



UNIVERSIDAD AUTÓNOMA CHAPINGO

POSGRADO EN INGENIERIA AGRICOLA Y USO INTEGRAL DEL AGUA

**MODELACIÓN DINÁMICA DEL CRECIMIENTO Y DESARROLLO
DE FRIJOL (*Phaseolus vulgaris* L.) CON DIFERENTES NIVELES
DE AGUA EN EL SUELO**

TESIS

**Que como requisito parcial
para obtener el grado de:**

DOCTOR EN INGENIERIA


Presenta:

MIGUEL SERVIN PALESTINA

Bajo la supervisión de: IRINEO LORENZO LOPEZ CRUZ, PhD



APROBADA




Chapingo, Estado de México, agosto de 2022

**MODELACIÓN DINÁMICA DE CRECIMIENTO Y DESARROLLO
DE FRIJOL (*Phaseolus vulgaris* L.) CON DIFERENTES NIVELES
DE AGUA EN EL SUELO**


Tesis realizada por **MIGUEL SERVÍN PALESTINA** bajo la supervisión del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

DOCTOR EN INGENIERÍA

DIRECTOR:


Irineo Lorenzo López Cruz, PhD.

ASESOR:


Dr. Agustín Ruiz García

ASESOR:


Raquel Salazar Moreno, PhD

CONTENIDO

LISTA DE CUADROS	vi
LISTA DE FIGURAS	vii
LISTA DE APÉNDICES	xi
ABREVIATURAS USADAS	xii
DEDICATORIAS	xiii
AGRADECIMIENTOS	xiv
DATOS BIOGRÁFICOS	xv
.....	xv
RESUMEN GENERAL	xvi
ABSTRACT	xvii
I. INTRODUCCIÓN GENERAL	1
1.1 Objetivo general	3
1.2 Objetivos particulares	3
1.3. Justificación	4
1.4 Estructura de la tesis	4
II. MODELOS PARA CRECIMIENTO Y DESARROLLO PARA EL CULTIVO DEL FRIJOL (<i>Phaseolus vulgaris</i> L.): ESTADO DEL ARTE	6
2.1 Resumen	6
2.2. Abstract	7
2.3. Introducción	8
2.4. Modelos dinámicos utilizados para crecimiento frijol	12
2.4.1. BEANGRO	12
2.4.2. CROPGRO	14
2.4.3. WOFOST	19
2.4.4. DIACROS	20
2.4.5. SSM-Legumes	21
2.4.6. SODCOM	23
2.4.7. Cereal-Legumes	24
2.4.8. El modelo SIMPLE	24
2.5. Modelos basados en transpiración	25
2.5.1. El modelo SALTMED	25
2.5.2. AQUACROP	26
2.5. Conclusiones	30
2.6. Literatura citada	30
III.- ANÁLISIS DE INCERTIDUMBRE Y SENSIBILIDAD ESPACIOTEMPORAL DEL MODELO PARA CRECIMIENTO DE CULTIVOS SIMPLE APLICADO AL CULTIVO DE FRIJOL	36

3.1.- Resumen	36
3.2.- Introducción	37
3.3.- Materiales y Métodos	39
3.3.1.- Colección de datos	39
3.3.1.1.- Calendario de riego	40
3.3.2.- Modelo de crecimiento de cultivos SIMPLE	41
3.3.2.1.- Tiempo térmico	42
3.3.2.2.- Biomasa	42
3.3.3 Análisis de incertidumbre (UA)	43
3.3.6.- Análisis de sensibilidad global	44
3.4.- Resultados	47
3.4.1.- Condiciones climáticas	47
3.4.2.- Análisis de incertidumbre	48
3.4.3.- Análisis de sensibilidad	50
3.5.- Discusión	54
3.5.1.- Condiciones climáticas	54
3.5.2.- Análisis de incertidumbre	54
3.5.3 Análisis de sensibilidad	56
3.6.- Conclusiones	58
3.7.-Literatura Citada	58
IV.- ANÁLISIS DE INCERTIDUMBRE GLUE DEL MODELO DE CULTIVOS SIMPLE APLICADO A UN CULTIVO DE FRIJOL (<i>Phaseolus vulgaris</i> L.)	63
4.1.-Resumen	63
4.2.- Introducción	64
4.3.- Materiales y métodos	65
4.3.1.- Descripción del área de estudio	65
4.3.1.1.- Datos climáticos	66
4.3.1.2.- Establecimiento del experimento	66
4.3.2. Descripción del modelo para crecimiento de cultivos SIMPLE	67
4.3.3. Procedimiento Estimación de la Incertidumbre de Verosimilitud Generalizada (GLUE).	69
4.3.4.- Calibración del modelo SIMPLE	72
4.4.- Resultados y discusión	73
4.4.1.- Datos de clima	73
4.4.2.- Incertidumbres sin calibración	74
4.4.3. Resultados de la calibración del modelo SIMPLE	81
4.4.4.- Análisis de incertidumbre con calibración	82
4.5.- Conclusiones	87
4.6.- Referencias	88
V.- CALIBRACIÓN Y EVALUACIÓN DEL MODELO DE CULTIVO SIMPLE PARA FRIJOL (<i>Phaseolus vulgaris</i> L.) BAJO DIFERENTES NIVELES DE RIEGO	92
5.1.-Resumen	92
5.2.- Introducción	93

