.

## 2.2. MATERIAL E MÉTODOS

### 2.2.1. Área de estudo e observações meteorológicas

Observações diárias de precipitação para os 28 municípios produtores de cana-de-açúcar (Tabela 1) foram obtidas do Instituto Agrônomo (IAC, Campinas, Brasil) e do Instituto Nacional de Meteorologia (INMET) de 01/01/2005 a 31/12/2010. Os municípios utilizados nesse estudo concentram-se na região Centro-Sul do Brasil (Figura 1).

Os dados de precipitação observados foram coletados em estações meteorológicas de superfície automatizadas (Campbell Scientific Ltd. ®) equipadas com pluviômetros automáticos e calibrados (tipos TE525WS-L, TE525MM-L e TB5MM-L).

### 2.2.2. O modelo Eta

O modelo Eta é representado pela letra grega  $\eta$  (eta). Na previsão numérica de tempo,  $\eta$  refere-se a um sistema de coordenadas particular que representa a estrutura vertical da atmosfera com o nível médio do mar como base (Mesinger, 1984; equação 1).

$$\eta = \left( \frac{p - p_t}{p_s - p_t} \right) \left[ \frac{p_r(z_s) - p_t}{p_r(0) - p_t} \right] \quad (1)$$

sendo,  $p$  é pressão do ar (hPa) e  $z$  é altura (m), com índices  $t$  para o modelo superior,  $s$  para a superfície do modelo, o índice  $r$  refere-se a uma atmosfera de referência prescrita,  $p_r(0)$  é pressão do ar na altura 0 m e  $p_r(z_s)$  é a pressão do ar na superfície do modelo, com ambas as pressões tomadas de uma atmosfera de referência.


A representação correta da estrutura vertical da atmosfera leva a melhores previsões por modelos numéricos de previsão do tempo. O sistema de coordenadas do modelo Eta define a posição vertical de um ponto na atmosfera como uma razão entre a diferença de pressão entre esse ponto e o topo do domínio sobre a diferença de pressão entre uma base fundamental abaixo do ponto e o topo do domínio. As coordenadas variam entre 1 na base e 0 na parte superior do domínio.

**Tabela 1.** Lista dos municípios utilizados para avaliação das previsões de precipitação do modelo Eta.

| nº | Município                | Estado | Latitude (Sul) | Longitude (Oeste) |
|----|--------------------------|--------|----------------|-------------------|
| 1  | Avaré                    | SP     | 23°05'56"      | 48°55'33"         |
| 2  | Limeira                  | SP     | 22°33'54"      | 47°24'07"         |
| 3  | Piracicaba               | SP     | 22°43'30"      | 47°38'56"         |
| 4  | Rancharia                | SP     | 22°13'44"      | 50°53'34"         |
| 5  | Bauru                    | SP     | 22°18'54"      | 49°03'39"         |
| 6  | Paraguaçu Paulista       | SP     | 22°24'46"      | 50°34'33"         |
| 7  | Campos do Jordão         | SP     | 22°44'20"      | 45°35'27"         |
| 8  | Matão                    | SP     | 21°36'10"      | 48°28'57"         |
| 9  | São Carlos               | SP     | 22°00'00"      | 47°53'27"         |
| 10 | Sorocaba                 | SP     | 23°30'07"      | 47°27'28"         |
| 11 | Taubaté                  | SP     | 23°01'33"      | 45°33'31"         |
| 12 | Barretos                 | SP     | 20°33'35"      | 48°34'04"         |
| 13 | Bebedouro                | SP     | 20°56'56"      | 48°28'44"         |
| 14 | Votuporanga              | SP     | 20°25'22"      | 49°58'22"         |
| 15 | Batatais                 | SP     | 20°53'27"      | 47°35'06"         |
| 16 | Jaboticabal              | SP     | 21°15'18"      | 48°19'19"         |
| 17 | São Simão                | SP     | 21°28'44"      | 47°33'03"         |
| 18 | Catanduva                | SP     | 21°08'16"      | 48°58'22"         |
| 19 | Guaíra                   | SP     | 20°19'04"      | 48°18'39"         |
| 20 | São Sebastião do Paraíso | MG     | 20°55'01"      | 46°59'27"         |
| 21 | Guaxupé                  | MG     | 21°18'18"      | 46°42'46"         |
| 22 | Monte Santo de Minas     | MG     | 21°11'24"      | 46°58'48"         |
| 23 | Frutal                   | MG     | 20°01'30"      | 48°56'27"         |
| 24 | Uberaba                  | MG     | 19°44'52"      | 47°55'55"         |
| 25 | Itumbiara                | GO     | 18°25'12"      | 49°13'04"         |
| 26 | Rio Verde                | GO     | 17°47'52"      | 50°55'40"         |
| 27 | Jataí                    | GO     | 17°52'51"      | 51°42'50"         |
| 28 | Pedro Afonso             | TO     | 08°54'04"      | 48°10'30"         |

Os dados de previsão de precipitação do modelo Eta foram obtidos do CPTEC-INPE em intervalos horários, na resolução de grids de 15 x 15 km de. Esses foram agregados ao passo de tempo diário para avaliação do desempenho do modelo.

Mais informações sobre uso e cálculos do modelo Eta podem ser encontradas em Mesinger et al. (2016).



**Figura 1.** Principais áreas de produção de cana-de-açúcar no Brasil (UNICA, 2017).

### 2.2.3. Avaliação das previsões do modelo Eta

No Brasil, as previsões de precipitação do Modelo Eta são feitas para períodos de dez dias. O dia 0 representa o dia em que o modelo começa a operar e os dias 1 a 10 os dias de previsão (*days of forecast*, DF). Por exemplo, se o modelo for começar a operar no dia 0 (01/01/2000), suas previsões vão até os próximos 10 dias (11/01/2000). Portanto, se o modelo Eta é iniciado novamente em 02/01/2000 (dia 0), as previsões de precipitação vão até 12/01/2000 (dia 10).

Os dados de previsão e os dados observados foram organizados em períodos de dez dias, seguindo o esquema das previsões de precipitação do modelo Eta. Todas as comparações entre dados observados e previstos foram feitas para cada DF separadamente.

A verificação dicotômica foi utilizada para avaliar as previsões de precipitação do modelo Eta. Este método binário (sim / não) avalia os acertos verdadeiros (*hits*, HIT), erros (*misses*, MISS), alarmes falsos (*false alarms*, FA) e negativos corretos (*correct negatives*, CN, Tabela 2), que podem ser combinados para calcular os índices de desempenho do modelo (Tabela 3).

HIT indica que um evento previsto para ocorrer realmente ocorreu. CN mede as previsões corretas do modelo quando não choveu (ou quando a quantidade de precipitação (PREC) foi menor que os limiares analisados ( $> 0$  mm,  $<5$  mm a  $<40$  mm)). É importante entender que CN também são considerados como acertos do modelo.

MISS e FA indicam vezes que o modelo estava errado em suas previsões, sendo um evento previsto para não ocorrer que ocorreu na realidade e um evento previsto para ocorrer que não ocorreu na realidade, respectivamente.

**Tabela 2.** Esquema de análise dos elementos da tabela de contingência para verificação dicotômica. HIT: acertos verdadeiros, CN: negativos corretos, FA: alarmes falsos e MISS: erros.

| Evento Previsto | Evento Observado | Resposta |         |
|-----------------|------------------|----------|---------|
| SIM             | SIM              | HIT      | acertos |
| NÃO             | NÃO              | CN       |         |
| SIM             | NÃO              | FA       | erros   |
| NÃO             | SIM              | MISS     |         |

**Tabela 3.** Resumo dos elementos da tabela de contingência usados para calcular os índices de desempenho. ACC é a acurácia geral, POD: a probabilidade de detecção de um evento, SR: taxa de sucesso, B: viés, CSI: índice crítico de sucesso, ORSS: probabilidade de o desempenho não ser ao acaso. HIT: acertos verdadeiros, CN: negativos corretos, FA: alarmes falsos e MISS: erros

|      | HIT | MISS | FA | CN |
|------|-----|------|----|----|
| ACC  | X   | X    | X  | X  |
| *POD | X   | X    |    |    |
| *SR  | X   |      | X  |    |
| *B   | X   | X    | X  |    |
| *CSI | X   | X    | X  |    |
| ORSS | X   | X    | X  | X  |

(\*) índices de desempenho utilizados no diagrama de desempenho proposto por Roebber (2009) para avaliar modelos de previsão de precipitação.

Os índices de desempenho usados para avaliar as previsões de precipitação do modelo Eta foram acurácia (*Accuracy*, ACC, equação 2), probabilidade de detecção (*Probability Of Detection*, POD, equação 3), índice de

sucesso (*Success Ratio*, SR, equação 4), viés (*Bias*, B, equação 5), índice crítico de sucesso (*Critical Success Index*, CSI, equação 6) e a probabilidade de o desempenho não ser ao acaso (*Odds Ratio Skill Score*, ORSS, equação 7).

O ACC é a acurácia geral e mede a fração de previsões corretas de todo o conjunto de dados. Quanto maior o valor do ACC, melhor o desempenho do modelo

$$ACC = \frac{HIT+CN}{HIT+MISS+CN+FA} \quad (2)$$

POD, ou taxa de acerto, indica qual fração dos eventos "sim" observados foi corretamente prevista pelo modelo. O POD é sensível a HIT, mas não considera negativos corretos (CN) ou alarmes falsos (FA). Quanto mais próximos de 1.00 os valores de POD, melhor o desempenho do modelo.

$$POD = \frac{HIT}{HIT+MISS} \quad (3)$$

SR informa sobre um evento observado, dado que foi previsto. O SR é sensível a FA e expressa qual fração dos eventos "sim" previstos foram efetivamente observados. Quanto mais próximos de 1.00 os valores de SR melhor desempenho do modelo.

$$SR = \frac{HIT}{HIT+FA} \quad (4)$$

O viés (B) mede a razão entre a frequência de um evento previsto e a frequência de um evento observado. B mostra se o sistema de previsão tende a subestimar os eventos observados ( $B < 1$ ) ou superestimar ( $B > 1$ ).

$$B = \frac{HIT+FA}{HIT+MISS} \quad (5)$$

CSI mede a fração de eventos observados que foram corretamente previstos. Em outras palavras, mostra como os eventos "sim" da previsão correspondem aos eventos "sim" observados proporcionalmente à frequência de eventos que foram previstos (Shcafer, 1990). Quanto mais próximo de 1.00 os valores de CSI, melhor desempenho do modelo.

$$CSI = \frac{HIT}{HIT+MISS+FA} \quad (6)$$

ORSS, também comumente conhecido como *Yule-Q*, é uma medida de para estatísticas categóricas e permite discriminar se o desempenho resultante é devido ao acaso ou à robustez do modelo.

Valores de ORSS variam de -1 a 1, sendo que 0 (zero) indica nenhuma habilidade (Montero-Martínez et al. 2012). Valores mais próximos da unidade indicam maior robustez. Se o ORSS estiver tendendo para zero, isso significa que o modelo não tem poder para fazer previsões (Eskes et al. 2011).

$$ORSS = \frac{HIT \times CN - MISS \times FA}{HIT \times CN + MISS \times FA} \quad (7)$$

Os quatro índices (POD, SR, B e CSI) foram combinados em um diagrama de desempenho para visualizar a precisão das previsões de precipitação do modelo Eta (Roebber 2009). Os pontos de dispersão no canto superior direito do diagrama representarão alta precisão do modelo (Chaudhuri e Middey, 2012), já que os índices usados no diagrama de desempenho indicam bom desempenho quando próximos de 1.00.

Valores altos de ORSS implicam probabilidade significativas de o desempenho não ser ao acaso. Para testar o desempenho real é essencial que um teste de significância seja realizado nos índices de desempenho (Montero-Martínez et al., 2012). A significância a 95% do ORSS foi testada neste trabalho usando o intervalo de confiança (IC) de seus valores (equação 8).

$$IC = Y_{est} \pm t_{table(\frac{\alpha}{2}, n-2)} \times S_{Y_{est}} \times \sqrt{\frac{1}{n} + \frac{(X_{obs} - \bar{X})^2}{(n-1) \times S_X^2}} \quad (8)$$

sendo,  $Y_{est}$ : ajuste polinomial para razão de chance (1 a 10 dias);  $t_{table(\frac{\alpha}{2}, n-2)}$ : tabela de distribuição bicaudal t;  $S_{Y_{est}}$ : desvio padrão de  $Y_{est}$ ;  $n$ : número de dados;  $\bar{X}$ : média dos dados observados;  $S_X^2$ : variância dos dados observados;  $X_{obs}$ : dados observados.

#### 2.2.4. Limiares de Precipitação

Para combinar a avaliação das previsões de precipitação do modelo Eta com as exigências dos produtores de cana-de-açúcar, dividiu-se a quantidade de precipitação acumulada diária (PREC) em cinco limiares: > 0 mm, > 5 mm, > 10 mm, > 20 mm e > 40 mm. PREC > 0 mm indica se choveu ou não.

PREC > 5 mm é um limiar importante, uma vez que mesmo pouca precipitação pode impedir a entrada de maquinário e atrasar as operações no campo, p.e. a colheita (Abreu et al., 2013) e se constante com mesma intensidade por poucos minutos já pode levar a erosão do solo (Souza et al., 2012).

O CPTEC-INPE indica que o monitoramento de PREC > 10 mm é útil para o planejamento de atividades no campo: requisitos de irrigação, aplicações de tratamentos fitossanitários e condições de manejo do solo. PREC > 20 mm e > 40 mm indicam eventos raros e extremos, respectivamente.

Eventos de alta pluviosidade no sistema de cultivo de cana-de-açúcar podem gerar um estado de respiração inadequada da raiz, perda de nutrientes, lixiviação da sacarose e riscos de erosão (Mall et al. 2016).

Resumidamente, foram comparados na escala de tempo diária (0 a 10 DF) as previsões do modelo Eta e os dados observados de precipitação em 28 municípios de produção de cana-de-açúcar no Brasil, calculando os índices de desempenho para cada município. Em seguida, dividimos esses municípios em seis grupos, usando o método de agrupamento hierárquico de Ward, de acordo com os valores de ACC para PREC > 0 mm. Essa divisão foi feita para facilitar a representação dos resultados.


As previsões do modelo Eta foram avaliadas nas condições dos cinco limiares de PREC dentro de cada grupo, comparando índices de desempenho entre eles.

### **2.3. RESULTADOS E DISCUSSÃO**

Primeiramente, é apresentada uma visão geral das previsões do modelo Eta sobre a região Centro-Sul do Brasil (Figura 2). Foi observado que para PREC > 0 mm, a previsão do modelo teve acurácia geral (HIT+CN) de 62,9%, considerando todos os municípios (61.320 dados).

A acurácia geral aumenta com aumento dos limiares de precipitação devido ao aumento de respostas CN nas tabelas de contingência. Isso ocorre, pois, a frequência de eventos diários com volume maior de precipitação acumulada é baixa, principalmente para PREC > 20 mm e PREC > 40 mm.

Para  $PREC > 10$  mm, houve mais FA do que MISS, indicando que o modelo Eta tende a superestimar esses eventos de precipitação.




**Figura 2.** Visão geral das previsões de precipitação do modelo Eta sobre a região Centro-Sul do Brasil. PREC: volume de precipitação, F.A.: alarmes falsos e C.N.: negativos corretos.

A análise de agrupamento dividiu os 28 municípios em seis grupos de acordo com o valor do ACC (Figura 3). O critério de Ward seguiu os métodos de ordenação multivariada, procurando clusters no espaço euclidiano (Murtagh e Legendre 2014).


O modelo Eta apresentou para todas as regiões valores de ACC acima de 55%. O grupo III (56,43%), representante do bioma Mata Atlântica e o grupo VI (70,59%), representativo do bioma Cerrado, foram os menos e mais acurados, respectivamente.

Essas diferenças na ACC provavelmente estão relacionadas às características orográficas de cada grupo de locais. De acordo com Cannon et al. (2017), as precipitações orográficas podem ser altamente dependentes das variações do relevo da superfície e influenciar a meteorologia regional. Zhu e Pi (2014) descobriram que existem diferenças significativas na precisão das previsões em diferentes localidades nos Estados Unidos

Em geral, notamos que o modelo Eta tende a superestimar o volume precipitação (Figura 4).



**Figura 3.** Municípios produtores da cana-de-açúcar Centro-Sul do Brasil combinados em grupos pelo método de análise hierárquica de clusters de Ward, para a acurácia geral do modelo Eta.  $\overline{ACC}$  é a acurácia média do grupo.



**Figura 4.** Produção de cana-de-açúcar região centro-sul do Brasil. Cada ponto e número representa o lugar e o grupo a que pertence, respectivamente (A) e visão geral das previsões das precipitações do modelo Eta para a região Centro-Sul do Brasil (B).

Os índices de desempenho utilizados para avaliar as previsões do modelo Eta foram calculados a partir das respostas na tabela de contingência (Tabela 3). Essas distribuições foram geradas para cada dia de previsão e para cada local para todos os grupos e apresentam uma visão geral do comportamento do modelo em relação aos elementos da tabela de contingência.

Analisar as distribuições conjuntas permite entender melhor os índices de desempenho. Para uma análise mais detalhada, foi usado o diagrama de desempenho proposto por Roebber (2009), que combina quatro índices de desempenho em um gráfico (Figura 6). No diagrama procura-se que os pontos se concentrem no canto superior direito. Para todos os grupos  $PREC > 0$  mm apresentou melhor desempenho do modelo Eta.

### **2.3.1. Limiar $PREC > 0$ mm**

Considerando todos os grupos, para o limiar de  $PREC > 0$  mm, o modelo Eta apresentou melhor desempenho que nos demais limiares em termos de POD, que foi superior a 0,7. Isso indica que mais de 70% dos eventos observados com ocorrência chuva foram corretamente previstos pelo modelo Eta. É importante entender que o POD abrange apenas o domínio de acertos e erros (que são medidas de eventos de chuva que realmente aconteceram) e não considera alarmes falsos e negativos corretos (que são medidas de não ocorrência de um evento de chuva).

Em contraste ao POD, a pontuação SR dentre todos os grupos, exceto o grupo VI, foi abaixo de 0,5, indicando que menos de 50% dos eventos de chuva previstos foram realmente observados. SR representa a taxa de sucesso considerando apenas os resultados reais já que os CN não são considerados.

Esse indicador também aponta para o comportamento de superestimação do modelo. Para o grupo VI, a SR variou entre 0,5 e 0,6, superando os demais grupos, provavelmente porque esse grupo representa uma região mais seca com menores eventos de precipitação.

O CSI é uma medida diretamente conectada à frequência de eventos previstos, ou seja, uma estatística que considera apenas situações em que existe um problema de previsão (Schaefer, 1990).