5.3.- Materiales y métodos	96
5.3.1.-Descripción del área de estudio.....	96
5.3.2-. Material genético y manejo del cultivo	97
5.3.3. Tratamientos de riego y diseño experimental	97
5.3.4. Información climática	98
5.3.5. Descripción del modelo SIMPLE.....	98
5.3.6. Calibración del modelo.....	100
5.3.6.1. Algoritmos de evolución diferencial	101
5.3.6.2. Función objetivo.....	102
5.3.7. Evaluación del modelo	102
5.3.8. Medidas para el grado de ajuste	102
5.4.- Resultados	103
5.4.1.-Clima y calendario de riego	103
5.4.2. Curva de acumulación de biomasa.....	105
5.4.3. Calibración y Evaluación.....	106
5.4.4. Índice de cosecha	111
5.5.- Discusión	113
5.5.1. Clima y calendario de riego.....	113
5.5.2. Curva de acumulación de biomasa.....	114
5.5.3. Parámetros calibrados	115
5.5.4. Calibración y evaluación	116
5.5.5. Índice de cosecha	117
5.6.- Conclusiones	117
5.6.- Referencias bibliográficas	118
VI. CONCLUSIONES GENERALES	124
VII. LITERATURA CITADA	126
VIII. APÉNDICES	128
8.1. Descripción de modelo SIMPLE	128

LISTA DE CUADROS

Tabla 3.1. Valores nominales de los de los parámetros utilizados en el modelo SIMPLE para el cultivo de frijol variedad Pinto Saltillo.....	46
Tabla 4.1. Valores nominales y límites de exploración de los parámetros para cada escenario, utilizados en el modelo SIMPLE para el cultivo de frijol variedad Pinto Saltillo.....	70
Tabla 4.2. Vector de parámetros que minimiza el RMSE en cada uno del escenario con el modelo SIMPLE en frijol establecido en Zacatecas, México...	78
Table 4.3. Parameter values after the differential evolution (DE) calibration process and goodness of fit statistics of the SIMPLE model for bean in Zacatecas, Mexico.....	82
Tabla 4.4. Vector de parámetros que minimiza el RMSE en cada uno del escenario con el modelo SIMPLE en frijol establecido en Zacatecas, México...	85
Tabla 5.1. Parámetros del modelo SIMPLE con sus valores nominales y límites de exploración usado para GSA y calibración en frijol ‘Pinto Saltillo’	101
Tabla 5.2. Riego y productividad de frijol con diferentes niveles de agua en el suelo en Zacatecas, México.....	105
Tabla 5.3. Producción promedio ($\pm$ desviación estándar) de biomasa de frijol CV ‘Pinto Saltillo’ en Zacatecas, México del ciclo 2020, usados para la calibración.	106
Tabla 5.4. Producción promedio ($\pm$ desviación estándar) de biomasa de frijol cv ‘Pinto Saltillo’ en Zacatecas, México del ciclo 2021, usados para la evaluación.	106
Tabla 5.5. Vector de parámetros, resultado de la calibración del modelo SIMPLE con el algoritmo de Evolución Diferencial.....	107
Tabla 5.6. Estadísticos de evaluación del modelo SIMPLE para la simulación de biomasa de frijol sometido a diferentes niveles de humedad.	108 108
Tabla 5.7. Rendimiento de grano de frijol cv ‘Pinto Saltillo’ simulado y observado	113
Tabla 8.1. Ecuaciones auxiliares del modelo SIMPLE	130

LISTA DE FIGURAS

Figura 1.1. Procedimiento de modelación dinámica de sistemas. Adaptado de (Ljung y Glad, 1994; Haefner, 2005; Voinov, 2008; Bala et al., 2017)	3
Figura 2.1. Línea del tiempo de la modelación dinámica de crecimiento y desarrollo de frijol.....	11
Figura 2.2. Estructura e interfaz de usuario de modelo BEANGRO (Hoogenboom et al, 1994).....	12
Figura 2.3. Diagrama del modelo CROPGRO (Zamora et al., 2009)	15
Figura 2.4. Diagrama relacional modelo WOFOST	20
Figura 2.5. Diagrama modelo DAICROS	21
Figura 2.6. Diagrama SODCOM	23
Figura 2.7. Diagrama Aquacrop	27
Figura 3.1. Diagrama del modelo de crecimientos de cultivos SIMPLE, las variables de estado se representan por rectángulos, las tasas de cambio por válvulas, los parámetros con una línea horizontal y un círculo con relleno negro, las variables de entrada un círculo y una línea horizontal y las variables auxiliares con circunferencias. Los flujos de material se representan mediante flechas normales y los flujos de información con líneas discontinuas	42
Figura 3.2. Condiciones climáticas de las cuatro estaciones para los años 2005, 2010, 2015, 2020,	48
Figura 3.3. Promedios ($\pm$ desviación estándar) de las variables de salida, tiempo térmico (A), biomasa (B)y rendimiento (C) del frijol bajo riego o seco para el modelo SIMPLE en ensayos entre estaciones climáticas y entre años en Zacatecas, México.	49
Figura 3.4. Curtosis (barras) y asimetría (líneas) de las variables de salida A) tiempo térmico, B) biomasa y C) rendimiento del modelo SIMPLE en ensayos entre estaciones climáticas y entre años producción de frijol en Zacatecas, México.	50
Figura 3.5. Índices de sensibilidad de primer orden ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en riego para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.	51

Figura 3.6. Índices de sensibilidad de efecto total ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en riego para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.	52
Figura 3.7. Índices de sensibilidad de primer orden ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en secano para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.	53
Figura 3.8. Índices de sensibilidad de efecto total ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en riego para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.	54
Figura 4.1. Diagrama relacional de Forrester del modelo SIMPLE, Estados (rectángulos), tasas de cambio (válvulas), parámetros (línea horizontal y círculo con relleno negro) entrada (línea horizontal y círculo). Los flujos de material se representan mediante flechas normales y los flujos de información con líneas discontinuas.	67
Figure 4.2. Variables climáticas recolectadas durante la estación de crecimiento con medias históricas (17 años) de la estación CEZAC-INIFAP *quincenal.....	74
Figure 4.3. Irrigation water applied (mm) during the growing season.....	74
Figura 4.4. Histograma de RMSE de los valores de biomasa observados y simulados por el modelo SIMPLE para los tres escenarios: a) escenarios U10 b) escenario U20 c) escenario U20N	75
Figura 4.5. Intervalos de confianza con GLUE del modelo SIMPLE con datos observado de frijol en Zacatecas para los tres escenarios. A) U10, B) U20 y C) U20N.....	77
Figura 4.6. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U10, los puntos negros representan el 10% de los valores más bajos.....	79
Figura 4.7. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U20, los puntos negros representan el 10% de los valores más bajos.....	80

Figura 4.8. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U25N, los puntos negros representan el 10% de los valores más bajos.	81
Figura 4.9. Histograma de RMSE de los valores de biomasa observados y simulados por el modelo SIMPLE usando parámetros calibrados, para los tres escenarios: a) escenarios U10 b) escenario U20 c) escenario U25N.....	83
Figura 4.10. Intervalos de confianza con GLUE del modelo calibrado SIMPLE con datos observado de frijol en Zacatecas para los tres escenarios. A) U10, B) U20 y C) U20N.....	84
Figura 4.11. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U10 con el modelo calibrado, los puntos negros representan el 10% de los valores más bajos (RSA).....	86
Figura 4.12. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U20 con el modelo calibrado, los puntos negros representan el 10% de los valores más bajos (RSA).....	86
Figura 4.13.- Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U25N con el modelo calibrado, los puntos negros representan el 10% de los valores más bajos (RSA).	87
Figura 5.1. Diagrama del modelo de crecimientos de cultivos SIMPLE, las variables de estado se representan por rectángulos, las tasas de cambio por válvulas, los parámetros con una línea horizontal y un círculo con relleno negro, las variables de entrada un círculo y una línea horizontal y las variables auxiliares con circunferencias. Los flujos de material se representan mediante flechas normales y los flujos de información con líneas discontinuas	100
Figure 5.2. Variables climáticas recolectadas durante la estación de crecimiento y media histórica de la estación CEZAC INIFAP-Zacatecas. *medias quincenales	104

Figura 5.3. Biomasa observada vs simulada para los cuatro tratamientos de riego. Calibración (datos 2020) y Evaluación (datos 2021).....	109
Figura 5.4. Calibración (a) y evaluación (b) de la biomasa observada y simulada - En cada punto, las barras verticales indican la desviación estándar (n = conjunto de datos).....	110
Figura 8.1. Diagrama conceptual del modelo simple	128

LISTA DE APÉNDICES

8.1. Descripción de modelo SIMPLE.....	128
--	-----

ABREVIATURAS USADAS

Abreviatura	Descripción	Unidades
Tsum	Temperatura acumulada de siembra a madurez	°C día
HI	Índice de cosecha	--
I50A	Temperatura acumulada requerida para el desarrollo del área foliar para interceptar el 50% de la radiación	°C día
I50B	Temperatura acumulativa hasta la madurez para alcanzar el 50% de intercepción de radiación debido a la senescencia de la hoja	°C día
Tb	Temperatura base para el desarrollo y fenología	°C
Topt	Temperatura óptima para el crecimiento de la biomasa	°C
RUE	Eficiencia de uso de radiación	g MJ ⁻¹ m ⁻²
I50maxH	Reducción diaria máxima en I _{50B} debido al estrés por calor	°C día
I50maxW	Reducción diaria máxima en I _{50B} debido al estrés por sequía	°C día
Tmax	Temperatura umbral para comenzar a acelerar la senescencia del estrés por calor	°C
Text	Umbral de temperatura extrema cuando RUE se convierte en 0 debido al estrés por calor	°C
Sco2	Aumento relativo de RUE por ppm de CO ₂ después de 350 ppm.	ppm
Swater	Sensibilidad de RUE al estrés por sequía	--
Bio	Biomasa seca o materia seca	t ha ⁻¹
TT	Tiempo térmico	°C día ⁻¹
Y	Rendimiento de grano	T ha ⁻¹
Tmin	Temperatura mínima	°C
Tmax	Temperatura máxima	°C
Rs	Radiación solar	g MJ ⁻¹ m ⁻²
ETo	Evapotranspiración de referencia	mm
P	Precipitación	mm
Bias	Sesgo	
RMSE	Raíz del error cuadrático medio	
MAE	Error medio absoluto	
EF	Eficiencia del modelo	
UA	Análisis de incertidumbre	
SA	Análisis de sensibilidad	

DEDICATORIAS

A mi esposa (Jessi) y mis hijos (Tristán, Saraí y Said) por su apoyo y comprensión

AGRADECIMIENTOS

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico otorgado para obtener este grado académico.

A la Universidad Autónoma Chapingo y al Posgrado en Ingeniería Agrícola y Uso Integral del Agua por todos los conocimientos que me brindaron para mi formación profesional

Al Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP) por el apoyo y facilidades otorgadas para el desarrollo de esta investigación

Al PhD. Irineo López Cruz, por su excelente dirección en la presente investigación, por todo su apoyo brindado durante todo el desarrollo de esta investigación. Toda mi admiración y respeto por su compromiso con la ciencia.

Al PhD. Jorge Zegbe Domínguez, por el apoyo en el establecimiento, toma de datos experimentales y revisión de documentos derivado de esta investigación.

A los integrantes de mi comité asesor:

DATOS BIOGRÁFICOS

Nombre: Miguel Servin Palestina.

Fecha de nacimiento: 7 de diciembre de 1985

Lugar de Nacimiento: Tételes de A. C., Puebla.