**Tabela 2.** Contagem e porcentagem das respostas das tabelas de contingência (Evento Previsto/ Evento Observado) para todos os grupos e limiares. PREC: volume de precipitação, n ° obs: número de ocorrência na tabela de contingência. HIT: acertos (SIM/SIM), MISS: erros (NÃO/SIM), FA: alarmes falsos (SIM/NÃO) e CN: negativos corretos (NÃO/NÃO).

| <b>PREC<br/>&gt; 0<br/>mm</b> | <b>Group I</b> |          | <b>Group II</b> |          | <b>Group III</b> |          | <b>Group IV</b> |          | <b>Group V</b> |          | <b>Group VI</b> |          | <b>Total<br/>n°obs</b> |
|-------------------------------|----------------|----------|-----------------|----------|------------------|----------|-----------------|----------|----------------|----------|-----------------|----------|------------------------|
|                               | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>    | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> |                        |
| <b>HIT</b>                    | 4.115          | 22,3     | 3.361           | 27,3     | 3.007            | 24,4     | 3.929           | 26,0     | 3.796          | 24,7     | 3.854           | 30,8     | 22.062                 |
| <b>MISS</b>                   | 1.386          | 7,5      | 595             | 4,8      | 694              | 5,6      | 981             | 6,5      | 827            | 5,4      | 817             | 6,5      | 5.300                  |
| <b>FA</b>                     | 5.949          | 32,2     | 4.171           | 33,9     | 4.709            | 38,2     | 4.232           | 28,0     | 4.686          | 30,5     | 2.855           | 22,8     | 26.602                 |
| <b>CN</b>                     | 7.030          | 38,0     | 4.193           | 34,0     | 3.910            | 31,7     | 5.968           | 39,5     | 6.041          | 39,4     | 4.996           | 39,9     | 32.138                 |
| <b>Total</b>                  | 18.480         | 100      | 12.320          | 100      | 12.320           | 100      | 15.110          | 100      | 15.350         | 100      | 12.522          | 100      | 86.102                 |

| <b>PREC<br/>&gt; 5<br/>mm</b> | <b>Group I</b> |          | <b>Group II</b> |          | <b>Group III</b> |          | <b>Group IV</b> |          | <b>Group V</b> |          | <b>Group VI</b> |          | <b>Total<br/>n°obs</b> |
|-------------------------------|----------------|----------|-----------------|----------|------------------|----------|-----------------|----------|----------------|----------|-----------------|----------|------------------------|
|                               | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>    | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> |                        |
| <b>HIT</b>                    | 1.553          | 8,5      | 1.355           | 11,2     | 1.197            | 9,9      | 1.508           | 10,6     | 1.530          | 10,0     | 1.385           | 11,4     | 8.528                  |
| <b>MISS</b>                   | 1.414          | 7,7      | 1.006           | 8,3      | 1.031            | 8,5      | 1.000           | 7,0      | 1.042          | 6,8      | 930             | 7,6      | 6.423                  |
| <b>FA</b>                     | 3.260          | 17,8     | 2.259           | 18,7     | 2.312            | 19,1     | 2.691           | 18,9     | 3.024          | 19,7     | 2.227           | 18,3     | 15.773                 |
| <b>CN</b>                     | 12.113         | 66,0     | 7.440           | 61,7     | 7.550            | 62,4     | 9.031           | 63,5     | 9.754          | 63,5     | 7.646           | 62,7     | 53.534                 |
| <b>Total</b>                  | 18.340         | 100      | 12.060          | 100      | 12.090           | 100      | 14.230          | 100      | 15.350         | 100      | 12.188          | 100      | 84.258                 |


| <b>PREC<br/>&gt; 10<br/>mm</b> | <b>Group I</b> |          | <b>Group II</b> |          | <b>Group III</b> |          | <b>Group IV</b> |          | <b>Group V</b> |          | <b>Group VI</b> |          | <b>Total<br/>n°obs</b> |
|--------------------------------|----------------|----------|-----------------|----------|------------------|----------|-----------------|----------|----------------|----------|-----------------|----------|------------------------|
|                                | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>    | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> |                        |
| <b>HIT</b>                     | 846            | 4,6      | 687             | 5,7      | 645              | 5,3      | 849             | 6,0      | 858            | 5,6      | 603             | 5,0      | 4.488                  |
| <b>MISS</b>                    | 1.250          | 6,8      | 970             | 8,0      | 901              | 7,5      | 944             | 6,6      | 955            | 6,2      | 1.031           | 8,5      | 6.051                  |
| <b>FA</b>                      | 2.470          | 13,4     | 1.684           | 14,0     | 1.796            | 14,9     | 2.150           | 15,1     | 2.465          | 16,0     | 1.570           | 12,9     | 12.135                 |
| <b>CN</b>                      | 13.896         | 75,3     | 8.722           | 72,3     | 8.747            | 72,4     | 10.287          | 72,3     | 11.122         | 72,2     | 8.966           | 73,7     | 61.740                 |
| <b>Total</b>                   | 18.462         | 100      | 12.063          | 100      | 12.089           | 100      | 14.230          | 100      | 15.400         | 100      | 12.170          | 100      | 84.414                 |

| <b>PREC<br/>&gt; 20<br/>mm</b> | <b>Group I</b> |          | <b>Group II</b> |          | <b>Group III</b> |          | <b>Group IV</b> |          | <b>Group V</b> |          | <b>Group VI</b> |          | <b>Total<br/>n°obs</b> |
|--------------------------------|----------------|----------|-----------------|----------|------------------|----------|-----------------|----------|----------------|----------|-----------------|----------|------------------------|
|                                | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>    | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> |                        |
| <b>HIT</b>                     | 232            | 1,3      | 201             | 1,7      | 203              | 1,7      | 216             | 1,5      | 278            | 1,8      | 104             | 0,9      | 1.234                  |
| <b>MISS</b>                    | 781            | 4,3      | 647             | 5,4      | 621              | 5,1      | 729             | 5,2      | 709            | 4,6      | 774             | 6,4      | 4.261                  |
| <b>FA</b>                      | 1.274          | 6,9      | 863             | 7,2      | 941              | 7,8      | 929             | 6,7      | 1.224          | 8,0      | 491             | 4,0      | 5.722                  |
| <b>CN</b>                      | 16.053         | 87,5     | 10.349          | 85,8     | 10.315           | 85,4     | 12.076          | 86,6     | 13.139         | 85,6     | 10.801          | 88,8     | 72.733                 |
| <b>Total</b>                   | 18.340         | 100      | 12.060          | 100      | 12.080           | 100      | 13.950          | 100      | 15.350         | 100      | 12.170          | 100      | 83.950                 |

| <b>PREC<br/>&gt; 40<br/>mm</b> | <b>Group I</b> |          | <b>Group II</b> |          | <b>Group III</b> |          | <b>Group IV</b> |          | <b>Group V</b> |          | <b>Group VI</b> |          | <b>Total<br/>n°obs</b> |
|--------------------------------|----------------|----------|-----------------|----------|------------------|----------|-----------------|----------|----------------|----------|-----------------|----------|------------------------|
|                                | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>    | <b>%</b> | <b>n° obs</b>   | <b>%</b> | <b>n° obs</b>  | <b>%</b> | <b>n° obs</b>   | <b>%</b> |                        |
| <b>HIT</b>                     | 16             | 0,1      | 12              | 0,1      | 18               | 0,1      | 23              | 0,2      | 13             | 0,1      | 4               | 0,0      | 86                     |
| <b>MISS</b>                    | 284            | 1,5      | 239             | 2,0      | 239              | 2,0      | 259             | 1,8      | 297            | 1,9      | 306             | 2,5      | 1.624                  |
| <b>FA</b>                      | 274            | 1,5      | 166             | 1,4      | 158              | 1,3      | 424             | 3,0      | 212            | 1,4      | 58              | 0,5      | 1.292                  |
| <b>CN</b>                      | 17.766         | 96,9     | 11.643          | 96,5     | 11.675           | 96,6     | 13.524          | 95,0     | 14.828         | 96,6     | 11.802          | 97,0     | 81.238                 |
| <b>Total</b>                   | 18.340         | 100      | 12.060          | 100      | 12.090           | 100      | 14.230          | 100      | 15.350         | 100      | 12.170          | 100      | 84.240                 |



**Figura 6.** Diagramas de desempenho das previsões de precipitação do Modelo Eta na região produtora de cana-de-açúcar Centro-Sul do Brasil. Cada ponto está relacionado a 1 a 10 dias de previsão; o pequeno gráfico de dispersão mostra os valores médios para 10 dias da previsão. Cada cor representa um limiar de precipitação diferente. As linhas de curva são o índice de sucesso crítico (CSI) e as linhas tracejadas, a pontuação de tendência (B). I a VI são os grupos de precisão.

Para  $PREC > 0$  mm, todos os grupos apresentaram valores de CSI superiores a 0,3 e os valores dos grupos IV e VI maiores que 0,4. Isso significa que os eventos de chuva só aconteceram em 30-40% do conjunto de dados dos eventos que foram previstos. Semelhante ao SR, a pontuação CSI indica a taxa de sucesso, mas também leva em consideração as falhas do modelo.

B foi maior que um para todos os grupos, como foi também para todos os outros limiares de PREC, indicando que o modelo Eta superestima o número real de dias chuvosos.

### **2.3.2. Outros Limiares**

Para  $PREC > 5$  mm, POD foi acima de 0,5 para todos os grupos. Com SR sendo na maior parte ligeiramente superior a 0,4, podemos dizer que das 10 previsões de  $PREC > 5$  mm, o modelo detecta a possibilidade de chuva 5 vezes, sendo o modelo Eta correto em suas previsões em quatro destas situações (com ocorrência de chuva).

CSI variou para todos os grupos entre 0,2 e 0,4, com os grupos I e VI com valores de CSI superiores a 0,3.

Os resultados de desempenho para  $PREC > 10$  mm foram distintos dos demais limiares, com alta dispersão. POD e SR tiveram maiores amplitudes, mas para todos os grupos, os valores não passaram 0,5 e 0,4, respectivamente. CSI ficou entre 0,1 e 0,4.

Para  $PREC > 20$  mm, POD e SR foram menores que 0,3 principalmente, com CSI ligeiramente acima de 0,1, exceto para o grupo VI (valores de CSI abaixo de 0,1). Em contraste com os outros limiares, B foi abaixo de 1 para o grupo IV, indicando que para este grupo, a previsão do modelo Eta subestimou a quantidade real de dias chuvosos.

Os indicadores do limiar  $PREC > 40$  mm foram difíceis de calcular, pois esse limite aparece em menos de 8% do total de dias (3.388 dias por local). A maioria dos dias mostrou HIT, MISS, FA e CN com valores iguais ou próximos a zero.

### 2.3.3. ORSS - probabilidade de o desempenho não ser ao acaso


O limiar  $PREC > 40$  mm não entrou nesta análise. De acordo com Stephenson (2000) ORSS não é um bom indicador de desempenho quando qualquer das classes da tabela de contingência é (ou próximo de) zero.

Todos os demais limiares avaliados apresentaram ORSS positivos (Figura 6). Para  $PREC > 0$  mm, os dias de previsão (DF) 1 a 4 tiveram resultados semelhantes para todos os grupos com ORSS entre 0,65 e 0,90. Após o DF 4, o ORSS variou de acordo com o grupo, onde o grupo VI manteve o ORSS acima de 0,65 todo o período (10 DF). Os grupos IV e V mantiveram o ORSS acima de 0,60 até o DF 8.


Em geral, as previsões de precipitação do modelo Eta foram robustas até o DF 4 (Figura 7). Destaque do Grupo VI para  $PREC > 0$  mm e  $> 5$  mm com robustez até DF 10, mas para maiores quantidades,  $PREC > 10$  mm e  $> 20$  mm o ORSS diminuiu mais que para os outros grupos.

Para  $PREC > 5$  mm, ORSS diminuiu em comparação com  $PREC > 0$  mm para todos os grupos. Até DF 4, todos os grupos tinham ORSS de 0,6 ou mais, excluindo o grupo I, que começou a diminuir a partir de menores quantidades de chuva. Após DF 5, apenas o grupo VI continuou com ORSS mínimo de 0,6. Para  $PREC > 10$  mm, ORSS permaneceu maior que 0,6 até DF 4 para todos os grupos.

Para  $PREC > 20$  mm, os valores de ORSS foram maiores do que para os demais limiares de  $PREC$  próximos a 0. Para os grupos VI, III e I, este foi por DF 4, 5 e 8, respectivamente. Para o  $PREC > 20$  mm, o teste de significância pelo intervalo de confiança não apresentou todos os grupos com 95% de confiabilidade, sendo os dados dos grupos III a VI não significativos ao valor de  $p < 0,05$ .



**Figura 6.** Escores de habilidades de razão de chances das previsões de precipitação do Modelo Eta para diferentes dias de previsão para a região produtora de cana-de-açúcar na região Centro-Sul do Brasil.



**Figura 7.** Dias de previsão (1 a 10) das previsões de precipitação do Modelo Eta para as regiões produtoras de cana-de-açúcar da região centro-sul do Brasil com ORSS > 0,6. Os números I ao VI indicam os grupos analisados.

## **2.4. CONCLUSÕES**

A precisão geral das previsões de precipitação do modelo Eta para a região Centro-Sul do Brasil é superior a 55% para a mata atlântica e 71% para os biomas do Cerrado.

As previsões para todos os municípios são confiáveis até quatro dias e podem dar suporte à tomada de decisão para gestão de operações e manejo do canavial.

As pontuações do viés mostraram que a previsão do modelo Eta tende a superestimar a quantidade de precipitação. A probabilidade de detecção (POD) da chance de um evento de precipitação é a característica mais forte do modelo Eta, com mais de 70% de acertos.

## **AGRADECIMENTOS**

Agradecemos a Fundação de Coordenação e Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento deste projeto e o apoio do Instituto Nacional de Pesquisas Espaciais no desenvolvimento deste trabalho.

## **2.5. REFERÊNCIAS**

- Abreu et al. (2013) Growth and productivity of sugarcane varieties as affected by water availability in the Coastal Tablelands of the Alagoas State, Brazil. *Bragantia*, 72:262-270
- Cannon, F., L. M. V. Carvalho, C. Jones, J. Norris, B. Bookhagen, and G. N. Kiladis (2017), Effects of topographic smoothing on the simulation of winter precipitation in High Mountain Asia, *J. Geophys. Res. Atmos.*, 122, 1456–1474, doi:10.1002/2016JD026038.
- Chaudhuri S and Middey A (2012) A composite stability index for dichotomous forecast of thunderstorms. *Theor Appl Climatol*, 110:457-469.
- Chou, SC, Bustamante, JF and Gomes, JL (2005) Evaluation of Eta Model seasonal precipitation forecasts over South America. *Nonlinear Processes in Geophysics*. 12:537-555.

CPTEC-INPE. Center for Weather Forecast and Climate Studies - Institute of Space Research, 2017 (<http://tempo.cptec.inpe.br/tempo/in>)

Eskes, H, Joly, M and Peuch, V-H (2011) Skill scores and model evaluation methodology. Report merging. December 2011

Frisvold, G.B., Murugesan, A., 2012. Use of weather information for agricultural decision making. *Weather Clim. Soc.* 5, 55–69.

Hansen, J.W., 2002. Realizing the potential benefits of climate prediction to agriculture: issues, approaches, challenges. *Agric. Syst.* 74, 309–330.

IAC. Agronomic Institute, Campinas, Brazil, 2017 (<http://www.iac.sp.gov.br/>)

INMET. National Institute of Meteorology, Brazil, 2017 (<http://www.inmet.gov.br/>)

IPCC, 2013. Annex III: glossary. In: Planton, S., Stocker, T.F., Qin, D., Plattner, G.-K., et al. (Eds.), *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.

Klemm, T and McPherson, R (2017) The development of seasonal climate forecasting for agricultural producers. *Agric. Forest Meteorol.* 232:384-399.

Mall, RK, Sonkar, G, Bhatt, D, Sharma, NK, Baxla, AK and Singh, KK (2016) Managing impact of extreme weather events in sugarcane in different agro-climatic zones of Uttar Pradesh. *MAUSAM*, 67:233-250.

Mesinger F (1984) A blocking technique for representation of mountains in atmospheric models. *Riv Meteorol Aeronautica* 44:195–202.

Mesinger F, Janjic ZI, Nickovic S, Gavrilov D, Deaven DG (1988) The step-mountain coordinate: model description, and performance for cases of Alpine lee cyclogenesis and for a case of an Appalachian redevelopment. *Mon Weather Rev.* 166(7):1493-1518.

Mesinger F, Veljovic K, Chou SC, Gomes J, Lyra A (2016) The Eta Model: Design, Use, and Added Value. *Topics in Climate Modelling.* 1(6):138-150. <http://dx.doi.org/10.5772/64956>

Montero-Martínez G, Zarraluqui-Such V, García-García<sup>1</sup> F (2012) Evaluation of 2B31 TRMM-product rain estimates for single precipitation events over a region with complex topographic features. *J. Geophys. Res* 117, 21:01, doi:10.1029/2011JD016280.

Muller OV, Miguel, AL (2016) Evaluation of WRF Model forecasts and their use for hydroclimate monitoring over Southern South America. *Am. Meteorol. Soc.* 31:10011015.

Murphy, AH (1993) What is a good forecast? An essay on the nature of goodness in weather forecasting. *Wea Forecasting*. 8:281-293.

Murtagh, F and Legendre, P (2014) Ward's Hierarchical Agglomerative Clustering Method: Which Algorithms Implement Ward's Criterion? *Journal of Classification*. 31:274-295, doi: 10.1007/s00357-014-9161-z

Roebber PJ (2009) Visualizing multiple measures of forecast skill. *American Meteorological Society*, 1:601-607. doi: 10.1175/2008WAF2222159.1

Schaefer, JT (1990) The critical success index as an indicator of warning skill. *American Meteorological Society* 5:1-6.

Sonka, S.T., Hofing, S.L., Changnon, S.A., 1992. How agribusiness uses climate predictions: implications for climate research and provision of predictions. *Bull. Am. Meteorol. Soc.* 73, 1999–2008.

Souza, BG, Martins Filho, MV, Matias, SSR. Perdas de solo, matéria orgânica e nutrientes por erosão hídrica em uma vertente com palha de cana-de-açúcar em Guariba – SP. *Eng. Agric. Jaboticabal*. 12(3):490-500, 2012.

Stephenson, DB (2000) Use of the “odds ratio” for diagnosing forecast skill. *Wea Forecasting*. 15:221-232.

Taylor, KE (2001) Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res.* 106(7):7183-7192.

Theis, SE, Hense A and Damrath, U (2005) Probabilistic precipitation forecasts from a deterministic model: a pragmatic approach. *Meteorol. Appl.* 12(1):257–268. doi:10.1017/S1350482705001763

Thornes, JE and Stephenson, DB (2001) How it judges the quality and value of weather forecast products. *Meteorol. Appl.* 8:307-314.

UNICA. Union of the sugar cane industry, 2017 (<http://www.unica.com.br/>)

Wilks, D.S., 2011. *Statistical Methods in the Atmospheric Sciences*. Elsevier/Academic Press, Amsterdam; Boston.

WORDATLAS, 2017 (<http://www.worldatlas.com/>)

Zhao, D and Li, YR (2015) Climate Change and Sugarcane Production: Potential Impact and Mitigation Strategies. *International Journal of Agronomy*. 2015:1-10. <http://dx.doi.org/10.1155/2015/547386>.

Zhu, A.W. and Pi, H (2014) A Method for Improving the Accuracy of Weather Forecasts Based on a Comprehensive Statistical Analysis of Historical Data for the Contiguous United States. *J Climatol Weather Forecasting*. 2:1, DOI: 10.4172/2332-2594.1000110.

### **CAPÍTULO 3 – Modelo AquaCrop: parametrização e conversão de biomassa para o cultivo de cana de açúcar.**

**RESUMO:** O cultivo de cana-de-açúcar é considerado uma das principais fontes de renda e melhoria da qualidade de vida das pessoas de regiões em desenvolvimento. O sucesso da produção de cana-de-açúcar depende de diversos fatores, sobretudo a influência climática no desenvolvimento do cultivo. Uma forma de mensurar essa influência, não apenas do clima, mas também do solo e do manejo na produção agrícola, é com o uso de técnicas de modelagem de cultivos. Esse estudo visa calibrar e validar parâmetros do cultivo de cana-de-açúcar para simulações do acúmulo de biomassa no modelo AquaCrop. Foram usados dados de campo de produção de biomassa de cana-de-açúcar de quatro importantes regiões produtoras do Brasil (Araraquara, Pradópolis, Itacemópolis e Quirinópolis), dados meteorológicos e de manejo agrônômico foram utilizados na calibração e posterior validação do modelo. Foi possível realizar simulações confiáveis para o cultivo da cana-de-açúcar com MAPE de 7,65% e  $R^2 = 0.73$  na calibração e MAPE de 13,44% e  $R^2 = 0.30$  na validação. Modificações propostas para os parâmetros para cana-de-açúcar gerou melhorias nas simulações quando comparadas com simulações com parâmetros padrões do modelo AquaCrop.