CURP: SEPM851207HPLRLG04

Profesión: Ingeniero agrónomo en irrigación

Cedula profesional: 11518670



Desarrollo Académico:

Licenciatura: Universidad autónoma Agraria Antonio Narro unidad laguna

Maestría: Hidrociencias - Colegio de Postgraduados

RESUMEN GENERAL

1

MODELACIÓN DINÁMICA DEL CRECIMIENTO Y DESARROLLO DE FRIJOL (*Phaseolus vulgaris* L.) CON DIFERENTES NIVELES DE AGUA EN EL SUELO

El frijol es la leguminosa más importante para consumo humano por su contenido proteico, vitaminas y minerales. Sin embargo, su producción está en riesgo debido al cambio climático, disminución de los recursos hídricos y un manejo inadecuado del cultivo. Aunque los modelos dinámicos de cultivos son herramientas útiles para gestión y toma de decisiones, los modelos existentes en la literatura científica tienen problemas para simular el desarrollo del cultivo, sobre todo fechas de cambio de las etapas fenológicas. Por esto, los objetivos de este trabajo de investigación fueron simular, identificar las fuentes de incertidumbre, identificar los parámetros más influyentes, calibrar y evaluar el modelo SIMPLE para simulación de biomasa y rendimiento de frijol en Zacatecas, México. En un análisis de sensibilidad espacio temporal de las zonas productoras de frijol se identificaron los parámetros Tsum>Swater>Tb>Topt>I50A, como los más influyentes para simular biomasa y tiempo térmico de frijol. También mediante

un análisis de incertidumbre con el método GLUE se identificó la importancia de utilizar distribución normal en los parámetros Tsum y Swater para evitar sesgo en la selección y calibración de parámetros. Por otro lado, calibrando los parámetros I50A, Topt, Swater, Tb, I50maxW y Tsum con datos observados de cuatro tratamientos de riego, el modelo SIMPLE resultó confiable para predecir la biomasa en su etapa de evaluación. También, se desarrolló un modelo para estimar el índice de cosecha y simular el rendimiento de frijol sometido a diferentes niveles de humedad. En conclusión, el modelo SIMPLE mostró potencial para simular la biomasa de frijol sometido a diferentes condiciones de humedad y puede ser útil como una herramienta de planificación de actividades productivas para el cultivo de frijol. Sin embargo, cuando los cambios de humedad son pequeños, el modelo no tiene la capacidad para expresar estas variaciones en la simulación de la biomasa.

Palabras clave: simulación, análisis de sensibilidad, análisis de incertidumbre, estimación de parámetros, calibración, evaluación del modelo.

¹ Tesis de Doctorado en Ingeniería, Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Miguel Servin Palestina

Director: Irineo L. López Cruz, PhD

ABSTRACT

2

DYNAMIC MODELING OF GROWTH AND DEVELOPMENT OF COMMON BEANS (*Phaseolus vulgaris* L.) WITH DIFFERENT LEVELS OF WATER IN THE SOIL

Common bean is the most important legume for human consumption due to their protein content, vitamins, and minerals. However, its production is at risk due to climate change, decreased water resources and inadequate operation of the crop. Although crop dynamic models are useful tools for management and decision-making, existing models in the scientific literature have limitations in simulating crop development, especially dates of change in phenological stages. Therefore, the objectives of this research work were to simulate, identify the sources of uncertainty, identify the most influential parameters, model calibration and evaluation the SIMPLE model for simulation of biomass and bean yield in Zacatecas, Mexico. From a spatio-temporal sensitivity analysis of bean-producing areas, the parameters $T_{sum} > S_{water} > T_b > T_{opt} > I_{50A}$ turned out to be as the most influential for simulating bean biomass and thermal

time. Also, through an uncertainty analysis with the GLUE method, the importance of using a normal distribution in the T_{sum} and S_{water} parameters was identified to avoid bias in the selection and calibration of parameters. On the other hand, by calibrating the I_{50A} , T_{opt} , S_{water} , T_b , I_{50maxW} and T_{sum} parameters with observed data from four irrigation treatments, the SIMPLE model was reliable for predicting biomass in its evaluation stage. In addition, a model was developed to estimate the harvest index and simulate the yield of beans subjected to different moisture levels. In conclusion, the SIMPLE model showed potential to simulate common bean biomass subjected to different moisture conditions and thus it can be useful as a tool for planning productive activities for bean cultivation. However, when moisture changes are small, the model does not have the ability to express these variations in the biomass simulation.

Keywords: simulation, sensitivity analysis, uncertainty analysis, parameter estimation, model calibration, model evaluation.

² PhD Thesis, Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Miguel Servin Palestina

Director: Irineo L. López Cruz, PhD

I. INTRODUCCIÓN GENERAL

Actualmente Zacatecas ocupa el primer lugar en la producción de frijol en México. En 2020 la superficie cosechada se ubicó en 640 mil ha y la producción en 382 mil t (SIAP 2020). El maíz y frijol son los cultivos de mayor importancia agrícola en México, además, considerado como prioritario para la seguridad alimentaria. En México, el consumo per cápita de esta leguminosa es de 8 Kg. (INEGI 2012). El frijol es básico para la dieta de los mexicanos por su alto contenido proteico (Lépiz y Navarro, 1983). El frijol se cultiva en gran parte del territorio mexicano, donde destaca la Región del Altiplano Semiárido del Norte, con clima muy seco o árido (Bs o Bw) (García, 2004). El estado de Zacatecas se reporta la mayor producción de frijol en México por más de 20 años consecutivos; se cultivaron en promedio de 55 mil ha de riego y de 650 mil ha de temporal. El promedio de rendimiento de grano ha variado de 1.5 a 2.1 t ha⁻¹ en riego y 0.23 a 0.57 t ha⁻¹ en temporal (SAGARPA, 2015). La mala distribución de la precipitación y las condiciones climáticas adversas (cambio climático), el manejo (riego, fertilización y labores culturales) y el efecto del clima sobre la producción de frijol demanda de herramientas que integren todos los componentes (cultivo, clima, manejo, etc.) de los sistemas de producción, como lo son los modelos matemáticos de simulación dinámica de cultivos. Estos modelos son utilizados para estimar la producción potencial de los cultivos, además para identificar factores limitantes y analizar cambios en el manejo, principalmente los que involucran manejo de agua en el suelo (López et al., 2005), así como para pronóstico y simulación de rendimientos útil para determinar la disponibilidad de grano a escala regional, además se podrá identificar fechas de siembra y densidad de siembra óptimas para cada condición climática en donde se desarrolla el cultivo. Para dichas tareas se han desarrollado varios modelos de cultivos: Crop-Syst (Stöckle et al., 2003), EPIC (Cavero et al., 2000; Ko et al., 2009), DSSAT (Jones et al., 2003), APSIM (Keating et al., 2003), Hybrid-Maize (Yang et al., 2004), WOFOST (Boogaard et al., 1998), STICS (Brisson et al., 1998), AquaCrop (Raes et al., 2009), SUCROS (Goudriaan and van Laar, 2012; van Laar et al., 1997), LINTUL de Leffelaar citado por (Farre et al. 2000) y GECROP (Xinyou, y Van Laar, 2005). De acuerdo con Sandhu y

Irmak (2019) y Heng et al. (2009) la mayoría de estos modelos son bastante complejos ya que requieren muchos parámetros y variables de entrada y pueden no ser siempre factibles o susceptible de uso general (Hoogenboom et al., 2010; Jones et al., 2003). Recientemente Zhao et al. (2019) desarrollaron un modelo de cultivo genérico denominado SIMPLE que puede modificarse fácilmente para cualquier cultivo que simule su desarrollo y crecimiento con solo 13 parámetros. El modelo SIMPLE se ha utilizado para estimar el rendimiento potencial del trigo en granjas verticales (Asseng *et al.*, 2020) y también se ha adaptado para simular el rendimiento de la linaza en China (Li *et al.*, 2022). El modelo es de reciente creación y su uso aún es limitado, sin embargo, el la versatilidad, simplicidad y adaptabilidad del modelo SIMPLE lo hacen un candidato potencial para aplicarlo en cultivos alternativos y cultivos de crecimiento indeterminado como el frijol.

Los modelos de crecimiento y desarrollo de cultivos se basan en un enfoque cuantitativo y utilizan un conjunto de ecuaciones diferenciales ordinarias o ecuaciones en diferencias no-lineales, se centran en el aprovechamiento de la radiación solar y otros con más detalles en procesos fisiológicos como fotosíntesis, respiración, transpiración, así como balances de agua en el suelo. La utilidad y su uso de dichos modelos están ligados con calidad de predicción y al requerimiento de parámetros, en este sentido, este documento se centra en el análisis y aplicación del modelo para crecimiento y desarrollo de cultivos SIMPLE, siguiendo el procedimiento general de modelación de sistemas (Fig. 1) (Ljung y Glad, 1994; Haefner, 2005; Voinov, 2008; Bala et al., 2017) en la simulación de biomasa en cultivo de frijol sometido a diferentes niveles de humedad en Zacatecas.




Figura 1.1. Procedimiento de modelación dinámica de sistemas. Adaptado de (Ljung y Glad, 1994; Haefner, 2005; Voinov, 2008; Bala et al., 2017)

1.1 Objetivo general

Desarrollar, analizar y evaluar un modelo matemático dinámico confiable para pronóstico de cosechas, simulación de crecimiento y desarrollo de cultivo de frijol (*Phaseolus vulgaris* L.), bajo diferentes escenarios de manejo de riego aplicando el procedimiento general de modelación de sistemas dinámicos.

1.2 Objetivos particulares

1. Realizar análisis de incertidumbre de los parámetros de modelo SIMPLE aplicado al cultivo de frijol mediante simulación Monte Carlo y el método de incertidumbre de verosimilitud generalizada (GLUE).
2. Llevar a cabo un análisis de sensibilidad del modelo SIMPLE aplicado al cultivo de frijol bajo condiciones de riego y seco
3. Caracterizar la respuesta fisiológica de frijol a diferentes niveles de disponibilidad hídrica en el suelo bajo condiciones de campo abierto y

analizar la incertidumbre del modelo SIMPLE con el procedimiento de verosimilitud generalizada (GLUE)

4. Llevar a cabo la calibración o estimación de parámetros del modelo SIMPLE aplicado al cultivo del frijol
5. Llevar a cabo la evaluación del modelo SIMPLE en la predicción de la dinámica del crecimiento del cultivo de frijol bajo condiciones de riego y seco.

1.3. Justificación

La simulación de variables relacionadas con el rendimiento de grano del cultivo de frijol a través del tiempo, mediante modelos matemáticos permite generar estrategias de manejo del cultivo para optimizar los recursos hídricos principalmente, de igual manera es posible estimar/predecir los rendimientos del cultivo bajo diferentes condiciones climáticas (cambios espaciales) y escenarios de cambio climático (cambios temporales).

Los modelos de simulación son usados para estimar, pronosticar, optimizar e identificar factores limitantes y analizar cambios en la producción de los cultivos. Con el fin de obtener un modelo matemático funcional y confiable es necesario conocer la fuente de incertidumbre, e identificar los parámetros más influyentes.

1.4 Estructura de la tesis

Capítulo II. Se describe la revisión de estado del arte sobre los modelos de simulación del crecimiento y rendimiento de frijol. Los modelos para simular y crecimiento y desarrollo son: BEANGRO, GenoGro, CROPGRO, WOFOST, SODCOM, DIACROS, Cereal-Legume, SSM-Legumes, Daisy, A simple model for snap bean, SIMPLE para simular crecimiento y desarrollo. También, se describen los modelos matemáticos dinámicos para manejo de riego en frijol SWB model, SALTMED y AquaCrop.

Capítulo III. se describen resultados del análisis de incertidumbre (UA) y análisis de sensibilidad (SA) global espaciotemporal para los parámetros del modelo SIMPLE, utilizando datos climáticos de cuatro estaciones climáticas representativas de las regiones productoras de frijol en Zacatecas para frijol de riego y secano.