**PALAVRAS-CHAVE:** modelagem de cultivos, *Sacharumm* spp., produtividade da água, toneladas de cana por hectare, parâmetros de cultura.

#### **AquaCrop model: parameterization and biomass conversion for sugarcane crop**

**ABSTRACT:** The cultivation of sugarcane is considered one of the main sources of income and improvement of the quality of life of the people of developing regions. The success of sugarcane production depends on several factors, especially the climatic influence on the development of the crop. One way to measure this influence, not only of the climate but also of the soil and the management in agricultural production, is with the use of crop modeling techniques. In this sense, this study aims to calibrate and validate the parameters of the sugarcane cultivation for simulations of the accumulation of biomass in the AquaCrop model. Sugarcane biomass production field data from four important

producing regions of Brazil (Araraquara, Pradópolis, Itacemópolis, and Quirinópolis) were used, meteorological and agronomic data were used in the calibration and later validation of the model. It was possible to perform reliable simulations for the cultivation of sugarcane with MAPE of 7.65% and  $R^2 = 0.73$  in the calibration and MAPE of 13.44% and  $R^2 = 0.30$  in the validation. Proposed modifications to the parameters for sugarcane generated improvements in the simulations when compared to simulations with standard parameters of the AquaCrop model.

**KEYWORDS:** crop modeling, *Sacharumm* spp., water productivity, tons of sugar cane per hectare, crop parameters.

### 3.1. INTRODUÇÃO

A cana-de-açúcar é um cultivo mundialmente importante, a planta de cana pode acumular altos níveis de sacarose e produzir açúcar, etanol e produtos biodegradáveis. A biomassa da cana-de-açúcar pode ser usada como ração animal ou para gerar energia. Sua extensa área de produção e diversas aplicações indicam que a cana-de-açúcar está adaptada para crescer em diversas regiões, sob diferentes condições ambientais e de manejo. O cultivo da cana-de-açúcar é considerado uma das principais fontes de renda e melhoria da qualidade de vida para as regiões em desenvolvimento (Heinrichs et al., 2017).

A implantação de cultivos agrícolas depende de alguns fatores, entre eles: da seleção da espécie e do modo de cultivo adequado para cada região; da escolha de datas de plantio favoráveis; do planejamento da produtividade e época de colheita; do desenvolvimento de cronogramas de irrigação e da determinação do manejo da fertilidade. Tais fatores são diretamente dependentes do ambiente e influenciam uma produção agrícola bem-sucedida.

Para entender as interações entre o sistema solo-planta-atmosfera agricultores e pesquisadores fazem uso de modelos de cultivo agrícolas como ferramentas poderosas para auxiliar na tomada de decisões ou definir prioridades de pesquisa (Dourado-Neto et al., 1998). As técnicas de modelagem de cultivos agrícolas também podem auxiliar na avaliação de riscos para projetos e apólices de seguro agrícola (Rader et al., 2009; Kadiyala et al., 2015).

A abordagem “Climate-Smart-Agriculture”, definida pela FAO (Food and Agriculture Organization of the United Nations) em 2010, orienta ações necessárias para transformar os sistemas agrícolas e apoiar efetivamente o desenvolvimento sustentável. Modelos de cultivos agrícolas contribuem para esta transformação do sistema convencional para abordagem CSA (FAO, 2013).

Modelos específicos para cana-de-açúcar variam em relação à sua aplicação pretendida. Um modelo torna-se útil se puder simular o crescimento e a produção das diversas cultivares de cana de açúcar existentes, crescendo em diversas áreas de produção em todo o mundo. Existem diferentes modelos de cana-de-açúcar, p.e. DSSAT-CaneGro (Inman-Bamber, 1991), APSIM-Cane (McCown et al., 1996) e o QCANE (Liu e Kingston, 1995), desenvolvido com foco apenas na cana-de-açúcar, enquanto o DSSAT e APSIM são plataformas de modelagem de vários cultivos.

Cada modelo apresenta características favoráveis e desfavoráveis e a escolha do modelo correto depende do objetivo do estudo (Somard et al., 2018). O AquaCrop é uma plataforma de modelagem de vários cultivos que visa o entendimento da influência da água no ciclo da planta e no ambiente da cultura (Steduto et al., 2009; Vanuytrecht et al., 2014). Foi desenvolvido com enfoque em culturas de ciclo anual e não especificamente para a cana de açúcar.

Os modelos de cultivo agrícolas geralmente contêm muitos parâmetros, que são, por definição, características de um sistema escolhido, cujas alterações de valor alteram a solução de um problema (Di Paola et al., 2015). A parametrização é o processo de estimar valores de parâmetros para melhorar o desempenho de um modelo (Wallach et al., 2001). A parametrização confiável deve respeitar as relações botânicas e fisiológicas das plantas assim como as características físicas do solo. São necessários dados quantitativos e conhecimento sobre a fisiologia da planta para se conseguir uma boa parametrização.

A maioria dos modelos de cultivos agrícolas existentes exigem calibração extensiva, o que requer coleta abundante de dados. Em contrapartida a este conceito, o modelo AquaCrop visa limitar os requisitos de entrada (‘inputs’) e precisa de apenas alguns parâmetros explícitos e intuitivos a serem calibrados. O modelo AquaCrop respeita as condições fisiológicas e é relativamente

simples, tendo como base princípios hídricos e uso da produtividade da água para simular a biomassa da planta a partir da transpiração (Steduto et al., 2009, Raes et al., 2009, Vanuytrecht et al., 2014).


Este estudo visa (i) calibrar os parâmetros do modelo AquaCrop necessários para simular safras de cana-soca com ciclo de 12 meses, (ii) validar a produção de biomassa de cana de açúcar simulada de acordo com os valores observados.

## **3.2. MATERIAL E MÉTODOS**


### **3.2.1. Área de estudo e dados observados**

A produção brasileira de cana-de-açúcar cobre uma área de cerca de 10 milhões de hectares, dos quais 90% estão concentrados no centro-sul do país. Três importantes áreas de produção de cana estão localizadas no estado de São Paulo: Pradópolis, Araraquara e Itacemópolis (Figura 1A). Em crescimento no setor, a região de Quirinópolis está localizada no sul do estado de Goiás (Figura 1B).

Neste estudo foram utilizados dados da produção de biomassa em toneladas de cana por hectare (TCH) e manejo agrônômico de uma safra de cana-de-açúcar de 12 meses (cana-soca). A colheita da cana-de-açúcar e o início de um ciclo subsequente da safra são processos simultâneos (Figura 2). Assim, quando uma cana-soca é colhida, o início da próxima safra se dá a partir da brotação das gemas dos toletes deixados e que após 12 meses será colhida novamente. A cana-soca ou cana de ano é colhida normalmente entre os meses de agosto a novembro. Esse processo de sucessão da cana-soca continua por vários ciclos até que seja necessário reformar a área e replantar as mudas/toletes de cana-de-açúcar.



**Figura 1.** Áreas de produção de cana de açúcar do Brasil, no estado de São Paulo (A) e no estado de Goiás (B) com indicação de 1) Pradópolis; 2) Araraquara; 3) Iracemápolis e 4) Quirinópolis. Adaptado de RUDORFF et al., 2010; CONAB, 2010.




**Figura 2.** Ciclo da cana-soca (12 meses). Por exemplo, para a temporada 2002-2003: (■) emergência; (■) brotação, crescimento e acumulação inicial de sacarose; (■) maturação e acumulação intensa de sacarose; (■) mês de colheita referente ao mês de plantio.

Dados meteorológicos diários de 2002 a 2014 registrados em estações meteorológicas automáticas (Tipo Campbell 21X) locais foram fornecidos pelos produtores locais e usinas de açúcar e etanol das regiões Pradópolis (Lat: 21°21'32" S, Long: 48°03'57" O, Alt: 538 m), Araraquara (Lat: 21°47'38" S, Long: 48°10'33" O, Alt: 664 m) e Iracemápolis (Lat: 22°34'51" S, Long: 47°31'08" O, Alt: 608 m). Os dados coletados foram temperatura mínima (Tmin) e máxima do ar (Tmax), precipitação (P) (Figura 3), temperatura média do ar, velocidade do vento, umidade relativa e balanço de radiação. Para Quirinópolis, os dados meteorológicos foram extraídos de dados do sistema NASA-POWER.

A evapotranspiração de referência diária (ET<sub>o</sub>) foi calculada pelo modelo de Penman-Monteith-FAO (Allen et al., 1998).

Os dados de tipos de solo foram obtidos por meio de uma classificação geral e posteriormente adaptados de acordo com trabalhos científicos realizados nas regiões estudadas. A classificação do solo seguiu as recomendações do Instituto Agrônomo de São Paulo (IAC), para Pradópolis, Araraquara e Iracemópolis e do Sistema de Geo-informação de Goiás (SIEG) para Quirinópolis. Para definição das propriedades físicas das classes de solos dominantes nessas regiões foram usados os trabalhos de Castro et al., (2009) e Montanari et al. (2010). Posteriormente, estes dados foram usados para estimar as características hídricas do solo por meio de funções de pedo-transferência (Saxton e Rawls, 2006; Saxton e Willey, 2009) (Tabela 1).



**Figura 3.** Média mensal de precipitação (P), evapotranspiração de referência (ET<sub>o</sub>), temperaturas máxima e mínima (T<sub>max</sub> e T<sub>min</sub>) de Araraquara (a), Pradópolis (b), Iracemópolis (c) e Quirinópolis (d) de 2002 a 2014.

Dados da produção de cana-de-açúcar, em toneladas de cana por hectare (TCH) do período de 2002 a 2014 foram fornecidos por produtores locais de cada região parceiros neste trabalho. Foram utilizadas seis safras do conjunto de dados de Araraquara (2008-09 a 2013-14), colhidas entre agosto e novembro, para calibrar os parâmetros do modelo AquaCrop.

**Tabela 1.** Propriedades físicas e hídricas dos solos de I) Araraquara, Pradópolis e Quirinópolis e II) Iracemópolis. Legenda: CAD é a capacidade de água disponível, PMP é o ponto de murcha permanente, CC é a capacidade de campo, SAT é o ponto de saturação e  $K_{sat}$  é a condutividade hidráulica.

| Solo | Horizonte | Textura    | Espessura | CAD                | PMP  | CC   | SAT  | Ksat                 |
|------|-----------|------------|-----------|--------------------|------|------|------|----------------------|
|      |           |            | m         | mm m <sup>-1</sup> | vol% |      |      | mm day <sup>-1</sup> |
| I    | 1         | Sandy Clay | 0.5       | 90                 | 18.6 | 27.6 | 40.6 | 126                  |
|      | 2         | "          | 1         | 102                | 22   | 32.2 | 41.7 | 49.9                 |
|      | 3         | "          | 1         | 111                | 24.8 | 35.9 | 43.2 | 22.6                 |
|      | 4         | "          | 2         | 115                | 26.4 | 37.9 | 44   | 13.7                 |
| II   | 1         | Clay       | 0.2       | 107                | 34.9 | 45.6 | 52.5 | 18                   |
|      | 2         | "          | 0.5       | "                  | "    | "    | "    | "                    |
|      | 3         | "          | 0.5       | "                  | "    | "    | "    | "                    |
|      | 4         | "          | 2         | "                  | "    | "    | "    | "                    |
|      | 5         | "          | 4         | "                  | "    | "    | "    | "                    |

Parâmetros calibrados foram testados (validados) com dados independentes do estado de São Paulo, ou seja, 12 safras de cada um dos locais restantes de Pradópolis e Iracemópolis (2002-14), e 7 safras de Quirinópolis, estado de Goiás (Tabela 2).

**Tabela 2.** Divisão dos dados observados de produção de cana-de-açúcar para as etapas de calibração e testes do modelo. N é o número de safras utilizado.

|            |              | N  | Safras            |
|------------|--------------|----|-------------------|
| Calibração | Araraquara   | 6  | 2008-09 a 2013-14 |
|            | Pradópolis   | 12 | 2002-03 a 2013-4  |
| Testes     | Iracemópolis | 12 | 2002-03 a 2013-14 |
|            | Quirinópolis | 7  | 2007-08 a 2013-14 |

### 3.2.2. Cálculo de biomassa do modelo AquaCrop

O AquaCrop é um modelo de simulação de culturas com um intervalo de tempo diário e foco na produtividade da água das culturas. Seus cálculos seguem uma sequência de quatro principais etapas de simulação: i) desenvolvimento de cobertura de dossel; ii) transpiração do cultivo; iii) produção de biomassa seca acima do solo e iv) produtividade (Steduto et al., 2009; Raes et al., 2009). Os coeficientes de estresse ( $K_s$ ) são parâmetros sem unidade que

representam o estresse ambiental no desenvolvimento e produção final da cultura e variam entre um (sem estresse) a zero (estresse máximo).

Após a simulação da cobertura do dossel, a transpiração ( $Tr$ ) é calculada pela equação 1.

$$Tr = K_s \times (K_{s_{Tr,x}} \times K_{c_{Tr}}) \times ETo \quad (\text{eq. 1})$$

na qual,  $K_s$  é o coeficiente de estresse hídrico (sem unidade),  $K_{s_{Tr,x}}$  (sem unidade) é o coeficiente de estresse ao frio (sem unidade),  $K_{c_{Tr}}$  é o coeficiente de transpiração do cultivo (sem unidade),  $ETo$  é a evapotranspiração de referência ( $\text{mm dia}^{-1}$ ), e  $Tr$  é a transpiração da cultura ( $\text{mm dia}^{-1}$ ).

O modelo calcula a biomassa seca acima do solo, que para a cana-de-açúcar inclui todo o material vegetal de folhas e colmo é calculada pela equação 2, após a simulação da  $Tr$ .

$$B = WP^* \times \sum \left( \frac{Tr}{ETo} \right) \quad (\text{eq. 2})$$

sendo,  $WP^*$  é a produtividade de água normalizada ( $\text{g m}^{-2}$ ),  $Tr$  é transpiração da cultura ( $\text{mm dia}^{-1}$ ) e  $B$  é a biomassa seca acima do solo ( $\text{g m}^{-2}$ )

### 3.2.3. Parametrização do modelo AquaCrop

O modelo trabalha em função de dois tipos de parâmetros: conservativos e não-conservativos.

- (i) Os parâmetros conservativos (CP) são específicos de cada cultura. Estes são constantes entre os diferentes ambientes, cultivares e práticas de manejo. Os CP são calibrados uma vez com base em dados observados e conhecimento de especialistas.
- (ii) Os parâmetros não conservativos (NCP) variam em função das condições ambientais, cultivares e/ou práticas de manejo. Estes devem ser calibrados de acordo com as condições específicas do local de estudo, antes de iniciar o modelo.

Para a cana-de-açúcar, a parametrização antiga usada no modelo foi proposta pela FAO (Bello, 2013), porém apenas um estudo publicou valores de CP em artigo científico revisado (Bahmani e Eghbalian, 2018). Os parâmetros publicados provaram não ser aplicáveis a diferentes ambientes, manejos e

cultivares. Sendo assim, para este estudo, uma nova parametrização de CP foi proposta para serem aplicáveis em diversas condições para o cultivo da cana-de-açúcar. Também foram calibrados NCP levando em consideração as condições das regiões estudadas.

#### 3.2.4. Adaptação do cálculo de biomassa do AquaCrop para cana

Enquanto o modelo AquaCrop simula toda biomassa seca acima do solo (folhas e caule), na prática, a produção de biomassa de cana-de-açúcar é expressa em toneladas de biomassa de caule fresco por hectare, conhecido popularmente como toneladas de cana por hectare (TCH). Desta forma o algoritmo para o cálculo de biomassa do modelo foi adaptado para converter a produção de biomassa total seca em um valor de biomassa de caule fresco (equação 3), mais prático e em concordância com o termo usado pela comunidade. O método de conversão de biomassa foi adaptado da equação proposta por Waclawovsky et al. (2010).

$$TCH = B_{fs} = \frac{B}{f_{dry-fresh}} \times f_{trash} \quad (\text{eq. 3})$$

sendo,  $B$  é a biomassa seca total acima do solo ('output' do AquaCrop, em  $\text{t ha}^{-1}$ ),  $f_{dry-fresh}$  é o coeficiente de conversão de biomassa seca para biomassa fresca (sem unidade),  $f_{trash}$  é o coeficiente sazonal de remoção de folhas (sem unidade) e  $B_{fs}$  é a biomassa fresca de cana de açúcar, o TCH, em  $\text{t ha}^{-1}$ .

O coeficiente  $f_{trash}$  foi introduzido para explicar a remoção de folhas e foi adaptado de acordo com o trabalho de Donaldson et al. (2008). O  $f_{trash}$  foi parametrizado iterativamente ajustando-se à variação sazonal da quantidade de folhas observada. Diferentes valores de coeficientes sazonais  $f_{trash}$  foram pesquisados e testados, de acordo com a época de colheita (agosto a novembro) após a análise de variância (ANOVA) com um fator, confirmar a variabilidade sazonal na produção de biomassa entre os meses de colheita.

#### 3.2.5. Avaliação do desempenho do modelo

O desempenho do modelo foi avaliado considerando duas medidas de acurácia: erro percentual absoluto médio (MAPE, equação 4) e erro médio quadrático relativo (RRMSE, equação 5), uma medida de tendência: erro sistemático ( $E_s$ , equação 6) e uma medida de precisão: coeficiente de determinação ( $R^2$ ).

$$MAPE = \frac{\sum_{i=1}^n \left( \left| \frac{B_{sim_i} - B_{obs_i}}{B_{obs_i}} \right| \times 100 \right)}{n} \quad (\text{eq.4})$$

$$RRMSE = \sqrt{\frac{\sum_{i=1}^n (B_{sim_i} - B_{obs_i})^2}{n}} \times \frac{100}{\overline{B_{obs}}} \quad (\text{eq.5})$$

$$ES = \sqrt{\frac{\sum_{i=1}^n (B_{obs_i} - \overline{B_{sim}})^2}{n}} \quad (\text{eq.6})$$

sendo,  $B_{sim_i}$  é a biomassa fresca final simulada (após conversão) na safra  $i$  ( $\text{t ha}^{-1}$ ),  $B_{obs_i}$  é a biomassa fresca observada na safra  $i$  ( $\text{t ha}^{-1}$ ),  $\overline{B_{obs}}$  é a biomassa observada média ( $\text{t ha}^{-1}$ ),  $\overline{B_{sim}}$  é a biomassa simulada média ( $\text{t ha}^{-1}$ ) e  $n$  é o número de safras.

Os indicadores de desempenho foram usados para avaliar as simulações do modelo durante a calibração (com o conjunto de dados de Araraquara) e testes (com os conjuntos de dados Pradópolis, Iracemópolis e Quirinópolis). A acurácia do modelo pelo RRMSE foi avaliada de acordo com as categorias definidas por Vanuytrecht et al. (2016) (Tabela 3).

**Tabela 3.** Classificação de desempenho do modelo por valores calculados da raiz erro quadrático médio relativo (RRMSE). TCH equivalente é referente a produtividade média de 85,0 toneladas de colmo por hectare.

| RRMSE     | Classificação de desempenho | TCH equivalente              |
|-----------|-----------------------------|------------------------------|
| < 10 %    | Excelente                   | < 8,5 $\text{t ha}^{-1}$     |
| 10 - 20 % | Bom                         | 8,5 a 17 $\text{t ha}^{-1}$  |
| 20 - 30 % | Fraco                       | 17 a 25,5 $\text{t ha}^{-1}$ |
| > 30 %    | Ruim                        | > 25,5 $\text{t ha}^{-1}$    |

Uma análise de frequência foi realizada para classificar a disponibilidade hídrica de anos úmidos, normais e secos, com base na precipitação acumulada durante o crescimento da cana-de-açúcar. Safras em que a quantidade de precipitação durante o ciclo foi acima e/ou abaixo dos requerimentos hídricos para desenvolvimento adequado da planta foram separadas para análise detalhada das simulações do modelo AquaCrop em relação à disponibilidade de água e as respostas do cultivo ao estresse hídrico.