Capítulo VI. Se describe el análisis de incertidumbre de verosimilitud generalizada (GLUE) con datos de un experimento de frijol común (*Phaseolus vulgaris* L.) llevado a cabo en Zacatecas, México, para el modelo de crecimiento de cultivos SIMPLE, explorando el comportamiento del modelo bajo condiciones de calibración y sin calibración para identificar la respuesta de la variable de salida biomasa.

Capítulo V. Se describen el procedimiento de estimación de parámetros (calibración) usando datos observados del ciclo de cultivo 2020 y el proceso de evaluación, con los datos del ciclo de cultivo 2021 con el modelo SIMPLE, en condiciones de riego en Zacatecas que servirá como herramienta para planificación de actividades productivas con menor riesgo de efectos climáticos adversos y falta de agua de riego en el cultivo de frijol.

II. MODELOS PARA CRECIMIENTO Y DESARROLLO PARA EL CULTIVO DEL FRIJOL (*Phaseolus vulgaris* L.): ESTADO DEL ARTE

3

2.1 Resumen

El frijol común (*Phaseolus vulgaris* L.) es la leguminosa de grano más importante para consumo humano directo por su alto contenido proteico, vitaminas y minerales. El estudio sobre la producción de este cultivo, para bajar costos de producción e incrementar rendimientos en condiciones de cambio climático, demanda de herramientas confiables para describir y comprender los sistemas de producción. Por lo anterior, el objetivo del presente estudio es realizar una revisión del estado del arte sobre los modelos de simulación del crecimiento y rendimiento de frijol. El desarrollo de modelos utilizados se centra en dos grandes familias: familia DSSAT con el modelo CROPGRO y la familia Wageningen con el modelo WOFOST. Otros modelos desarrollados para crecimiento y de desarrollo de frijol incluyen el modelo Cereal-Legume que simula el crecimiento de frijol intercalado con maíz, el modelo SSM-Legumes y el modelo Daisy. Recientemente, se han desarrollado modelos de simulación que requieren pocos parámetros como el modelo SIMPLE. Los modelos SWB, SALTMED y AquaCrop han sido desarrollados para simular el manejo de frijol bajo riego. En conclusión, los modelos de código abierto y la disponibilidad de las ecuaciones de los procesos fisiológicos involucrados de los modelos de la familia Wageningen permite a los investigadores adaptarlos en acuerdo a sus necesidades de simulación, esta ventaja permite que haya una gran variedad de modelos con este enfoque, aunque su uso se limita a usuarios con conocimientos de programación, comparada con los modelos de la familia DSSAT que cuentan con una estructura unificada y versátil lo que permite su amplio uso. En general los

Tesis de Doctorado en Ingeniería, Posgrado en Ingeniería Agrícola y Uso Integral del Agua,
Universidad Autónoma Chapingo

Autor: Miguel Servin Palestina

Director: Irineo L. López Cruz, PhD

6

modelos encontrados en la literatura científica tienen dificultades para simular el desarrollo del cultivo, sobre todo fechas de cambio de las etapas fenológicas.

Palabras clave: modelos dinámicos, simulación de biomasa, rendimiento

2.2. Abstract

The common bean (*Phaseolus vulgaris* L.) is the most important grain legume for direct human consumption due to its high protein content, vitamins and minerals. The study on the production of this crop, to lower production costs and increase yields under climate change conditions, demands reliable tools to describe and understand production systems. For the above, the objective of this study is to review the state of the art on bean growth and yield simulation models. The development of models used focuses on two large families: the DSSAT family with the CROPGRO model and the Wageningen family with the WOFOST model. They also developed the Cereal-Legume model that simulates the growth of beans intercropped with maize, the SSM-Legumes model, and the Daisy model. Recently, SIMPLE models have been developed that require few parameters such as the SIMPLE model, on the other hand, SWB model, SALTMED and AquaCrop models have been developed using models for irrigation management in beans. The results were that the open source models and the availability of the equations of the physiological processes involved in the Wageningen family models allow researchers to adapt them according to their simulation needs, this advantage allows for a wide variety of models. with this approach, although its use is limited to users with programming knowledge, compared to the models of the DSSAT family that have a unified and versatile structure that allows its wide use. In general, the models found in the scientific literature have problems to simulate the development of the crop, especially dates of change of the phenological stages.

Key words: dynamic models, biomass simulation, yield

2.3. Introducción

Las leguminosas, junto con los cereales, han sido la base principal de la alimentación humana durante milenios. El frijol común (*Phaseolus vulgaris* L.) es la leguminosa de grano más importante para consumo humano directo (Beebe et al., 2013), el grano contiene entre 20 y 25% de proteína de alta calidad (Ma and Bliss, 1978), vitaminas y minerales (Graham and Ranalli, 1997). El frijol juega un papel importante en la dieta de la población latinoamericana (Beebe et al., 2017), en donde se cultiva el 50% de la producción mundial total, que asciende a 29 millones de toneladas métricas en promedio en la última década (CEDRSSA, 2020). Esta leguminosa crece en un rango de altitud de 0 a 3000 msnm, como resultado de su amplia adaptación y variabilidad morfológica (Broughton et al., 2003). Este cultivo tiene varios hábitos de crecimiento: tipo I. determinado y arbustivo, tipo II. indeterminado-arbustivo, tipo III. indeterminado postrado y tipo IV. indeterminado trepador (Fernández et al., 1985), además, es una planta con la capacidad de fijar nitrógeno al suelo (Vance, 1997). Flores (2015) menciona que incorpora de 60 a 120 kg ha⁻¹ de N al suelo. Esta especie se cultiva como monocultivo, en rotación e intercalado (Broughton et al., 2003) con maíz (Nassary et al., 2020), café (Huang et al., 2020), tubérculos (Horacio et al., 2019). El frijol se cultiva en diversos sistemas de producción desde tradicionales hasta altamente tecnificados (Beebe et al., 2017) y los promedios de rendimiento más altos se obtienen en Estados Unidos y China con 2.04 y 1.67, respectivamente; mientras que los rendimientos más bajos ocurren en la India y México con 0.42 y 0.71 t ha⁻¹, respectivamente (FAOSTAT, 2021). El frijol es sensible al estrés hídrico, temperatura y fotoperiodo (Seidel et al., 2016). Beebe et al. (2017) afirman que los factores que limitan la producción de frijol son: la sequía, altas temperaturas, exceso de aluminio, magnesio y deficiencia de fósforo en el suelo, así como las plagas y enfermedades (Beebe, 2012). Por otro lado, Mittler (2016), menciona que las condiciones de estrés abiótico, como temperaturas extremas del aire o del suelo y la sequía, provocan gran pérdida de la producción agrícola en todo el mundo. Por consiguiente, es importante conocer el cultivo (su fisiología, crecimiento, desarrollo, demanda de agua y nutrientes) y el medio ambiente donde crecen (clima, suelo). Ya que el cambio climático, el crecimiento