### 3.3. RESULTADOS

#### 3.3.1. Parametrização

Seis estações do conjunto de dados observados de Araraquara (2008-09 a 2013-14) foram utilizadas para parametrizar NCP do cultivo de cana-soca em condições tropicais brasileiras (Tabela 4). Além disso, os CP foram alterados já que os valores de CP do arquivo padrão de cana-de-açúcar do modelo AquaCrop foram considerados irrealistas.

As alterações foram feitas para CP que descrevem o crescimento e declínio do dossel (CGC e CDC, respectivamente). A CGC foi ajustada para representar o desenvolvimento mais rápido da cana-soca em comparação com a cana-planta (com ciclo de 18 meses). Outros CP, como CDC, envelhecimento, coeficiente de transpiração de cultura e coeficiente de estresse descrevendo a resposta da expansão do dossel ao estresse hídrico ( $K_{S_{exp}}$ ) também foram alterados para uma representação mais realista do crescimento e desenvolvimento da cana-de-açúcar (Tabela 4).

#### 3.3.2. Coeficientes de conversão de biomassa

Um coeficiente geral de conversão de biomassa total seca para fresca foi calibrado ( $f_{dry-fresh}=0,30$ ) de acordo com a filosofia de simplicidade que o modelo AquaCrop se baseia. Embora, na realidade, a conversão possa ser ligeiramente dependente da localização e da estação, o valor é consistente com as conversões propostas por Waclawovsky et al. (2010) e Bello (2013).

Para o coeficiente de remoção de folhas ( $f_{trash}$ ), foram escolhidos os valores sazonais, após a ANOVA identificar diferenças significativas ( $\alpha = 0,05$ ) na remoção de folhas de acordo com o mês da colheita. Isso está de acordo com o trabalho de Donaldson et al. (2008), que também encontraram diferentes coeficientes de remoção de folhas para cana-de-açúcar influenciados pela época de colheita. Os ajustes mensais para  $f_{trash}$  (Tabela 5) melhoraram a precisão das simulações em comparação com o uso de coeficiente fixo para todos os meses de colheita (Figura 4).


**Tabela 4.** Parâmetros conservativos (CP) e não conservativos (NCP) do cultivo da cana-de-açúcar do arquivo padrão do modelo AquaCrop e os parâmetros alterados

| Parâmetros não conservativos (NCP)                                                 | Originais                | Proposta de alteração |                                     |       |     |
|------------------------------------------------------------------------------------|--------------------------|-----------------------|-------------------------------------|-------|-----|
| Cobertura inicial do dossel (CCo)                                                  | 0.91                     | 0.27                  | %                                   |       |     |
| Mudas transplantadas                                                               | 6.50                     | 3.16                  | cm <sup>2</sup> plant <sup>-1</sup> |       |     |
| Densidade de plantio                                                               | 140,000                  | 85,443                | plantas ha <sup>-1</sup>            |       |     |
| Cobertura máxima do dossel (CCx)                                                   | 95                       | 90                    | %                                   |       |     |
| Desenvolvimento (a partir da emergência):                                          |                          |                       |                                     |       |     |
| Para recuperação                                                                   | 7                        | 21                    | days                                | 306   | GDD |
| Para atingir CCx                                                                   | 64                       | 144                   | days                                | 2,240 | GDD |
| Para início da senescência                                                         | 330                      | 345                   | days                                | 5,030 | GDD |
| Até a colheita                                                                     | 365                      | 375                   | days                                | 5,460 | GDD |
| Para crescimento máximo de raízes                                                  | 60                       | 362                   | days                                | 5,270 | GDD |
| Comprimento máximo de raízes                                                       | 1.80                     | 1.80                  | m                                   |       |     |
| Parametros conservativos (CP)                                                      |                          |                       |                                     |       |     |
| Coeficiente de transpiração do cultivo (k <sub>CTr</sub> )                         | 1.10                     | 1.20                  |                                     |       |     |
| Coeficiente de envelhecimento                                                      | 0.15                     | 0.10                  | %day <sup>-1</sup>                  |       |     |
| Produtividade da água normalizada                                                  | 30                       | 30                    | g m <sup>-2</sup>                   |       |     |
| Temperatura base inferior                                                          | 9.0                      | 9.0                   | °C                                  |       |     |
| Temperatura base superior                                                          | 32.0                     | 32.0                  | °C                                  |       |     |
| Coeficiente de crescimento (CGC)                                                   | 12.50                    | 6.80                  | % day <sup>-1</sup>                 |       |     |
| Requerimento para atingir CCx                                                      | -                        | 2,240.0               | GDD                                 |       |     |
| Coeficiente de declínio (CDC)                                                      | 7.60 % day <sup>-1</sup> | 0.673                 | % GDD <sup>-1</sup>                 |       |     |
| Coeficientes de estresses hídricos (Ks = 1, sem estresse, Ks = 0, estresse máximo) |                          |                       |                                     |       |     |
| Nível de estresse afetando a expansão do dossel (Ks <sub>exp</sub> )               | 0.25 - 0.55              | 0.10 - 0.40           | Fração da CAD reduzida              |       |     |
| o fechamento de estômatos (Ks <sub>sto</sub> )                                     | 0.50                     | 0.50                  | “                                   |       |     |
| a senescência precoce (Ks <sub>sen</sub> )                                         | 0.60                     | 0.60                  | “                                   |       |     |

CAD = capacidade de água disponível, a água mantida entre a capacidade de campo e o ponto de murcha permanente. GDD são os graus-dia médio de crescimento em todos os períodos do conjunto de dados de calibração (Araraquara).

**Tabela 5.** Coeficientes de conversão de biomassa seca total para biomassa fresca ( $f_{dry-fresh}$ ) com remoção de folhas ( $f_{trash}$ ) para cálculo de toneladas de cana por hectare (TCH).

| $f_{dry-fresh}$ |      | $f_{trash}$                                      |  |
|-----------------|------|--------------------------------------------------|--|
| Valores fixos   |      | Valores sazonais de acordo com o mês de colheita |  |
| Agosto          | 0.30 | 0.39                                             |  |
| Setembro        |      | 0.33                                             |  |
| Outubro         |      | 0.39                                             |  |
| Novembro        |      | 0.43                                             |  |




**Figura 4.** Comparação do desempenho do modelo para todas as safras da validação (Pradópolis, Iracemápolis e Quirinópolis) usando o coeficiente mensal sazonal ajustado  $f_{trash}$  (a) e  $f_{trash}$  fixo = 0,60 (b). MAPE é erro percentual absoluto médio, RRMSE é raiz quadrática do erro médio e Es é erro sistemático.

### 3.3.3. Calibração

No geral, os indicadores estatísticos mostraram desempenho bom a excelente após a calibração (RRMSE = 10%) de todos parâmetros, NCP e CP (Figura 5). As colheitas de setembro e novembro mostram alguma subestimação de TCH, enquanto agosto e outubro tendem a ser superestimados. Após a

calibração dos parâmetros da cultura (NCP e CP), o modelo explica 73% da variabilidade observada da biomassa ( $R^2 = 0,73$ ), enquanto que, sem calibrar os CP, 52% da variabilidade da biomassa observada poderia ser explicada pelas simulações do modelo. Acurácia das simulações foi boa com MAPE = 7,6% ou 6,0 toneladas  $ha^{-1}$ , considerando a média de TCH de Araraquara.




**Figura 5.** Comparação da biomassa fresca observada com a biomassa fresca simulada ( $t\ ha^{-1}$ ) para o conjunto de dados de calibração da região de Araraquara, de 2002 a 2014, com CP atualizada (a) e parametrização CP padrão AquaCrop (b).


### 3.3.4. Validação

Os dados de validação, a fim de melhor apresentar os resultados, foram separados: São Paulo (Figura 6) e Quirinópolis-Goiás (Figura 7). No estado de São Paulo, o modelo calibrado pode explicar 30% da variabilidade observada da biomassa. O modelo AquaCrop em geral subestimou as observações com um erro sistemático (Es) de 15,25  $t\ ha^{-1}$ . Ainda, com RRMSE = 17%, o desempenho do modelo foi classificado como bom.

No estado de Goiás (Quirinópolis), as simulações foram classificadas entre fracas e bom, com RRMSE = 19,46% e MAPE = 13,44% ou 14  $t\ ha^{-1}$ , e apresentaram precisão baixíssima, ou nenhuma precisão ( $R^2 = 0,12$ ) (Figura 7).



**Figura 6.** Comparação da biomassa fresca observada com a biomassa fresca simulada ( $\text{t ha}^{-1}$ ) para os dados de Pradópolis e Iracemápolis, nas safras de 2002 a 2014, com parametrização de parâmetros conservativos atualizados (a) e padrão (b). MAPE é erro percentual absoluto médio, RRMSE é raiz quadrática média erro quadrático e Es é erro sistemático.



**Figura 7.** Comparação da biomassa fresca observada com a biomassa fresca simulada ( $\text{t ha}^{-1}$ ) de Quirinópolis, nas safras de 2008 a 2014, com parametrização de parâmetros conservativos atualizados (a) e padrão (b). MAPE é erro percentual absoluto médio, RRMSE é raiz quadrática média erro quadrático e Es é erro sistemático.

### 3.3.5. Resposta das simulações às estações úmidas e secas

A classificação das estações de acordo com a precipitação apresentou diferenças na acurácia das simulações do modelo AquaCrop, entre condições úmidas e secas (Tabela 6). Os indicadores estatísticos mostraram melhor desempenho do modelo em condições úmidas ( $> 1500$  mm), com exceção do erro sistemático (Es), que foi similar nas duas condições.


**Tabela 6.** Avaliação do desempenho do modelo em safras de condição úmida e seca, de acordo com a precipitação acumulada de toda a safra (P).

|                                                  | Condição úmida | Condição seca |
|--------------------------------------------------|----------------|---------------|
|                                                  | P > 1500 mm    | P < 1500 mm   |
| <b>n° safras</b>                                 | 28             | 52            |
| <b>MAPE (%)</b>                                  | 9.7            | 15.45         |
| <b>MAPE (t ha<sup>-1</sup>)</b>                  | 8.21           | 13.43         |
| <b>RRMSE (%)</b>                                 | 12.18          | 18.45         |
| <b>Es (t ha<sup>-1</sup>)</b>                    | 11.32          | 11.45         |
| <b>Média B<sub>obs</sub> (t ha<sup>-1</sup>)</b> | 84.65          | 86.93         |

A análise de frequência quantificou a precipitação sazonal em três categorias: seca, normal e úmida, com 1370 mm, 1670 mm e 1990 mm, respectivamente. Com base na análise, a safra 2006-07, com colheita em outubro na região de Iracemápolis, foi selecionada como representativa para uma safra seca típica, temporada 2009-10 com colheita em agosto em Pradópolis como uma típica safra úmida e safra 2011-12 com colheita em agosto em Pradópolis como safra típica de precipitação normal (Tabela 7). A transpiração sazonal mostra uma clara tendência decrescente com a diminuição da pluviosidade, e indica períodos curtos a longos de estresse hídrico severo, reduzindo a condutância estomática em condições típicas normais e secas. O erro médio da simulação de biomassa aumenta com o aumento do estresse hídrico (Figura 8).

**Tabela 7.** Visão geral das respostas das simulações do modelo AquaCrop para condição seca, normal e úmida nas safras de cana de açúcar no estado de São Paulo. P é a precipitação acumulada (mm), Tr é a transpiração (mm), ETo é a evapotranspiração de referência (mm), ARM é o armazenamento de água no solo (mm dia<sup>-1</sup>), T min é a temperatura mínima do ar (°C), B obs e B sim são a biomassa observada e simulada (t ha<sup>-1</sup>), respectivamente, e ME é o erro médio das simulações.

| Condição de Precipitação | P      | Tr    | ETo  | ARM   | Tmin | B obs  | B sim              | ME     |
|--------------------------|--------|-------|------|-------|------|--------|--------------------|--------|
|                          |        | mm    |      |       | °C   |        | t ha <sup>-1</sup> |        |
| <b>Seca</b>              | 1372.4 | 410.5 | 4.39 | 807.8 | 14.9 | 95.48  | 63.27              | -32.21 |
| <b>Normal</b>            | 1669.5 | 705.4 | 3.21 | 567.3 | 15.2 | 112.95 | 95.89              | -17.06 |
| <b>Úmida</b>             | 1989.4 | 842.3 | 3.06 | 569.1 | 16.2 | 100.41 | 99.87              | -0.54  |



**Figura 8.** Transpiração do cultivo (quadro superior), desenvolvimento do dossel (quadro do meio) e depleção de água no solo (quadro inferior) para cana-de-açúcar simulada no modelo AquaCrop em estação úmida (a) normal (b) e seca (c). As linhas coloridas indicam o nível de depleção da água no solo que causam redução na expansão da cobertura do dossel (verde), fechamento estomático (vermelho) e senescência precoce (amarelo). As setas indicam quando o estresse hídrico grave começou.

### **3.4. DISCUSSÃO**

#### **3.4.1. Coeficientes de crescimento e declínio (CGC e CDC, respectivamente)**

O desenvolvimento da cultura é simulado em graus-dias (GDD), portanto modulado por variações de temperatura. Para a cana-soca, a CGC foi reduzida porque o crescimento da planta é mais lento e a cobertura máxima do dossel é alcançada mais tarde do que as mudas de cana-de-açúcar pré-germinadas transplantadas já com suas primeiras folhas acima do solo. O CDC foi aumentado para representar a influência de temperaturas noturnas mais frias (próximo à temperatura base da cultura; Camargo et al., 1993; Prela-Pantano et al., 2009). A baixa temperatura reduz a assimilação de CO<sub>2</sub> e a eficiência da condutância estomática, o que desacelera o crescimento da planta (Machado et al., 2013).

#### **3.4.2. Coeficiente de estresse para expansão do dossel ( $K_{s_{exp}}$ )**

Em geral, a cana-de-açúcar é considerada um cultivo de alta demanda hídrica, e seu crescimento é sensível à disponibilidade de água (Lakshmanan e Robinson, 2014; Inman-Bamber et al., 2009). Apesar do fato de a cana adotar um mecanismo C4 que facilita o desenvolvimento da cultura em áreas quentes e secas, reduzindo a taxa de fotorrespiração e a perda de água, Ghannoum (2009) afirma que a bioquímica metabólica da fotossíntese C4 é tão ou mais sensível à água do que a das plantas C3. O coeficiente de estresse que determina a resposta da expansão do dossel ao estresse hídrico no AquaCrop está fisicamente relacionado a duas fases principais do desenvolvimento da cana: o perfilhamento e o alongamento do caule. Como esse crescimento foliar nessas fases é relativamente suscetível ao estresse hídrico (Ramesh, 2000; Inman-Barber e Smith, 2005; Machado et al., 2009), níveis mais baixos e superiores de  $K_{s_{exp}}$  foram ajustados para 0,1 e 0,4, respectivamente, tornando assim a cultura mais sensível a falta de água.

O estresse hídrico da cana-de-açúcar é um atributo de cultivo relacionado ao genótipo, em que a alta variabilidade de expressões gênicas sugere complexidade na quantificação das respostas do estresse hídrico da cana-de-açúcar (Andrade et al., 2015).

### 3.4.3. Transpiração do cultivo

Os parâmetros ajustados que afetam a transpiração do cultivo foram o coeficiente de transpiração do cultivo ( $KcTr$ ) e o envelhecimento ( $\% \text{ dia}^{-1}$ ) que representa a taxa de redução do dossel com o avanço da idade do canavial. Adotamos o  $KcTr = 1.20$ , conforme recomendado pela FAO (Allen et al., 1998) para o cultivo da cana-de-açúcar em regiões tropicais. Coeficientes de colheita semelhantes de cana-de-açúcar no meio e no final da estação foram encontrados por Silva et al. (2012) em regiões tropicais do Brasil.

O valor da taxa de envelhecimento foi reduzido de  $0,15\% \text{ dia}^{-1}$  para  $0,10\% \text{ dia}^{-1}$ . Esse ajuste foi feito para representar a planta de cana-de-açúcar na fase de colheita, quando a cobertura do dossel ainda está próxima do seu máximo, com apenas algumas folhas amareladas, mas com aparência ainda vigorosa.

### 3.4.4. Coeficientes de conversão de biomassa

Em geral, a biomassa de caules frescos é uma medida bem conhecida da produção de cana-de-açúcar. Estudos de campo e artigos científicos revisados normalmente relatam resultados da produção de cana de açúcar em peso fresco ao invés de peso seco (Zhao et al., 2010; Legendre e Burner, 1995; Zhao et al., 2010; Leal et al., 2017). A conversão da biomassa faz com que a saída do modelo AquaCrop seja de um valor mais útil para o setor de cana-de-açúcar.

O  $f_{trash}$  na cana-de-açúcar é definido principalmente como folhas que são removidas no campo durante as operações de colheita, principalmente para melhorar a fertilidade do solo com nutrientes e coberturas orgânicas. Depois de pelo menos oito folhas terem surgido, a biomassa da cana-de-açúcar começa a se desenvolver, enquanto a massa dos talos aumenta, a fração da folhagem diminui.

A fração de folhagem difere no campo entre cultivares e épocas de colheita, sendo esta última influenciada pela temperatura (Robertson et al., 1999; Donaldson et al., 2008). A influência das condições ambientais de colheita na quantidade e composição de folhagem foi demonstrada em vários estudos (Robertson e Thorburn, 2007; Donaldson et al., 2008; Marin et al., 2014).

Neste estudo, o uso de coeficientes de folhagem com conversão sazonal melhorou as simulações de biomassa fresca no modelo AquaCrop, obtendo

respostas mais factíveis e em concordância com práticas usadas no setor da de cana-de-açúcar para quantificar a produção.

#### **3.4.5. Calibração**

A tolerância ao estresse hídrico da cana-de-açúcar é complexa e ainda não totalmente compreendida. Diferenças na tolerância entre cultivares parecem existir (Graça et al., 2010; Ferreira et al., 2017; Andrade Junior et al., 2017). Ainda assim, seguindo a filosofia do AquaCrop de gerar um conjunto genérico de parâmetros conservativos (CP) para uma cultura, neste caso para a cana-de-açúcar foram calibrados um conjunto de CP. Diferenças potenciais entre cultivares devem ser cobertas pelo ajuste de parâmetros não conservativos (NCP), o que deve ser feito pelos usuários do modelo sempre antes de executar o modelo em um novo ambiente.

A análise estatística indicou concordância aceitável entre observações de biomassa e as simulações do modelo AquaCrop para cana-de-açúcar, mas com tendência geral de subestimação da biomassa fresca observada. A biomassa simulada variou entre 55 e 105 t ha<sup>-1</sup>, enquanto a biomassa observada variou entre 65 e 115 t ha<sup>-1</sup>. A subestimação foi maior em anos secos com precipitação sazonal abaixo de 1500 mm (Tabela 6).

Estações normais e particularmente secas apresentaram erros maiores entre os dados observados e simulados em comparação com as estações úmidas típicas (Tabela 7). Como o estado de São Paulo apresenta anos mais secos com precipitações abaixo de 1.500 mm, a subestimação da biomassa registrada foi geralmente maior nesse estado.

Quando são realizadas simulações em uma estação seca típica (Figura 9c), pode-se observar que quantidades limitadas de precipitação se traduzem em menor disponibilidade de umidade do solo ao longo do ciclo de crescimento. O cultivo não pode chegar ao final do ciclo de crescimento nas simulações e morre antes da colheita. Isso não é realista e não acontece no campo. Em vez disso, o cultivo permanece no campo e pode recuperar se a água estiver disponível no final do ciclo de crescimento.

O estresse hídrico reduz a produção de biomassa no campo, mas não tão forte quanto foi simulado pelo modelo. Em uma estação úmida, a depleção de

água do solo abaixo da capacidade de campo é baixa (Figura 9a) e a produção de biomassa é quase ótima, o que geralmente é bem simulado pelo modelo (Tabela 7).

Em uma condição normal como a safra 2011-12 com a colheita de agosto em Pradópolis (Figura 9b), a disponibilidade de água é limitada a partir da brotação intermediária, mas o estresse hídrico é moderado o suficiente para garantir o desenvolvimento da cultura até o final do ciclo.

Para a safra de condição seca, o cultivo da cana-de-açúcar não chegou nem ao final do ciclo em sua simulação, isso não acontece no campo, onde a colheita chega ao final do ciclo e provavelmente com o retorno de água disponível ao final do ciclo a planta pode se recuperar e ainda alcançar produção média de biomassa fresca.

#### **3.4.6. Validação**

A subestimação da biomassa fresca da cana-de-açúcar ocorreu com maior frequência nas simulações do modelo AquaCrop para locais de validação no estado de São Paulo, provavelmente isto está relacionado à presença de mais safras com menos de 1500 mm de precipitação durante o ciclo da cultura (Tabela 6).

Em geral, mesmo com valores subestimados visíveis, a biomassa simulada variou de 55 a 105 t ha<sup>-1</sup>, enquanto a biomassa observada variou de 65 a 115 t ha<sup>-1</sup>, evidenciando que os valores simulados estavam próximos do observado no geral, mas a precisão foi baixa (Figura 7). Essa subestimação no desempenho do modelo deve-se ao fato de que os maiores erros de simulação foram observados nas estações mais secas, quando a quantidade de precipitação não satisfaz as exigências mínimas de água para o desenvolvimento da cultura (1.500 a 2.000 mm por safra), afetando o balanço hídrico e consequentemente a simulações de biomassa.

Zhao e Li (2015) confirmam que a variabilidade interanual na produção de cana-de-açúcar segue diferenças sazonais nas condições climáticas, particularmente na precipitação. Rolim et al. (2015) também verificaram que a variabilidade na produção de biomassa e nos teores de sacarose da cana-de-açúcar está fortemente relacionada aos efeitos do fenômeno ENOS no clima

para São Paulo. Apesar de várias tentativas de calibrar os parâmetros das culturas que afetam a resposta da cultura à disponibilidade de água (severa), não conseguimos encontrar um conjunto de parâmetros que permita simular a sobrevivência de uma cultura de cana-de-açúcar em condições de estresse hídrico muito severo.

Ao distinguir entre as estações chuvosa e seca, foi demonstrado que o desempenho do modelo AquaCrop melhorou quando a disponibilidade de água era alta. Esta conclusão foi também encontrada em muitos estudos anteriores utilizando o modelo AquaCrop para simulação do ciclo de outros cultivos, p.e. Toumi et al. (2016) para trigo, Farahani et al. (2009) para algodão, Heng et al. (2009) e Abendipour et al. (2012) para o milho e, também para a cana-de-açúcar (Bahmani e Eghbalian, 2018).

No Brasil, Silva et al. (2018) encontraram resultados semelhantes usando o modelo AquaCrop para simulações de soja e concluíram que o modelo foi mais eficaz quando usado sob condições controladas de gerenciamento de água do que sob condições de regime natural de água. Na maioria dos estudos, o desempenho do modelo é relatado como bom e há redução nos erros das simulações do modelo AquaCrop quando usado para cultivos sob sistema irrigado.

Em pesquisas adicionais com o modelo AquaCrop para simulação de cana-de-açúcar, é uma opção usar mais dados que podem ser comparados ao resultado simulado do modelo, ou seja, observações da cobertura do dossel, acúmulo de biomassa no decorrer do ciclo e teor de água no solo. Isso poderia ajudar na parametrização e calibração do modelo, pois com a variedade de cultivares, as características da cultura diferem entre ambiente e manejo.

Acredita-se que mais dados de descrição do crescimento da planta, e não apenas de produção final, poderiam facilitar a compreensão dos processos fisiológicos e a influência do estresse abiótico no desenvolvimento da cultura da cana-de-açúcar, facilitando a representação de seu ciclo para simulações mais acuradas.

Um trabalho subsequente está sendo desenvolvido para simular o teor de açúcar da cana-de-açúcar. A proposta é adicionar um método específico que

considere os estresses hídricos e térmicos durante a fase de maturação da cana-de-açúcar aos cálculos do modelo AquaCrop.

### **3.5. CONCLUSÕES**

Neste estudo, foi proposto um conjunto atualizado de parâmetros conservativos para a cana-de-açúcar no modelo AquaCrop e calibrados os parâmetros locais para simular com segurança a produção de biomassa de cana-de-açúcar no Brasil.

O ajuste dos parâmetros conservativos, incluindo as taxas de expansão e declínio do dossel (CGC e CDC, respectivamente), a resposta de expansão do dossel ao estresse hídrico, o fator de transpiração específico da cultura ( $k_c$ ) e a taxa de envelhecimento, resultou em um conjunto de parâmetros mais acurado para simulação de cana-de-açúcar do que o conjunto padrão de parâmetro do modelo AquaCrop para cana-de-açúcar.

O uso do modelo AquaCrop pode contribuir para os estudos e melhor entendimento das relações hídricas da cultura da cana-de-açúcar com o ambiente.

Além disso, um modelo adicional de produção foi gerado pela conversão da biomassa seca para o valor mais prático de biomassa frescas de caules, através da inclusão de coeficientes de conversão da biomassa e a estimativa da fração de folhagem da cana-de-açúcar. Isso contribuiu para a usabilidade do modelo, que agora pode ser aplicado para estimar produção da cana-de-açúcar em unidade apropriada e que são de uso direto dos produtores.

A validação do modelo mostrou concordância aceitável entre simulações e observações de biomassa, embora o modelo apresente a característica/tendência de subestimar a produção. Os erros nas simulações do modelo AquaCrop foram menores em condições de estresse hídrico limitado.

## AGRADECIMENTOS

Agradecemos a Fundação de Coordenação e Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento deste projeto e o apoio do departamento de Ciências Ambientais e do Solo da Universidade de Leuven, na Bélgica, em especial a colaboração da Dra. Eline Vanuytrecht no desenvolvimento deste trabalho.

## 3.6. REFERÊNCIAS

- Abendipour, M., Sarangi, A., Rajput, T. B. S., Singh, M., Pathak, H., Ahmad, T. 2012. Performance evaluation of AquaCrop model for maize crop in a semi-arid environment. *Agricultural Water Management*. 110:55-66.
- Allen, R.G., Pereira, L.S., Raes, D. and Smith, M. 1998. Crop evapotranspiration. Guidelines for Computing Crop Water Requirements. FAO Irrigation Drainage Paper No. 56, FAO, Rome.
- Andrade Junior, A. S., Bastos, E. A., Ribeiro, V. Q., Sobrinho, C. A., Silva, P. H. S. 2017. Stalk yield of sugarcane cultivars under different water regimes by subsurface drip irrigation, *R. Bras. Eng. Agríc. Ambiental*, v.21, n.3, p.169-174.
- Andrade, J. C. F., Terto, J., Silva, J. V., Almeida, C. 2015. Expression profiles of sugarcane under drought conditions: Variation in gene regulation. *Genetics and Molecular Biology*, 38, 4, 465-469. <http://dx.doi.org/10.1590/S1415-475738420140288>.
- Bahmani, O., Eghbalian, S. Simulating the Response of Sugarcane Production to Water Deficit Irrigation Using the AquaCrop Model. 2018. *Agric Res* (June 2018) 7(2):158–166. <https://doi.org/10.1007/s40003-018-0311-0>.
- Camargo, M. B. P., Pedro Junior, M. J., Alfonsi, R. R., Ortolani, A. A., Brunini. 1993. Probability of monthly and yearly absolute minimum temperature occurrence in the state of São Paulo, Brazil. *Bragantia*, Campinas, 52(2):161-168.
- Bello, CAC 2013. Uso del modelo Aquacrop para estimar rendimientos para el cultivo de caña de azúcar en el departamento del valle del Cauca. Report of

Proyecto de Cooperación técnica TCP/COL/3302. FAO & Ministerio de Agricultura y Desarrollo Rural de Colombia. 66p. ISBN I3427S/1/08.13.

Castro, O. M., Viera, S. R., Siqueira, G. M., Andrade, C.A. 2009. Physical and chemical attributes of a rhodic hapludox under different tillage systems. *Bragantia*, Campinas, v.68, n.4, p. 1047-1057.

CONAB, 2010. (Companhia Nacional de Abastecimento: <https://www.conab.gov.br/>)

Donaldson, R. A., Redshaw, K. A., Rhodes, R., Van Antwerpen, R. 2008. Season effects on productivity of some commercial South African sugarcane cultivars, II: Trash production. *Proc S Afr Sug Technol Ass*, 81:528-538.

Di Paola, A., Valentini, R., Santini, M. An overview of available crop growth and yield models for studies and assessments in agriculture. *J Sci Food Agric*, 96:709-714, 2016. Doorenbos, J.; Kassam, A.H. Crop Yield response to water. 1994. FAO-Irrigation and Drainage. 306p.

Dourado-Neto, D.; Teruel, K.; Reichardt, D.R.; Nielsen, J.A. ;Frizzone; Bacchi, O.O.S., 1998. Principles of Crop Modeling and Simulation: I. Uses of Mathematical Models in Agricultural Science. *Scientia Agricola*, Piracicaba, v.55, p.46–50.

FAO, Climate-Smart Agriculture: Sourcebook. Rome, Italy: Food and Agriculture Organization of the United Nations, 2013.

Farahani, H. J., Izzi, G., Oweis, T. Y. 2009. Parameterization and Evaluation of the AquaCrop Model for Full and Deficit Irrigated Cotton. *Agronomy Journal*, v.101, n.3.

Ferreira, T. H. S., Tsunada, M. S., Bassi, D., Araújo, P., Matiello, L., Guidelli, G. V., Righetto, G. L., Gonçalves, V. R., Lakshmanan, P., Menossi, M. 2017. Sugarcane Water Stress Tolerance Mechanisms and Its Implications on Developing Biotechnology Solutions. *Frontiers in Plant Science*. v. 8, n. 1077. doi: 10.3389/fpls.2017.01077.

Ghannoum, O. 2009. C4 photosynthesis and water stress. *Annals of Botany*, Vol.103, No.4, (June 2008), pp. 635–644, 2009. ISSN 1095-8290.

Graça, J. P., Rodrigues, F.A., Farias, J. R. B., Oliveira, M. C. N., Hoffmann-Campo, C. B., Zingaretti, S. M. 2010. Physiological parameters in sugarcane cultivars submitted to water deficit. *Braz. J. Plant Physiol.*, 22(3): 189-197.

Heinrichs R., Otto R., Magalhães A., Meirelles G.C. (2017) Importance of Sugarcane in Brazilian and World Bioeconomy. In: Dabbert S., Lewandowski I., Weiss J., Pyka A. (eds) *Knowledge-Driven Developments in the Bioeconomy. Economic Complexity and Evolution*. Springer, Cham.

Heng, L.K., Hsiao, T.C., Evett, S., Howell, T., and Steduto, P., 2009. Validating the FAO AquaCrop Model for Irrigated and Water Deficient Field Maize. *Agron. J.* 101, 488-498.

IAC, 2018. Agronomic Institute (<http://www.iac.sp.gov.br/>).

Inman-Bamber, N. G., Bonnett, G. D., Spillman, M. F., Hewitt, M. L., Xu, J. 2009. Source–sink differences in genotypes and water regimes influencing sucrose accumulation in sugarcane stalks. *Crop Pasture Sci.* 60 (4): 316-327.

Inman-Bamber, N., Smith, D. 2005. Water relations in sugarcane and response to water deficits. *Field Crops Res.* 92, 185–202. doi: 10.1016/j.fcr.2005.01.023.

Inman-Bamber, N.G. 1991. A growth model for sugar-cane based on a simple carbon balance and the CERES-Maize water balance. *South African Journal of Plant and Soil* 8 (2): 93–99.

Kadiyala, M.D.M., Nedumaran, S., Singh, P., Chukka, S., Irshad, M.A., Bantilan, M.C.S., 2015. An integrated crop model and GIS decision support system for assisting agronomic decision making under climate change. *Sci. Total Environ.* 521, 123–134.

Karunaratne, A. S., Azam-Ali, S. N., Izzi, G., Steduto, P. 2011. Calibration and Validation of FAO-AquaCrop model for irrigated and water deficient Bambara groundnut. *Expl Agric.* v. 47, n. 3, p. 509–527.

Lakshmanan, P., Robinson, N. (2014). “Stress physiology: Abiotic stresses,” in *Sugarcane: Physiology, Biochemistry, and Functional Biology*, ed P. H. Moore and F. C. Botha (Chichester: John Wiley & Sons, Inc.), 411–434.

Leal, D. P. V., Coelho, R. D., Barbosa, F. S., Fraga Junior, E., Mauri, R., Santos, L. 2017. Water productivity for sugar and biomass of sugarcane varieties. R. Bras. Eng. Agríc. Ambiental, v.21, n.9, p.618-622.

Legendre, B. L., Burner, D. M. 1995. Biomass production of sugarcane cultivars and early-generation hybrids. Biomass and Bioenergy. v.8, n.2, p.55-61.

Liu, De Li, and G. Kingston. 1995. QCANE: A simulation model of sugarcane growth and sugar accumulation. Research and Modelling Approaches to Assess Sugarcane Production Opportunities and Constraints 1: 25–29.

Machado, R., Ribeiro, R., Marchiori, P., Machado, D., Machado, E., and Landell, M. 2009. Biometric and physiological responses to water deficit in sugarcane at different phenological stages. Pesqui. Agropecu. Bras. 44, 1575–1582. doi: 10.1590/S0100-204X2009001200003.

Machado, D. F. S. P., Lagôa, A. M. M. A., Ribeiro, R. V., Marchiori, P. E. R., Machado, R. S., Machado, E. C. 2013. Low night temperature and water deficit on photosynthesis of sugarcane. Pesq. Agropec. Bras., Brasília, v.48, n.5, p.487-495. doi: 10.1590/S0100-204X2013000500004.

Marin, F. R., Thorburn, P. J., da Costa, L. G., Otto, R. 2014. Simulating Long-Term Effects of Trash Management on Sugarcane Yield for Brazilian Cropping Systems. Sugar Tech. 16(2): 164-173. DOI 10.1007/s12355-013-0265-2.

McCown, Robert L., Graeme L. Hammer, John Norman Gresham Hargreaves, Dean P. Holzworth, and David M. Freebairn. 1996. APSIM: A novel software system for model development, model testing and simulation in agricultural systems research. Agricultural Systems 50 (3): 255–271. [https://doi.org/10.1016/0308-521X\(94\)00055-V](https://doi.org/10.1016/0308-521X(94)00055-V).

Montanari, R., Marques Junior, J., Campos, M. C. C., Souza, Z. M., Camargo, L. A. 2010 Mineralogical characterization of Oxisol in different relief form in the region of Jaboticabal, SP, Rev. Ciênc. Agron., v. 41, n. 2, p. 191-199.

NASA-POWER, 2017. (National Aeronautics and Space Administration: <https://power.larc.nasa.gov/>).

Prela-Pantano, A., Rolim, G. S., Camargo, M. B. P. 2009. Probability of occurrence of minimum temperature less than 5°C at Medio Paranapanema region in the state of São Paulo, Brazil. *Bragantia*, Campinas, v.68, n.1, p.279-284.

Rader, M., Kirshen, P., Roncoli, C., Hoogenboom, G., Ouattara, F., 2009. Agricultural risk decision support system for resource-poor farmers in Burkina Faso, West Africa. *J. Water Resour. Plan. Manag.* 135, 323–333.

Raes, D., Steduto, P., Hsiao, T.C., Fereres, E., 2009. AquaCrop-the FAO crop model to simulate yield response to water: ii. Main algorithms and software description. *Agronomy Journal* 101, 438–447.  
<https://doi.org/10.2134/agronj2008.0140s>.

Ramesh, P. 2000. Effect of different levels of drought during the formative phase on growth parameters and its relationship with dry matter accumulation in sugarcane. *J. Agron. Crop Sci.* 185, 83–89. doi: 10.1046/j.1439-037x.2000.00404.x.

Robertson MJ, Inmam-Bamber NG, Muchow RC, Wood AW. 1999. Physiology and productivity of sugarcane with early and midseason water deficit. *Field Crops Research* 64, 211–227.

Robertson, F. A., Thorburn, P. J. 2007. Decomposition of sugarcane harvest residue in different climatic zones. *Australian Journal of Soil Research*, 45, 1-11.

Rolim, G. S., Caporusso, N. B., Moreto, V. B., Prela-Pantano, A. 2015. Influence of El Niño and La Niña on sugarcane yield and sucrose production in northern São Paulo, Brazil. *Australian Journal of Crop Science*, v. 9, n. 6, p. 509-516.

Rudorff, B.F.T., Aguiar, D.A., Silva, W.F., Sugawara, L. M., Adami, M., Moreira, M.A., 2010. Studies on the Rapid Expansion of Sugarcane for Ethanol Production in São Paulo State (Brazil) Using Landsat Data. *Remote Sens.*, v.2, p.1057-1076. doi:10.3390/rs2041057.

Saxton, K.E., Rawls, W.J., 2006. Soil water characteristic estimates by texture and organic matter for hydrologic solutions. *Soil Science Society America Journal* 1569–1578.

Saxton, K.E., Willey, P.H., 2009. The SPAW model for agricultural field and pond hydrologic simulation. In: Singh, V.P. & Frevert, D.K., eds. Watershed models. Boca Raton, CRC Press, p.401-435.

SIEG, 2018. Geo-information System of Goiás (<http://www.sieg.go.gov.br/>).

Silva, V. P. R., Borges, C. J. R., Farias, C. H. A., Singh, V. P., Albuquerque, W. G., Silva, B. B. 2012. Water requirements and single and dual crop coefficients of sugarcane grown in a tropical region, Brazil. v.3, n.2, p. 274-286. <http://dx.doi.org/10.4236/as.2012.32032>.

Som-ard, J., Hossain, M.D., Ninsawat, S., Veerachitt, V. 2018. Pre-harvest Sugarcane Yield Estimation Using UAV-Based RGB Images and Ground Observation. Sugar Tech. <https://doi.org/10.1007/s12355-018-0601-7>.

Steduto, P., Hsiao, T.C., Raes, D., Fereres, E., 2009. AquaCrop-The FAO crop model to simulate yield response to water: i. Concepts and underlying principles. Agronomy Journal 101, 426–437. <https://doi.org/10.2134/agronj2008.0139s>.

Toumi, J., Er-Raki, S., Ezzahar, J., Khabba, S., Jarlan, L., Chehbouni, A. 2016. Performance assessment of AquaCrop model for estimating evapotranspiration, soil water content and grain yield of winter wheat in Tensift Al Haouz (Morocco): Application to irrigation management. Agricultural Water Management. 163:219-235.

Vanuytrecht, E., Raes, D., Steduto, P., Hsiao, T.C., Fereres, E., Heng, L.K., Garcia Vila, M., Mejias Moreno, P., 2014. AquaCrop: FAO'S crop water productivity and yield response model. Environmental Modelling & Software 62, 351–360. <https://doi.org/10.1016/j.envsoft.2014.08.005>.

Vanuytrecht, E., Raes, D., Willems, P. 2016. Regional and global climate projections increase mid-century yield variability and crop productivity in Belgium. Reg Environ Change. 16: 659. <https://doi.org/10.1007/s10113-015-0773-6>.

Waclawovsky, A. J., Sato, P. M., Lembke, C. G., Moore, P. H., Souza, G. M. 2010. Sugarcane for bioenergy production: an assessment of yield and regulation of sucrose content. Plant Biotechnology Journal, v.8, p. 263-276. doi: 10.1111/j.1467-7652.2009.00491.x, 2010.