demográfico, la escasez de agua y baja fertilidad del suelo ponen en riesgo la producción de alimentos, esto genera un gran reto para productores, técnicos e investigadores.

Seidel et al. (2016) mencionan que el modelado del crecimiento y desarrollo de los cultivos es una herramienta ampliamente aceptada para la comprensión de procesos. Los modelos matemáticos en agricultura son herramientas eficaces para describir y comprender sistemas complejos y se han utilizado para predecir los resultados de la producción en diferentes condiciones climáticas, suelo y manejo (Jones et al., 2003; Staggenborg y Vanderlip, 2005). La estructura de los modelos de crecimiento y desarrollo de cultivos es compleja, no lineal, dinámica, multivariable y con incertidumbre. Se representan mediante un conjunto de ecuaciones diferenciales u ordinarias de primer orden o ecuaciones en diferencias (Chalabi et al., 1996; Thornely and France, 2007). Las variables de estado permiten conocer el comportamiento interno del sistema, mientras que las variables de salida dan cuenta de su comportamiento externo. Las variables de entrada representan el efecto del ambiente sobre el sistema (Wallach et al., 2019). Además, se requiere un conjunto de coeficientes que representan parámetros fisiológicos cuyos valores deben determinarse con precisión para obtener un buen ajuste entre las variables predichas y las medidas (Trejo-Zuñiga et al., 2014). Wang et al. (2013) mencionan que hay una alta incertidumbre en los modelos asociada a los parámetros por la diversidad de cultivos (variedades) y condiciones climáticas, debido a los procesos fisiológicos planta-suelo, que dan origen a un número finito de permutación y combinaciones variables en tiempo y espacio e impulsadas por factores bióticos y abióticos, por esto existen muchos modelos matemáticos para la mayoría de cultivos. Keating y Thorburn (2018) han clasificado los modelos matemáticos dinámicos para crecimiento y desarrollo de cultivos en cinco grandes familias de acuerdo con su origen: los modelos de cultivos de Wageningen, Holanda (van Ittersum et al., 2003); DSSAT, EE. UU. (Jones et al., 2003), APSIM, Australia (Keating et al., 2003), Cropsyst EE. UU. e Italia (Stöckle et al., 2003) y STICS, Francia (Brisson et al., 2003). van Ittersum et al. (2003) asignan jerarquías a los modelos en base a la simulación de tipo de producción: potencial, limitada y real. La

primera jerarquía considera los factores climáticos temperatura, radiación solar y dióxido de carbono como las únicas limitantes para el crecimiento, mientras que la segunda jerarquía considera limitaciones de agua y nutrientes, y la tercera jerarquía incluye malezas, plagas, enfermedades y contaminación.

No obstante que el objetivo del presente capítulo consiste en realizar una revisión del estado del arte sobre los modelos de simulación del crecimiento y rendimiento de frijol, de acuerdo con la clasificación hecha por Keating y Thorburn (2018) los modelos utilizados para simular crecimiento y desarrollo de frijol se centra en dos grandes grupos. Dentro de la familia DSSAT, se encuentra BEANGRO (Hoogenboom et al., 1991) que se basó en SOYGRO y PNUTGRO (Hoogenboom et al., 1986), GenoGro (White y Hoogenboom, 1996) una adaptación del anterior con la incorporación de características fenotípicas y adaptación en presencia o ausencia de algún gen en particular. Posteriormente desarrollaron el modelo CROPGRO (Hoogenboom et al., 1994) basado en las experiencias con SOYGRO, PNUTGRO y BEANGRO. CROPGRO se desarrolló con un enfoque genérico que predice el crecimiento de varios cultivos, actualmente, simula diez cultivos, de los cuales siete son leguminosas de grano (Jones et al., 2003) y es ampliamente utilizado en frijol. Por otro lado, en la familia Wageningen, los primeros registros en modelación de frijol fueron reportados por el Centro de Investigación de la Comunidad Europea (Boons-Prins et al., 1993) con WOFOST (van Keulen y Wolf, 1986) es un modelo genérico que simula rendimiento potencial y limitado de uso a escala regional, nacional y mundial. Un año más tarde, O'Callaghan et al. (1994a) adaptaron el modelo SODCOM para simular el crecimiento de frijol intercalado con maíz. SODCOM (O'Callaghan et al., 1994b) considera la luz interceptada por el dosel y un balance de energía, su base fundamental está dada por SUCROS (van Keulen et al., 1982). Posteriormente desarrollaron DIACROS (Verdoodt, et al., 2004), es un modelo jerárquico que simula el crecimiento diario de los cultivos basado en fotosíntesis y respiración, es una síntesis de los modelos WOFOST y SUCROS. Tsubo et al. (2005) desarrollaron Cereal-Legume que simula el crecimiento de frijol intercalado con maíz y se basa en la intercepción y uso de la radiación por el dosel e incorpora un factor por estrés por agua. Soltani y Sinclair