Wallach, D., Goffinet, B., Bergez, J.-E., Debaeke, P., Leenhardt, D., Aubertot, J.N., 2001. Parameter estimation for crop models: a new approach and application to a corn model. *Agron. J.* 93 (4), 757–766.

Zhao, D. and Li, Y. 2015. Climate Change and Sugarcane Production: Potential Impact and Mitigation Strategies, *International Journal of Agronomy*. Article ID 547386, 10 pages. <http://dx.doi.org/10.1155/2015/547386>.

Zhao, D., Glaz, B., Edme, S., Del Blanco, I. 2010. Precision of Sugarcane Biomass Estimates in Pot Studies Using Fresh and Dry Weights. *Journal American Society of Sugar Cane Technologists*, v.30.

## **CAPÍTULO 4 - Modelo AquaCrop: influência de estresses hídricos e térmicos no acúmulo de sacarose**

**RESUMO:** O consumo mundial de produtos da cana de açúcar, seja para a indústria dos biocombustíveis ou para a alimentação, vem aumentando, sendo a sacarose o produto mais importante do cultivo da cana de açúcar. O Brasil é o quarto maior consumidor de açúcar mundial, sendo a Índia, Europa e China os três maiores. A concentração de sacarose é um indicador da qualidade da produção de cana-de-açúcar. Existem diversos índices para mensurar a quantidade de sacarose presente nos colmos. O açúcar total recuperável (ATR) é o mais usado devido a sua importância econômica pois é através dele que é baseado o valor da produção para os produtores rurais no Brasil. Este estudo objetiva o desenvolvimento de um método de estimativa do ATR com base nos cálculos do índice de colheita e produtividade do modelo AquaCrop. Foram usados dados meteorológicos, de solo e de produção de cana de açúcar em três regiões produtoras do estado de São Paulo, Brasil. O método propõe a integração dos efeitos de estresse hídrico e térmico durante a fase de maior acúmulo de sacarose (maturação). O estresse hídrico foi adicionado seguindo a metodologia para outros cultivos já implementados no modelo AquaCrop. Para adição dos efeitos da temperatura foi usado o método de graus dias negativos e equações de coeficientes de estresses. A calibração e validação foram classificadas como excelente com MAPE menor que 5% e RRMSE menor que 10%. O método proposto é inovador e atende uma antiga necessidade do setor que requer de novas tecnologias com resultados mais práticos para mensurar a qualidade do cultivo de cana de açúcar. O método é passível de ser utilizado em outras localidades, com poucos ajustes em relação ao corte e colheita da cana.

**PALAVRAS-CHAVE:** açúcar total recuperável; maturação da cana-de-açúcar; temperatura; disponibilidade hídrica; modelagem.

### **AquaCrop model: influence of water and thermal stresses on sucrose accumulation**

**ABSTRACT:** The world consumption of sugar cane products, whether for the biofuels industry or for food, has been increasing, sucrose being the most important product of sugar cane cultivation. There are several indices to measure

the amount of sucrose present in cane stalks. Total recoverable sugar (TRS) is the most used because of its importance for industry. Through the TRS is based the value of production. This study aims at the development of a method of estimation of TRS, based on the calculations of yield and harvest index of the AquaCrop model. Meteorological, soil and sugarcane production data were obtained from three production regions of the state of São Paulo, Brazil. The method proposes the integration of the effects of water and thermal stresses during the phase of higher accumulation of sucrose (maturation). Water stress was added following the methodology for other crops already implemented in AquaCrop model. To add the effects of temperature stress was used the method of negative degree days and equations of stress coefficients. Calibration and validation were classified as excellent with MAPE less than 5% and RRMSE less than 10%. The proposed method is innovative and meets an old need of the sector that requires new technologies with more practical results to measure the quality of sugarcane cultivation. The method can be used in other localities, with few adjustments in relation to the cutting and harvesting of sugarcane.

**KEY-WORDS:** total recoverable sugar; sugarcane maturation; temperature; water availability; crop modeling.

#### 4.1. INTRODUÇÃO

A maturação da cana-de-açúcar é um processo fisiológico que envolve a formação de sacarose ( $C_{12}H_{22}O_{11}$ ), o transporte e o armazenamento desta nos colmos da planta (Watt et al., 2014). Existem vários fatores que podem influenciar o acúmulo de sacarose: tipo de solo, condições climáticas, teor de fibras, cultivar, idade de corte, manejo e práticas de aplicação de fertilizantes (Dantas Neto et al., 2006; Shrivastava et al., 2015; Pereira et al., 2017). Sacarpari e Beuclair (2009) definiram que as plantas de cana-de-açúcar chegam a maturidade fisiológica quando atingem o ponto de maior acúmulo de sacarose.

Considerando as variáveis ambientais, há duas principais que influenciam o acúmulo de sacarose: a disponibilidade de água no solo e a variabilidade da temperatura do ar. Segundo Inman-Barber e Smith (2005), a umidade do solo é o fator mais relevante para a variabilidade da produção de cana-de-açúcar. Para

Cardozo e Sentelhas (2013), além do teor de água no solo, as temperaturas do ar também apresentam efeitos sobre a concentração de sacarose.

Modelos de cultivos agrícolas capazes de estimar o teor de sacarose são ferramentas importantes para o planejamento da colheita da cana-de-açúcar. Embora a literatura apresente muitos modelos para estimar a biomassa, a modelagem do teor de sacarose ainda é um desafio. Modelos mecanísticos têm dificuldades em simular a concentração de sacarose quando as condições de cultivo são modificadas e normalmente usam muitas variáveis de entrada que são complexas para mensurar no campo (Scarpari e Beuclair 2009; Cardozo et al., 2015; Pagani et al., 2017).

Existem diversas variáveis de avaliação da qualidade da produção da cana-de-açúcar que estão diretamente relacionadas à concentração de sacarose. Segundo Silva e Segato (2011) os índices tecnológicos mais comuns para a mensuração da qualidade da cana são POL, pureza de suco, sólidos solúveis e açúcar total recuperável (ATR).

Como as usinas de açúcar e etanol elaboram os preços da cana colhida com base no ATR, esse índice é considerado pelos produtores e pela indústria como o índice de qualidade de referência para a produção de cana-de-açúcar (Costa et al., 2011). Valores de ATR indicam a quantidade de açúcares totais na cana-de-açúcar, consistindo principalmente de sacarose e açúcares redutores (Fernandes 2000).

A complexidade em estimar o teor de sacarose na cana está relacionada à falta de dados observados, já que o setor prefere o uso de indicadores mais práticos para a indústria, e aos processos fisiológicos de conversão e transporte da sacarose não serem inteiramente conhecidos (Verma et al, 2019), o que torna mais difícil sua reprodução por modelos matemáticos.

Uma alternativa é uso de um fator de colheita, que em resumo, pode ser definido para o cultivo da cana como a quantidade de sacarose por unidade de biomassa. Esse fator é conhecido como índice de colheita.

O modelo AquaCrop usa do índice de colheita como fator para estimar a produtividade dos cultivos em seus cálculos. O índice de colheita é utilizado para

medir a eficiência de produtos sintetizados em material de importância econômica (Hay, 1995).

Apesar de ser um modelo mecanísticos, a utilização do índice de colheita nos cálculos do modelo AquaCrop condiz com sua filosofia de simplicidade, pois se utiliza de poucos e intuitivos parâmetros em sua metodologia. O AquaCrop é gratuito e apresenta grande importância no âmbito de projetos para segurança alimentar (Steduto et al., 2009; Raes et al., 2009; Muluneh et al., 2017).

Para o cultivo da cana de açúcar são poucos os trabalhos com uso do modelo AquaCrop, já que este é mais comumente utilizado para modelagem de cultivos anuais, como milho (Martins et al., 2019) e soja (Adeboye et al., 2019).

O objetivo deste estudo é adaptar o modelo AquaCrop para (i) incluir a influência dos estresses hídricos e térmicos em seus cálculos para o índice de colheita, (ii) simular o teor de sacarose da cana-de-açúcar em termos de ATR. E (iii) testar as simulações do teor de sacarose para as regiões de produção de cana-de-açúcar do Brasil no estado de São Paulo.

## **4.2. DADOS E MÉTODOS**


### **4.2.1. Área de estudo e dados observados**

Os dados de três regiões produtoras de cana-de-açúcar do estado de São Paulo foram utilizados para a análise: Pradópolis, Iracemápolis e Araraquara (Figura 1). Foram obtidos dados meteorológicos de temperaturas máxima, mínima e média do ar ( $T_{max}$ ,  $T_{min}$  e  $T$ , respectivamente), dados de precipitação ( $P$ ) e evapotranspiração de referência ( $ET_o$ ), coletados por estações meteorológicas automáticas, em escala diária.  $ET_o$  foi calculado pela fórmula de Penman-Monteith-FAO (Allen et al., 1998).

Dados de produção em toneladas por hectare de biomassa fresca ( $B_{obs}$ ) e valores de açúcar total recuperável ( $TRS_{obs}$ ) para cultivo da cana-soca (Figura 2) foram fornecidos por produtores e usinas locais.



**Figura 1.** Mapa das localidades de produção de cana-de-açúcar do estado de São Paulo (áreas em verde) utilizadas neste estudo (pontos vermelhos). (A) Pradópolis, (B) Araraquara e (C) Iracemápolis. Adaptado de Rudorff et al. (2010).



**Figura 2.** Ciclo da cana-soca (12 meses). Por exemplo, para a temporada 2002-2003: (laranja) emergência; (verde) brotação, crescimento e acumulação inicial de sacarose; (amarelo) maturação e acumulação intensa de sacarose; (preto) mês de colheita referente ao mês de plantio.

O açúcar total recuperável (TRS) indica a quantidade total de açúcares na cana-de-açúcar, consistindo principalmente de sacarose e açúcares redutores. O TRS mede a qualidade da cana-de-açúcar em quilogramas por tonelada de cana e é derivado de outros índices de qualidade, como porcentagem de fibra, pureza do suco e POL (equação 1).

$$TRS = 9.52 \times PC + 9.05 \times RS \quad (\text{eq. 1})$$

sendo, TRS é o açúcar total recuperável em kg ton<sup>-1</sup>, PC é a porcentagem de massa de sacarose contida em uma solução de açúcar (POL%), RS é a porcentagem de açúcares redutores, derivado da porcentagem de fibra e pureza do suco.

O primeiro passo foi organizar os dados observados de acordo com as saídas do modelo AquaCrop, transformando  $TRS_{obs}$ , em  $\text{kg ton}^{-1}$  de cana, para produtividade observada em toneladas de sacarose por hectare ( $Y_{obs}$ , equação 2). É importante mencionar que a transformação de TRS em sacarose é uma aproximação, pois o índice TRS é dependente de outras medidas de qualidade (Costa et al., 2011). Neste estudo, a saída do modelo AquaCrop para produtividade de cana-de-açúcar é referente ao teor de sacarose, em  $\text{t ha}^{-1}$ .

$$Y_{obs} = \left( \frac{TRS_{obs} \times B_{obs}}{1000} \right) \quad (\text{eq. 2})$$

na qual,  $Y_{obs}$  é o teor de sacarose observado em  $\text{t ha}^{-1}$ ,  $TRS_{obs}$  é o açúcar total recuperável observado em  $\text{kg ton}^{-1}$  e  $B_{obs}$  é a biomassa fresca observada de cana, em  $\text{t ha}^{-1}$ .

Após a transformação, os  $Y_{obs}$  e os dados meteorológicos de Araraquara foram usados para calibração do modelo AquaCrop e, em seguida, os testes foram feitos com dados independentes de Pradópolis e Itacemópolis. Foram utilizadas, como um todo, cinco safras (2009-10 a 2013-14) da localidade de Araraquara com colheita de agosto a novembro, totalizando 19 valores observados para calibração. A validação do modelo segue o mesmo esquema (com colheita de agosto a novembro) com 52 dados observados entre as safras 2001-02 a 2013-14.

Os dados de solo seguiram as classificações gerais do Instituto Agronômico (IAC) de Campinas, São Paulo. As características físicas foram adotadas de acordo com os trabalhos de I) Montanari et al. (2010) e II) Castro et al. (2009) e usadas para estimar as características hídricas do solo por funções de pedo-transferência (Saxton e Rawls, 2006; Saxton e Willey, 2009) (Tabela 1).

**Tabela 1.** Propriedades físicas e hídricas dos solos de I) Araraquara e Pradópolis e II) Itacemópolis. CAD é a capacidade de água disponível, PMP é o ponto de murcha permanente, CC é a capacidade de campo, SAT é o ponto de saturação e  $K_{sat}$  é a condutividade hidráulica.

| Solo | Horizonte | Textura        | Profundidade<br>m | CAD<br>mm<br>m <sup>-1</sup> | PMP<br>----- | CC<br>vol %----- | SAT  | $K_{sat}$<br>mm<br>dia <sup>-1</sup> |
|------|-----------|----------------|-------------------|------------------------------|--------------|------------------|------|--------------------------------------|
| I    | 1         | Argilo-arenoso | 0.5               | 90                           | 18.6         | 27.6             | 40.6 | 126                                  |
|      | 2         |                | 1.0               | 102                          | 22           | 32.2             | 41.7 | 49.9                                 |
|      | 3         |                | 1.0               | 111                          | 24.8         | 35.9             | 43.2 | 22.6                                 |
|      | 4         |                | 2.0               | 115                          | 26.4         | 37.9             | 44   | 13.7                                 |
| II   | 1 - 4     | Argiloso       | 0.2 – 4.0         | 107                          | 34.9         | 45.6             | 52.5 | 18                                   |

Por fim, seguindo a linha de tornar as saídas do modelo AquaCrop mais práticas e aplicáveis para o setor, as simulações finais de teor de sacarose ( $Y_{fs}$  em t ha<sup>-1</sup>) foram transformadas novamente para TRS (kg ton<sup>-1</sup> ha<sup>-1</sup>). O cálculo de transformação de TRS (equação 3) é o inverso do cálculo de  $Y_{fs}$ . Também TRS foi usada uma técnica de regressão para minimizar os efeitos combinados de erros nas simulações de biomassa fresca de colmos ( $B_{fs}$ ) e  $Y_{fs}$ .

$$TRS_{sim} = \frac{(Y_{fs} \times 1000)}{B_{fs}} \quad (\text{eq. 3})$$

sendo,  $TRS_{sim}$  é o açúcar total recuperável em kg ton<sup>-1</sup> de biomassa fresca ha<sup>-1</sup>,  $Y_{fs}$  é o teor final de sacarose simulada (t ha<sup>-1</sup>) e  $B_{fs}$  é a biomassa fresca de colmos simulada (t ha<sup>-1</sup>).

#### 4.2.2. Partição de biomassa em sacarose pelo índice de colheita

Este estudo concentra-se na etapa do cálculo de produtividade do modelo AquaCrop (equação 4). Para a cultura da cana-de-açúcar, usamos biomassa fresca simulada ( $B_{fs}$ ), que foi proposto no capítulo anterior como uma transformação da biomassa seca final simulada pelo modelo AquaCrop, sendo a  $B_{fs}$  uma medida mais prática e usual para a realidade dos produtores de cana-de-açúcar. Foi ajustado um coeficiente de índice de colheita ( $HI_{adj}$ ), para calcular a produtividade da cana-de-açúcar em termos de concentração de sacarose ( $Y_{fs}$ , equação 5).

$$Y = HI \times B \quad (\text{eq. 4})$$

sendo,  $B$  é a biomassa seca acima do solo (saída padrão do modelo AquaCrop), em t ha<sup>-1</sup>,  $HI$  é o índice de colheita, que define a fração de biomassa que é parte da produtividade e  $Y$  é a produtividade em t ha<sup>-1</sup>.

$$Y_{fs} = HI_{adj} \times B_{fs} \quad (\text{eq. 5})$$

sendo,  $B_{fs}$  é a biomassa fresca de colmos em t ha<sup>-1</sup>,  $HI_{adj}$  é o índice de colheita, que define a fração de sacarose presente na biomassa e  $Y_{fs}$  é o teor de sacarose em t ha<sup>-1</sup>.

No modelo AquaCrop o índice de colheita é o fator que separa a biomassa da produtividade final dos cultivos. No caso de cultivo de grãos como o milho, o modelo simula a biomassa seca acima do solo e a produtividade final de grãos com uso do índice de colheita (equação 4). Para cada tipo de cultivo existe um método para calcular o índice de colheita.

O ajuste do índice de colheita para cereais, por exemplo, começa a partir do florescimento e segue durante o período de produção dos grãos até a colheita. Para cultivos energéticos, onde o florescimento não é desejável, já que se espera que o produto final apresente alta concentração de açúcares, p.e. a beterraba, existe um período de início de formação do tubérculo até a colheita, que representa o período de ajuste do índice de colheita.

No caso da cana de açúcar o modelo AquaCrop considera o cultivo como de folhas, ou seja, não é computado um período de produção (formação e acúmulo de sacarose). No sentido de incorporar esta etapa de produção no ciclo da cana no modelo AquaCrop o tipo de cultivo foi trocado, passando a usar a cana como cultivo energético (como o ciclo da beterraba) com um período de maior acúmulo de sacarose, geralmente de 4 a 5 meses antes da colheita (Scarpari e Beuclair, 2004).

O índice de colheita ajustado (equação 6) foi calculado seguindo a metodologia do modelo AquaCrop para efeitos de estresses combinados no índice de referência de colheita. Foram aplicados coeficientes para ajustar as respostas da partição da biomassa de cana-de-açúcar referentes a influência do estresse hídrico e do estresse térmico durante a fase de maturação (de maior

acúmulo de sacarose, representada no modelo como o período de *yield formation*.

$$HI_{adj} = HI_0 \times f_{WS} \times f_{TS} \quad (\text{eq. 6})$$

sendo,  $HI_{adj}$  é o índice de colheita ajustado considerando os efeitos totais dos estresses hídricos e térmicos,  $HI_0$  é o índice de colheita de referência,  $f_{WS}$  é o coeficiente pelo qual o  $HI_0$  deve ser multiplicado para considerar o efeito do estresse hídrico e o  $f_{TS}$  é o coeficiente pelo qual o  $HI_0$  deve ser multiplicado para considerar o efeito do estresse térmico.

Quando os coeficientes  $f_{TS}$  e  $f_{WS}$  são unitários, significa que não houve efeito da temperatura ou do estresse hídrico durante o acúmulo de sacarose na maturação da cana-de-açúcar. O  $HI_0$  é um parâmetro não conservativo do modelo AquaCrop, isto significa que o usuário pode alterá-lo de acordo com suas observações.

#### 4.2.3. Determinação de fatores influentes no acúmulo de sacarose

Por meio da análise de componentes principais (PCA) foi possível identificar as fases fenológicas e os fatores ambientais que têm maior influência no acúmulo de sacarose durante todo o ciclo da cana-de-açúcar. A PCA é uma técnica estatística multivariada comumente utilizada em um grande banco de dados, pois permite reduzir o número de variáveis significativas ao fenômeno em estudo.

As variáveis indicadas pela análise de PCA foram utilizadas para desenvolver modelos de regressão linear múltipla (MLR) com a concentração final de sacarose como variável dependente (S) e máximo de quatro variáveis independentes (EVn) devido a limitações computacionais (equação 7). Variáveis mensais ambientais que influenciam o desenvolvimento da cana-de-açúcar foram identificadas e, assim, os principais fatores relacionados à formação e ao acúmulo de sacarose foram utilizados para analisar os períodos, a frequência e os efeitos (positivos e/ou negativos) a serem considerados para ajuste dos coeficientes de estresse ( $f_{WS}$  e  $f_{TS}$ ) nos cálculos do índice de colheita do modelo AquaCrop.

$$S = a \times EV_1 + b \times EV_2 + c \times EV_3 + d \times EV_4 + LC \quad (\text{eq. 7})$$

sendo, S é a concentração final de sacarose, a,b,c,d são os coeficientes angulares da regressão, EVn são as variáveis ambientais e LC é o coeficiente linear.

Devido ao elevado número de regressões possíveis, foi usado o critério de significância pelo valor-p (< 0.05) e as medidas de acurácia (MAPE < 5.0%) e precisão ( $R^2 > 0.71$ ) para seleção das regressões que entraram nas análises.

#### 4.2.4. Ajuste do HI<sub>0</sub> sob influência do estresse hídrico

Dependendo do momento e magnitude do estresse hídrico, este pode afetar o HI<sub>0</sub>. O ajuste do estresse hídrico para a cultura da cana-de-açúcar foi feito diretamente na interface do modelo AquaCrop, alterando o índice de colheita da condição não-estressada para influenciado pela condição de estresse hídrico. O coeficiente de estresse hídrico ( $f_{ws}$ ) segue a metodologia de combinar efeitos positivos e/ou negativos no HI<sub>0</sub> nos cálculos do modelo AquaCrop, uma opção que já existe para outros tipos de cultivos (equação 8).

$$f_{ws} = \left( \frac{n(veg) \times f_{ws(+)} + (n(yield) - n(veg))}{n(yield)} \right) \times f_{ws(-)} \quad (\text{eq. 8})$$


sendo,  $f_{ws}$  é o coeficiente pelo qual o HI<sub>0</sub> deve ser multiplicado para considerar o efeito combinado do estresse hídrico;  $n(veg)$  é o período (dias) em que o crescimento vegetativo ainda é possível;  $n(yield)$  é período (dias) em que o índice de colheita pode ser alterado;  $f_{ws(+)}$  é o coeficiente ajustado para considerar o efeito positivo do estresse hídrico e o  $f_{ws(-)}$  é o coeficiente ajustado para considerar o efeito negativo do estresse hídrico.

#### 4.2.5. Método dos graus-dias negativos (NDD)

O método dos graus-dias negativos (NDD), proposto por Scarpari (2002), foi utilizado para associar o efeito do estresse térmico no acúmulo de sacarose da cana-de-açúcar. O método segue o conceito dos graus-dias (GDD), que relacionam o desenvolvimento das plantas a cada fase fenológica e é controlado por uma soma térmica diária necessária para cada estágio de desenvolvimento, e que muda entre espécies vegetais diferentes (Schoffel e Volpe, 2002).

O método GDD trabalha com a temperatura basal inferior (T<sub>b</sub>), que representa a temperatura mínima necessária para ativar os dispositivos

metabólicos das plantas. Somente quando a temperatura do ar está acima do limite  $T_b$  a planta pode se desenvolver e o mesmo princípio pode ser aplicado para uma temperatura basal superior ( $T_B$ ), acima da qual há uma estagnação das atividades metabólicas e desenvolvimento da planta. O método NDD é o inverso do GDD, onde o efeito no desenvolvimento da planta é medido pelos valores acumulados de NDD durante os períodos em que as temperaturas do ar estão entre  $T_b$  e  $T_{min}$  (Figura 4, equação 9).



**Figura 4.** Esquema do método de soma cumulativa de graus-dias negativos (NDD). Legenda:  $T_M$  é a temperatura máxima do ar;  $T_m$  é a temperatura mínima do ar e  $T_b$  é a temperatura basal inferior. Situação (a), não acumula NDD, situações (b) e (c) há acúmulo de NDD no período em que a área da curva está abaixo de  $T_b$  e acima de  $T_m$  (área hachurada).

$$\left\{ \begin{array}{ll} \text{se } T_b > T_m \rightarrow NDD = \frac{(T_b - T_m)^2}{2 \times (T_M - T_m)} \times N & \text{(eq. 9).} \\ \text{se } T_b \leq T_m \rightarrow NDD = 0 \text{ (zero)} & \end{array} \right.$$

na qual,  $T_M$  é a temperatura máxima média;  $T_m$  é a temperatura mínima média e  $T_b$  é a temperatura base ( $^{\circ}\text{C}$ );  $N$  é o número de dias. O  $T_b$  funciona como um parâmetro não conservativo, em que o usuário pode adotar de acordo com as especificações climáticas da região.

#### 4.2.6. Ajuste do $HI_0$ sob influência do estresse térmico

O método NDD foi utilizado para medir a influência de temperaturas mais baixas no acúmulo de sacarose durante o ciclo da cana-de-açúcar. Ajustamos um coeficiente de estresse de temperatura ( $K_{ST}$ ) de acordo com categorias de acumulação de NDD.

A relação entre o estresse de temperatura e o teor de sacarose é de que quanto mais próximo a zero o valor de  $K_s$ , mais severo é o estresse para a planta, mas em vez de penalizar a concentração de sacarose, as plantas submetidas ao estresse térmico tendem a acumular mais sacarose. Na intenção de representar este ganho de sacarose quando a planta é submetida a temperaturas mais baixas, criamos o coeficiente de estresse térmico ( $f_{TS}$ , equação 10), que é calculado em função dos  $K_{sT}$  e especificidades da cultura. Foi desenvolvida uma equação próxima ao formato das equações do modelo AquaCrop. Para avaliação do  $f_{ws}$ , o modelo utiliza coeficientes de estresse hídrico ( $K_s$ , p.e. para expansão foliar ( $K_{s_{exp}}$ ) e / ou fechamento estomático ( $K_{s_{sto}}$ ) que definem a intensidade e efeito da falta de água no desenvolvimento da planta (manual de referência AquaCrop, capítulo 3; FAO, 2017). No caso do estresse térmico foram ajustados valores de  $K_{sT}$  para determinar a intensidade e o efeito de temperaturas mais baixas no período de maior acúmulo de sacarose (*yield formation*).

$$f_{TS} = \left( \frac{1 - K_{sT}}{10} \right) + c \quad (\text{eq. 10})$$

sendo,  $f_{TS}$  é o coeficiente pelo qual o HI0 deve ser multiplicado para considerar o efeito do estresse térmico;  $K_{sT}$  é o coeficiente de estresse de temperatura e  $c$  é um parâmetro de cultivo (o valor é específico do cultivo e pode variar entre 1 (efeito fraco) e 2 (efeito forte)).

#### 4.2.7. Avaliação de desempenho das simulações

O novo método de cálculo do índice de colheita para a estimar sacarose (TRS) foi avaliado usando duas medidas de acurácia: erro percentual absoluto médio (MAPE, equação 11) e erro médio quadrático relativo (RRMSE, equação 12, Tabela 2), uma medida de tendência: erro sistemático ( $E_s$ , equação 13) e uma medida de precisão: o coeficiente de determinação ( $R^2$ ).

$$MAPE = \frac{\sum_{i=1}^n \left( \left| \frac{TRS_{sim_i} - TRS_{obs_i}}{TRS_{obs_i}} \right| \times 100 \right)}{n} \quad (\text{eq. 11})$$

$$RRMSE = \sqrt{\frac{\sum_{i=1}^n (TRS_{sim_i} - TRS_{obs_i})^2}{n}} \times \frac{100}{TRS_{obs}} \quad (\text{eq. 12})$$

$$ES = \sqrt{\frac{\sum_{i=1}^n (TRS_{obs,i} - \overline{TRS_{sim}})^2}{n}} \quad (\text{eq. 13})$$

sendo,  $TRS_{sim,i}$  é a sacarose simulada na safra  $i$  em  $\text{kg t}^{-1}$  de biomassa fresca de colmos (Bfs)  $\text{ha}^{-1}$ ,  $TRS_{obs,i}$  é a sacarose observada na safra  $i$  em  $\text{kg ton}^{-1}$  de Bfs  $\text{ha}^{-1}$ ,  $\overline{TRS_{obs}}$  é a sacarose observada média em  $\text{kg t}^{-1}$  de Bfs  $\text{ha}^{-1}$ ,  $\overline{TRS_{sim}}$  é a sacarose simulada média em  $\text{kg t}^{-1}$  de Bfs  $\text{ha}^{-1}$  e  $n$  é o número de safras.

**Tabela 2.** Faixas de classificação do desempenho das simulações do modelo, por valores calculados da raiz erro quadrático médio relativo (RRMSE).


| RRMSE    | Classificação de desempenho | ATR equivalente ( $\text{kg}^{-1} \text{ha}^{-1}$ ) |
|----------|-----------------------------|-----------------------------------------------------|
| < 10%    | Excelente                   | < 14,5                                              |
| 10 - 20% | Bom                         | 14,5 a 29                                           |
| 20 - 30% | Fraco                       | 29 a 43,5                                           |
| > 30%    | Ruim                        | > 43,5                                              |

### 4.3. RESULTADOS


#### 4.3.1. Análise de componentes principais e regressões lineares múltiplas

A análise do PCA indicou as variáveis meteorológicas durante fase de intenso crescimento vegetativo (*reach maximum canopy cover*) até o fim da maturação (*yield formation*) como mais influentes no acúmulo de sacarose, dentre as quais a temperatura do ar foi apresentada como mais importante (Figura 5).

Durante o ciclo da cana-de-açúcar, a fase fenológica identificada como mais importante para o acúmulo de sacarose é a maturação (*yield formation*), que em média se inicia de 4 a 5 meses antes da colheita e pode durar entre 120 a 180 dias, ou seja, para cana-soca (12 meses), de safra com o plantio em agosto o acúmulo de sacarose será mais intenso a partir de maio do próximo ano. Considerou-se o período de acumulação intensa de sacarose como o período de possíveis ajustes no índice de colheita (Figura 6).




**Figura 5.** (a) Resultado da análise de componentes principais para as fases do ciclo da cana-soca mais importantes para o acúmulo de sacarose; (b) zoom na área circulada.



**Figura 6.** Representação do índice de colheita padrão para o cultivo tipo folhas no modelo AquaCrop (a) e para cultivo tipo energético, em que existe o período de acúmulo de açúcares e possível ajuste índice de colheita (b). Rec é o tempo em dias que a planta leva para se recuperar após o corte; CCx é o tempo em dias para fechamento do dossel; H é o ponto de colheita (quando a maturidade é alcançada).

Com auxílio dos modelos de regressão linear múltipla identificou-se que durante a expansão do dossel (até atingir CCx) o aumento das temperaturas do ar tem efeito positivo no acúmulo de sacarose e durante a maturação (*yield formation*, YF) o efeito é negativo, com temperaturas mais altas, a concentração de sacarose é prejudicada (Figura 7).



**Figura 7.** Resultado dos pesos das variáveis independentes nas regressões lineares múltiplas com teor de sacarose (TRS) como variável dependente. Tmax, Tmin e T são respectivamente as temperaturas máximas, mínimas e médias do ar e Eto é a evapotranspiração de referência.

#### 4.3.2. Ajustes dos estresses térmicos e hídricos no índice de colheita

Com base nos dados de calibração (Araraquara), foram definidos a intensidade e efeito dos estresses hídricos durante o período de possível ajuste no índice de colheita (*yield formation*). Foi considerado intensidade fraca com efeito positivo no índice de colheita quando a planta é submetida ao estresse hídrico, ou seja, estresse hídrico brando durante período a maturação (*yield formation*), favorece o acúmulo de sacarose. Porém estresse hídrico severo prejudica o acúmulo de sacarose, representado no modelo AquaCrop com efeito negativo e de intensidade forte (Tabela 3).

Os parâmetros que determinam a intensidade dos estresses são conservativos, portanto, o usuário não é incentivado a alterar esses valores, mas é possível fazer pequenos acertos, sem alterar a categoria de intensidade do estresse hídrico. O parâmetro 'a' é referente ao efeito positivo do estresse hídrico durante o período de produção e o parâmetro 'b' é referente ao efeito negativo (Tabela 3).

Outro parâmetro definido foi a taxa máxima de aumento possível para o índice de colheita durante o período de produção (15%), deixando parâmetros não conservativos como  $n(yield)$  e HI0 para serem alterados pelo usuário, quando necessário.


**Tabela 3.** Efeitos dos estresses hídricos no índice de colheita e a variação aceita pelo modelo AquaCrop nos parâmetros específicos de cultivo.

| Efeito                                                      | Parâmetro envolvido | Resposta | Valor Calibrado | Faixa de valor aceitável |
|-------------------------------------------------------------|---------------------|----------|-----------------|--------------------------|
| +                                                           | a                   | Fraca    | 4,0             | 3,0 a 40,0               |
| -                                                           | b                   | Forte    | 3,0             | 1,6 a 4,0                |
| <b>Máximo possível aumento para índice de colheita (HI)</b> |                     | 15,0%    |                 |                          |

Em relação ao estresse térmico, foi necessário desenvolver todo um método, já que os estresses térmicos não são computados pelo modelo AquaCrop nos cálculos do índice de colheita. A partir dos NDD calculados para a região de Araraquara foi possível definir as categorias de estresse térmico a serem consideradas para os efeitos no acúmulo de sacarose. Foram determinados os coeficientes de estresse térmico ( $K_{sT}$ ) (Tabela 4), seguindo a mesma metodologia utilizada pelo modelo AquaCrop para efeitos de estresse hídrico ( $K_{s_{exp}}$ ,  $K_{s_{sto}}$  e  $K_{s_{sen}}$ ) nas simulações de biomassa. Os coeficientes variam de 0,0 a 1,0, sendo 1,0 indicando sem efeito do estresse e zero para condição de estresse total. Além disso, um parâmetro de cultura 'c' foi definido com um intervalo de 1,0 indicando efeito fraco até 2,0 indicando efeito forte (Figura 8). O parâmetro de cultivo 'c' é específico e segue a mesma linha de uso que os parâmetros 'a' e 'b' (para estresse hídrico), podendo mudar em relação a diferentes cultivares de cana-de-açúcar e respostas ao estresse térmico na região de estudo. Os cálculos da soma de NDD são referentes ao número de dias do período de maturação.

**Tabela 4.** Categorias da soma de graus dias negativos ( $\Sigma$ NDD) para identificar intensidade do efeito dos estresses térmicos no acúmulo de sacarose.  $K_{ST}$  é coeficientes de estresse térmico.

| $\Sigma$ NDD | $K_{ST}$ | Efeito   |
|--------------|----------|----------|
| 0 – 20       | 1.00     | Nenhum   |
| 20. – 50     | 0.90     | Fraco    |
| 50. – 100    | 0.70     | Moderado |
| > 100        | 0.50     | Forte    |




**Figura 8.** Valores para o coeficiente de estresse térmico ( $f_{TS}$ ) para várias situações de estresse térmico ( $K_{ST}$ ) que afetam o acúmulo de sacarose e o comportamento das respostas para as variações do parâmetro específico "c".

#### 4.3.3. Desempenho das simulações para acúmulo de sacarose e ATR


O desempenho final das estimações de TRS apresentaram acurácia considerada excelente, de acordo com os valores de RRMSE (< 10%) para a calibração e validação (Figura 9). As saídas diretas do modelo AquaCrop em teor de sacarose ( $Y_{fs}$ , em t ha<sup>-1</sup>) se apresentaram com boa precisão satisfatória (Figuras 10 e 11).

Com MAPE menor que 5% na calibração e validação o modelo erra aproximadamente 3.68 kg ton<sup>-1</sup> ha<sup>-1</sup> considerando TRS médio de 145.55 para Araraquara (calibração) e 6.73 kg ton<sup>-1</sup> ha<sup>-1</sup> considerando TRS médio de Pradópolis e Iracemápolis (validação). Os valores de tendência ( $E_s$ ) foram mais elevados, porém ainda com resultados satisfatórios com menos de 10 kg ton<sup>-1</sup> ha<sup>-1</sup>. A precisão, pelo  $R^2$  foi alta na calibração conseguindo explicar 70% da variabilidade de TRS. Nos testes (validação) 42% da variabilidade de TRS pode


ser explicada pelo modelo AquaCrop e pelos ajustes térmicos e hídricos no índice de colheita.



**Figura 9.** Resultados da calibração (a) e validação (b) para as estimações finais de açúcar total recuperável (TRS) considerando efeitos dos estresses térmicos e hídricos nos ajustes do índice de colheita.




**Figura 10.** Resultados das simulações na calibração do modelo AquaCrop em relação ao teor de sacarose (t ha<sup>-1</sup>) quando usado o índice de colheita ajustado sob influência de estresses hídricos e térmicos (a) e índice de colheita médio (b).



**Figura 11.** Resultados das simulações na validação do modelo AquaCrop em relação ao teor de sacarose ( $\text{t ha}^{-1}$ ) quando usado o índice de colheita ajustado sob influência de estresses hídricos e térmicos (a) e índice de colheita médio (b).

Mesmo com as saídas diretas do modelo AquaCrop apresentando poucas diferenças nos valores de  $Y_f$ s quando usado índice de colheita médio ou ajustado a variabilidade sazonal do TRS só pode ser demonstrada quando usados os índices de colheita ajustados sob efeitos dos estresses hídricos e térmicos.

Na comparação dos índices de colheita observados com os ajustados pelo modelo mesmo com algumas diferenças é possível verificar que a variabilidade nos índices de colheita foi representada (Figura 12). O desvio padrão dos erros absolutos médios entre  $HI_{obs}$  e  $HI_{adj}$  foram de 0.0056 na calibração e 0.0065 na validação.



**Figura 12.** Variabilidade do índice de colheita observado e simulado na calibração (a) e validação (b).  $HI_{obs}$  é o índice de colheita observado,  $HI_{adj}$  é o índice de colheita ajustado e  $HI_{avg}$  é o índice de colheita médio.

## 4.4. DISCUSSÃO

### 4.4.1. Efeitos estresse hídrico e térmico no acúmulo de sacarose

Existem diversos trabalhos que usam o modelo AquaCrop para identificar os efeitos dos estresses do ambiente no desenvolvimento e produção de cultivos agrícolas. A grande maioria com foco nos estresses hídricos e uso de sistemas irrigados (Emdad et al., 2018; Kumar et al., 2018; Tsakmakis et al., 2019; Xu et al., 2019). A produtividade de água (*water productivity, WP*) também é um parâmetro estudado nos trabalhos com o modelo (Vanuytrecht et al., 2014; Jin et al., 2018; Adeboye et al., 2019), mas não foram encontrados trabalhos que propõem mudanças nos cálculos do modelo para melhorar as simulações de um cultivo específico.

No caso deste estudo o cultivo específico é a cana-de-açúcar, em especial, buscando melhorias nos cálculos para simulação do teor de sacarose pelo índice industrial TRS. O processo de acúmulo de sacarose está ligado diretamente com a fase de maturação da cana. Fisiologicamente se resume a maturidade da cana-de-açúcar como o estágio de máximo acúmulo de sacarose

Os fatores que favorecem maior acúmulo de sacarose são as baixas temperaturas e disponibilidade hídrica reduzida (Inman-Barber e Smith, 2005; Cardozo e Sentelhas, 2013; Araújo et al., 2016). Em resumo, quando a planta é submetida a efeitos adversos, aumenta o acúmulo de sacarose nos colmos, podendo ser uma fonte de energia para a própria planta (Toppa et al., 2010).

Menor montante de água disponível durante a maturação levam a atuação dos mecanismos de tolerância que permitem a manutenção do crescimento e andamento do ciclo (Ferreira et al., 2017). Os mecanismos de tolerância também atuam no controle da influência térmica e condutância estomática, sustentando a taxa fotossintética.

De acordo com Scarpari e Beuclair (2009) não existe concordância entre as relações térmicas e o cultivo da cana-de-açúcar, já que os valores propostos variam entre localidade, cultivar e fase fenológica. Cardozo (2012) encontrou variações de até 2°C nas temperaturas bases do cultivo considerando oito cultivares de cana. O método proposto contorna este problema, deixando espaço para o usuário definir a temperatura base a ser usada (parâmetro não-

conservativo), auxiliando no ajuste da intensidade do efeito das baixas temperaturas na maturação.

Em relação a disponibilidade hídrica, Cardozo e Sentelhas (2013) definem que o estresse hídrico moderado é um dos principais indutores da maturação, e associado as temperaturas mais frias reforçam o acúmulo de sacarose nos colmos promovendo a partição do carbono à sacarose armazenada (Uehara et al., 2009).

A disponibilidade hídrica também apresenta função importante na fase de crescimento e alongação dos colmos, sendo que a fase mais longa do ciclo da cana exige altas temperaturas e água abundante. Estresse severo prolongado reduz a taxa de transpiração, consequentemente também leva a menor acúmulo de biomassa (Inmam-Bamber et al., 2016).

Os estresses durante o perfilhamento e alongação dos colmos têm relação direta com o acúmulo de sacarose, afetando os tecidos imaturos e levando ao desenvolvimento inadequado que resulta em menor área de reserva, prejudicando severamente o processo de armazenamento de sacarose (Machado et al., 2009; Souza et al., 2015).

Ferreira et al., (2017) em revisão sobre relações hídricas da cana de açúcar, concluem que há necessidade de mais estudos para melhor entender o mecanismo. Neste trabalho foram considerados os efeitos de estresses hídricos e térmicos influentes no acúmulo de sacarose apenas durante a maturação da cana. Próximos estudos devem ser direcionados para a inserção da relação dos estresses hídricos nas as fases iniciais do ciclo e o teor de sacarose no colmo.

#### **4.4.2. Desempenho das simulações do acúmulo de sacarose**

Os métodos para estimação do teor de sacarose desenvolvidos neste trabalho vão de encontro com a necessidade do setor em estimar a sacarose em termos mais usuais. São diversos os trabalhos com estimação de sacarose em t ha<sup>-1</sup> e que apresentam erros baixos. Neste trabalho, o objetivo foi a estimação de TRS, mas com finalidade de comparação os erros para calibração e validação da estimação do teor de sacarose (Yfs) em termos de Es foram de 1.86 t ha<sup>-1</sup> e 2.15 t ha<sup>-1</sup>, respectivamente.

As repostas do modelo AquaCrop com adição dos estresses hídricos e térmicos na simulação do teor de sacarose foram satisfatórias com resultados mais acurados do que os demais modelos mais conhecidos para o cultivo da cana, como o DSSAT-Canegro (RMSE = 2.6 t ha<sup>-1</sup>), o APSIM-Sugarcane (3.3 t ha<sup>-1</sup>) e o QCANE (2.5 t ha<sup>-1</sup>) (O'Leary, 2000; Singles e Benzuidenhout, 2002).

Dentre os problemas para modelagem do teor de sacarose, autores ressaltam que o DSSAT-Canegro requer muitos parâmetros e a maioria deles são complicados de usar na prática (Zhao et al., 2018). Para o modelo APSIM a maior limitação está na inabilidade do modelo em representar os efeitos do estresse hídrico (Keating et al., 1999). O modelo QCANE é mais simples e usa uma abordagem empírica, porém faz as simulações de açúcares redutores e não do teor de sacarose diretamente (Liu e Bull, 2001).

Estes modelos de cultivos para cana-de-açúcar apresentam pontos em comum quando se trata de simulações para o teor de sacarose: há a necessidade de melhorar o entendimento (i) dos efeitos dos estresses hídricos e térmicos na formação e armazenamento de sacarose, (ii) das respostas de diferentes cultivares aos estresses e (iii) das diferenças na eficiência da transpiração e uso da radiação pelas canas-planta e canas-soca (O'Leary, 2000). Além da falta de dados ambientais e agrícolas observados acurados (Zhao et al., 2018).

Algumas novas alternativas vêm sendo desenvolvidas para superar estas dificuldades na modelagem do teor de sacarose. Jones e Singels (2018) propuseram melhorias nas simulações do modelo DSSAT-CaneGro em relação aos efeitos de altas temperaturas e da [CO<sub>2</sub>] atmosférico e obtiveram resultados acurados para a estimacão de sacarose (RMSE=3.3 t ha<sup>-1</sup>).

Também para o modelo DSSAT-CaneGro, Zhao et al., (2018) sugerem um método novo para estimacões de sacarose que usa o índice de area foliar calculado por NDVI. A técnica promete minimizar custos para obtenção de dados observados e atingiu acurácia de 80.9% nas previsões de máxima concentração de sacarose no ciclo da cana-de-açúcar em Araras, estado de São Paulo.

Para o modelo QCANE, Zu et al., (2018) usaram a técnica de estimar as diferenças no rendimento da cana de açúcar para depois determinar o teor de

sacarose. Devido ao número reduzido de safras para análise os autores conseguiram calibrar o modelo para região de Guangxi, China; porém indicam o uso de mais dados para melhor validação do método.

Em relação a estimacões de TRS, existem poucos trabalhos. Scarpari e Beuclair (2004) e Marcari et al., (2015) usaram análises empíricas para correlacionar elementos meteorológicos com o TRS da cana de açúcar. Os resultados foram satisfatórios com precisão mínima ( $R^2$ ) de 0,27 e 0,66, respectivamente.

No que diz respeito ao modelo AquaCrop são poucos os trabalhos publicados que fazem estimacões do teor de sacarose. Bello et al., (2013) ressaltaram que o modelo AquaCrop é uma boa ferramenta para estimar a biomassa da cana, porém necessita da adição de estimacões de sacarose, já que esta é determinante para o sucesso do canavial.

Bahmani e Eghbalian (2018) demonstraram uma tentativa de usar o modelo AquaCrop na estimacão de sacarose. Os autores criaram diferentes cenários para o uso de irrigação na região de Khuzestan, no Irã, e obtiveram resultados aceitáveis com RMSE médio de 1.70 t ha<sup>-1</sup>. É importante ressaltar que no trabalho de Bahmani e Eghbalian (2018) o teor de sacarose é definido apenas como uma porcentagem da biomassa, não sendo considerados estresses ambientais nos cálculos do modelo para produtividade (*Yield*).

Neste estudo foram associadas as necessidades do setor canavieiro tanto quanto as necessidades de melhoria na modelagem do teor de sacarose para cana-de-açúcar. Como o método foi desenvolvido seguindo a metodologia de do modelo AquaCrop, a melhoria se encaixa na filosofia de simplicidade do modelo, com parâmetros explícitos e intuitivos (Steduto et al., 2009).

Foram usadas técnicas novas e já conhecidas para melhorar e tornar mais reais as simulações do modelo AquaCrop, garantindo uma resposta mais prática com teor de sacarose já representado diretamente pelo TRS, índice onde produtores e indústrias do setor baseiam os preços pela produção da cana.

A adição de estresse térmico afetando o índice de colheita do modelo AquaCrop é inovadora sendo uma ferramenta para auxiliar em futuros estudos

das relações entre a planta de cana e as variações na temperatura do ar. Recomenda-se a adição da nova metodologia para estimação do teor de sacarose, nos cálculos do modelo AquaCrop, não apenas para cana-de-açúcar, como para teste em outros cultivos energéticos.

#### **4.5. CONCLUSÕES**

Neste estudo foi proposto um novo método para o cálculo do índice de colheita no modelo AquaCrop. A metodologia adiciona a influência das variações na temperatura do ar e da disponibilidade hídrica, definindo intensidade e efeito dos estresses durante o período de formação da produção (*yield formation*).

O uso do modelo AquaCrop associado ao novo método pode contribuir para próximos estudos e melhor entendimento das relações hídricas e térmicas da planta de cana de açúcar e o ambiente.

A adição do método ao modelo AquaCrop apresentou potencial e foi acurado nas estimações de ATR da cana de açúcar em regiões produtoras do estado de São Paulo, contribuindo para a usabilidade do modelo, que vai em concordância com os termos práticos de expressão de qualidade da cana de açúcar.

A precisão na validação foi ligeiramente baixa ( $R^2 = 0.42$ ), mesmo com a calibração precisa ( $R^2 = 0.70$ ). Há necessidade de mais dados para melhorar a precisão dos resultados. No entanto, em relação a acurácia geral as etapas de calibração e validação se mostraram eficazes, com erro percentual absoluto médio menor que 5% ( $\pm 4 \text{ kg ton}^{-1} \text{ ha}^{-1}$ ) e raiz do erro quadrático médio menor que 10%.

#### **AGRADECIMENTOS**

Agradecemos a Fundação de Coordenação e Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento deste projeto e o apoio do departamento de Ciências Ambientais e do Solo da Universidade de Leuven, em especial a colaboração da Dra. Eline Vanuytrecht e Dr. Dirk Raes no desenvolvimento deste trabalho.

#### 4.6. REFERÊNCIAS

Adeboye, O. B. et al. Performance evaluation of AquaCrop in simulating soil water storage, yield, and water productivity of rainfed soybeans (*Glycine max* L. merr) in Ile-Ife, Nigeria. *Agricultural Water Management*, 213(1):1130-1146, 2019.

Allen, R.G., L.S.Pereira, D. Raes, and M. Smith. Crop evapotranspiration: guidelines for computing crop water requirements Food and Agriculture Organization of the United Nations, Rome, 1998.

Araújo, R. et al., Variation in the sugar yield in response to drying-off of sugarcane before harvest and the occurrence of low air temperatures. *Bragantia*, Campinas v. 75, n. 1, p.118-127, 2016.

Bahmani, O., Eghbalian, S. Simulating the Response of Sugarcane Production to Water Deficit Irrigation Using the AquaCrop Model. *Agric Res*, 7(2):158–166. 2018, <https://doi.org/10.1007/s40003-018-0311-0>.

Bello, CAC 2013. Uso del modelo Aquacrop para estimar rendimientos para el cultivo de caña de azúcar en el departamento del valle del Cauca. Report of Proyecto de Cooperación técnica TCP/COL/3302. FAO & Ministerio de Agricultura y Desarrollo Rural de Colombia. 66p. ISBN I3427S/1/08.13.

Cardozo, N.P. e Sentelhas, P.C. Climatic effects on sugarcane ripening under the influence of cultivars and crop age. *Sci. Agric.* v.70, n.6, p.449-456, 2013.

Cardozo, N.P. et al. Modeling sugarcane ripening as a function of accumulated rainfall in Southern Brazil. *Int J Biometeorol*, 2015.

Cardozo, N.P. Modelagem da maturação da cana-de-açúcar em função de variáveis meteorológicas. (DISSERTAÇÃO). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2012.

Castro, O. M., Viera, S. R., Siqueira, G. M., Andrade, C.A. Physical and chemical attributes of a rhodic hapludox under different tillage systems. *Bragantia*, Campinas, v.68, n.4, p. 1047-1057, 2009.

Costa, C. T. S.; Ferreira, V. M.; Endres, L.; Ferreira, D. T. R. G.; Gonçalves, E. R. Crescimento e produtividade de quatro variedades de cana-de-açúcar no quarto ciclo de cultivo. *Revista Caatinga*, Mossoró, v. 24, n. 3, p. 56-63, 2011.

Dantas Neto, J.; Figueredo, J. L. da C.; Farias, C. H. de A.; Azevedo, H. M. de; Azevedo, C. A. V. de. Resposta da cana-de-açúcar, na primeira soca, a níveis de irrigação e adubação de cobertura. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.10, p.283-288, 2006.

Emdad, M.R., Tafteh, A., Ghalebi, S. Validation of AquaCrop model for simulating wheat yield in different irrigation events, *Journal of Water and Soil*, 32(3):463-473, 2018.

FAO, AquaCrop reference manual for version v.6: Chapter3. Calculation Procedures, by Dirk Raes, Pasquale Steduto, Theodore C. Hsiao, and Elias Ferres with the contribution of the AquaCrop Network, Rome, 2017.

Fernandes, A.C. *Cálculos na agroindústria da cana-de-açúcar*. Piracicaba: STAB - Açúcar, Álcool e Subprodutos, 193 p. 2000.

Ferreira, T. H. S., Tsunada, M. S., Bassi, D., Araújo, P., Matiello, L., Guidelli, G. V., Righetto, G. L., Gonçalves, V. R., Lakshmanan, P., Menossi, M. Sugarcane Water Stress Tolerance Mechanisms and Its Implications on Developing Biotechnology Solutions. *Frontiers in Plant Science*. v. 8, n. 1077. doi: 10.3389/fpls.2017.01077, 2017.

Hay, R.K.M. Harvest index: a review of its use in plant breeding and crop physiology, *Annals of Applied Biology*, 126(1):197-216, 1995.

IAC, Instituto Agronômico de Campinas, 2017. <http://www.iac.sp.gov.br/>

Inman-Bamber, N., Smith, D. Water relations in sugarcane and response to water deficits. *Field Crops Res.* 92, 185–202, 2005. doi: 10.1016/j.fcr.2005.01.023

Inman-Bamber, N.G. et al. Sugarcane for water-limited environments: Enhanced capability of the APSIM sugarcane model for assessing traits for transpiration efficiency and root water supply, *Field Crops Research*, 196(1):112-123, 2016.

Jin, X., Yang, G., Li, Z. et al. Estimation of water productivity in winter wheat using the AquaCrop model with field hyperspectral data. *Precision Agric*, 19:1, <https://doi.org/10.1007/s11119-016-9469-2>. 2018.

Jones, M. R. e Singels, A. Refining the Canegro model for improved simulation of climate change impacts on sugarcane, *European Journal of Agronomy*, 100(1):76-86, 2018.

Keating, B.A., Robertson, M.J., Muchow, R.C., Huth, N.I. Modelling sugarcane production systems. 1. Development and performance of the sugarcane module. *Field Crops Res.*, 61, pp. 253-271, 1999.

Kumar, V., Chandra, R., Jain, S.K. Performance Evaluation of AquaCrop Model for Rabi Maize Crop in the North Bihar Condition. *Journal of Pharmacognosy and Phytochemistry*, 7(5): 973-979, 2018.

Liu, D.L. e Bull, T.A. Simulation of biomass and sugar accumulation in sugarcane using a process-based model. *Ecological Modelling*, 144(2-3):181-211, 2001.

Machado, R. S., et al. Respostas biométricas e fisiológicas ao déficit hídrico em cana-de-açúcar em diferentes fases fenológicas. *Pesquisa Agropecuária Brasileira*, Brasília, v.44, n.12, p. 1575-1582, 2009.

Marcari, M.A., Rolim, G.S., Aparecido, L.E.O. Agrometeorological models for forecasting yield and quality of sugarcane, *Australian Journal of Crop Science*, 9(11):1049-1056, 2015.

Montanari, R., Marques Junior, J., Campos, M. C. C., Souza, Z. M., Camargo, L. A. Mineralogical characterization of Oxisol in different relief form in the region of Jaboticabal, SP, *Rev. Ciênc. Agron.*, v. 41, n. 2, p. 191-199, 2010.

Muluneh et al., Adapting to climate change for food security in the Rift Valley dry lands of Ethiopia: supplemental irrigation, plant density and sowing date. *The Journal of Agricultural Science*, 155(5):703-724, 2017.

O'Leary, G.J. A review of three sugarcane simulation models with respect to their prediction of sucrose yield, *Field Crops Research*, 68(1), 97-111, 2000.

Pagani V. et al. Forecasting sugarcane yields using agro-climatic indicators and Canegro model: A case study in the main production region in Brazil. *Agricultural Systems*, 154, 45-52, 2017.

Pereira, L.F.M. et al. Sugars levels of four sugarcane genotypes in different stem portions during the maturation phase. *Annals of the Brazilian Academy of Sciences*, 89(2):1231-1242, 2017.

Raes, D., Steduto, P., Hsiao, T.C., Fereres, E., 2009. AquaCrop-the FAO crop model to simulate yield response to water: ii. Main algorithms and software description. *Agronomy Journal* 101, 438–447. <https://doi.org/10.2134/agronj2008.0140s>.

Saxton, K.E., Rawls, W.J. Soil water characteristic estimates by texture and organic matter for hydrologic solutions. *Soil Science Society America Journal* 1569–1578, 2006.

Saxton, K.E., Willey, P.H., The SPAW model for agricultural field and pond hydrologic simulation. In: Singh, V.P. & Frevert, D.K., eds. *Watershed models*. Boca Raton, CRC Press, p.401-435, 2009.

Scarpari, M.S. e Beauclair, E.G.F. Sugarcane maturity estimation through edaphic-climatic parameters. *Sci. Agric. (Piracicaba, Braz.)*, v.61, n.5, p.486-491, 2004.

Scarpari, M.S. e Beauclair, E.G.F. Physiological model to estimate the maturity of sugarcane, *Sci. Agric. (Piracicaba, Braz.)*, v.66, n.5, p.622-628, 2009.

Scarpari, M.S. Modelos para previsão da produtividade de cana-de-açúcar (*Sacharum spp.*) através de parâmetros climáticos. (TESE), Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2002.

Schoffel, E.R. e Volpe, C.A. Relação entre a soma térmica efetiva e o crescimento da soja. *Revista Brasileira de Agrometeorologia*, Santa Maria, v. 10, n. 1, p. 89-96, 2002.

Shrivastava, A.K., Solomon, S., Rai, R.K. et al. Physiological Interventions for Enhancing Sugarcane and Sugar Productivity. *Sugar Tech*, 17:215, 2015. <https://doi.org/10.1007/s12355-014-0321-6>

Silva, R.F.S. e Segato, S.V. Importance of the use of maturity, plant in the culture of sugarcane. *Nucleus*, 8(2), 2011.

Singels, A. e Benzuidenhout, C.N. A new method of simulating dry matter partitioning in the Canegro sugarcane model, *Field Crops Research*, 78(2-3):151-164, 2002.

Souza, J.L. et al. Adjustment of water-crop production models for ratoon sugarcane. *Pesq. Agropec. Trop.*, Goiânia, v. 45, n. 4, p. 426-433, 2015.

Steduto, P., Hsiao, T.C., Fereres, E. AquaCrop-the FAO crop model to simulate yield response to water: I. Concepts and underlying principles. *Agronomy Journal*, 101(3), 426-437, 2009.

Toppa, E.V.B. et al. Physiology aspects of sugarcane production. *Pesqui Apl Agrotec* 3:223-230, 2010.

Tsakmakis, I.D. et al. Evaluation of AquaCrop model simulations of cotton growth under deficit irrigation with an emphasis on root growth and water extraction patterns, *Agricultura Water Management*, 213(1):419-432, 2019.

Uehara N., Sasaki, H., Aoki, N., Ohsugi, R. Effects of the Temperature Lowered in the Daytime and Night-time on Sugar Accumulation in Sugarcane, *Plant Production Science*, 12(4):420-427, DOI: 10.1626/pps.12.420, 2009.

Vanuytrecht, E., Raes, D., Steduto, P., Hsiao, T.C., Fereres, E., Heng, L.K., Garcia Vila, M., Mejias Moreno, P. AquaCrop: FAO'S crop water productivity and yield response model. *Environmental Modelling & Software* 62, 351–360. <https://doi.org/10.1016/j.envsoft.2014.08.005>, 2014.

Verma, I. et al. Expression analysis of genes associated with sucrose accumulation and its effect on source–sink relationship in high sucrose accumulating early maturing sugarcane variety, *Physiol Mol Biol Plants*, 25(1):207–220, 2019.

Watt, D. A., McCormick, A. J., & Cramer, M. D. Source and sink physiology. In P. H. Moore, & F. C. Botha (Eds.), *Sugarcane: physiology, biochemistry and functional biology* (p. 483-520). Oxford: Willey Blackwell. 2014.

Xu, J., et al. Modeling rice development and field water balance using AquaCrop model under drying-wetting cycle condition in eastern China, *Agricultura Water Management*, 213(1):289-297, 2019.

Zhao, Y., et al. Multivariety sugarcane sucrose estimation using a combination of spectral and agrotechnology methods. *Proc. SPIE 10783, Remote Sensing for Agriculture, Ecosystems, and Hydrology XX*, 107830L. doi: 10.1117/12.2326705, 2018.

Zu, Q., et al. Spatio-temporal distribution of sugarcane potential yields and yield gaps in Southern China. *European Journal of Agronomy*, 92(1):72-83, 2018.