(2012) desarrollaron SSM-Legumes es un modelo genérico utilizado para simular crecimiento y desarrollo de leguminosas. Seidel et al. (2016) utilizaron el modelo Daisy para modelar el impacto por estrés por agua y temperatura en frijol. Daisy fue desarrollado por Abrahamsen y Hansen (2000) el cual simula la dinámica del agua y nitrógeno en los cultivos. Recientemente, Yuan et al. (2017) desarrollaron un modelo para simular el desarrollo, crecimiento y rendimiento del frijol en respuesta al nitrógeno, mientras que Zhao et al. (2019) desarrollaron el modelo para crecimiento y desarrollo de cultivos SIMPLE, el cual es un modelo de cultivo genérico con pocas ecuaciones y parámetros que simula crecimiento y desarrollo de los cultivos en función de temperatura, radiación y estrés hídrico. El modelo SIMPLE fue desarrollado por el grupo DSSAT con funciones matemáticas usadas en otros modelos. Tanto el modelo de Yuan et al. (2017) como el modelo SIMPLE (Zhao et al., 2019) contienen funciones utilizadas por otros modelos que resultan precisas, simples y con requerimientos mínimos de parámetros. También, se han utilizado modelos matemáticos dinámicos para manejo de riego en frijol como: SWB model (Annandale et al., 1999), SALTMED (Regab, 2002) y AquaCrop (Steduto et al., 2009). En el siguiente apartado se describen, brevemente, los modelos más utilizados para la simulación de crecimiento de frijol.




Figura 2.1. Línea del tiempo de la modelación dinámica de crecimiento y desarrollo de frijol

2.4. Modelos dinámicos utilizados para crecimiento frijol

2.4.1. BEANGRO

Fue el primer modelo desarrollado para frijol desde 1986, por la universidad de Florida con apoyo del centro internacional de agricultura tropical (CIAT) de Cali, Colombia, basado en SOYGRO y PNUTGRO utilizados para soya y cacahuete, respectivamente (Hoogenboom et al., 1986). Codificado en FORTRAN, fue diseñado con la misma estructura estándar de archivos del sistema “Decisión Support System for Agrotechnology Transfer” (DSSAT; Hoogenboom et al., 1991). El modelo utiliza funciones de procesos fisiológicos como fotosíntesis, respiración y transpiración. Simula crecimiento de materia seca, índice de área foliar, desarrollo del cultivo y rendimiento de frijol común en función de variables climáticas (precipitación, radiación solar, fotoperiodo, temperatura máxima, mínima del aire y velocidad del viento), características del perfil del suelo y condiciones de manejo. Incluye un módulo de balance de agua en el suelo y simula rendimiento limitado por agua. El modelo es sensible al cultivar, fecha de siembra, arreglo topológico y manejo de riego. BEANGRO V1.01 es la última versión descrita y publicada (Figura 2.2).




Figura 2.2. Estructura e interfaz de usuario de modelo BEANGRO (Hoogenboom et al, 1994)

Por otro lado, Hoogenboom et al., (1994) desarrollaron el interfaz de usuario de BEANGRO V1.01. Esta versión cuenta con un módulo para el análisis de sensibilidad. BEANGRO V1.01 sigue los formatos de archivo estándar del sistema DSSAT y se puede utilizar durante varios años para evaluar los efectos de diferentes prácticas de gestión agrícola, utilizando datos meteorológicos históricos o generados. Éste opera en pasos de tiempo diarios y simula el crecimiento y desarrollo del frijol desde la siembra a cosecha. White et al. (1995) lo utilizaron para simular el efecto del rendimiento en función de la densidad de plantación, déficit hídrico y temperatura. Estos autores observaron que el déficit hídrico subestima la acumulación de biomasa aérea, afectando las variedades menos adaptadas y con ciclo fenológico más largo. determinaron que hay una relación cuadrática entre el rendimiento de grano y la lámina de riego aplicada, aunque, subestima el rendimiento en variedades con mayor adaptación al estrés hídrico, en cuanto a la temperatura es importante considerar la amplitud térmica entre el día y la noche, mencionan que con días más cortos el desarrollo es más lento. White et al. (1996) incorporaron parámetros genéticos en BEANGRO y desarrollaron GenoGro, incorporaron siete parámetros genéticos que afectan la fenología, hábito de crecimiento y tamaño de semilla del cultivo. GenoGro explicó el 31% de la variación observada para el rendimiento, el 58% para el peso de la semilla, el 84% para los días hasta la floración, el 85% para los días hasta la madurez, el 52% para el índice máximo de área foliar y 36% para el peso seco del dosel en la madurez, pero 0% para el índice de cosecha. Hoogenboom et al. (1997) Evaluaron GeneGro y compararon datos de campo y simulados. Utilizaron 14 ensayos de campo realizados en Canadá, Estados Unidos, México y Colombia, que representan 213 combinaciones de tratamientos e incluyen 39 cultivares. GeneGro explicó el 75% de la variación en los días hasta la floración, el 68% en los días hasta la madurez y el 39% en la masa de semillas, pero solo el 11% de la variación en el rendimiento de semillas. concluyeron que la información genética favorece la comprensión de rasgos como la fenología, el tamaño de la semilla y el hábito de crecimiento.

Acosta-Gallegos et al. (1996) utilizaron este modelo para comparar el crecimiento y el rendimiento de semillas de germoplasma de frijol común tropical y de tierras altas de

México y definieron fechas de siembra e identificar que la temperatura y radiación son las variables con mayor influencia en el crecimiento y desarrollo de frijol. Acosta-Gallegos et al. (1995), mencionan que la gran diversidad de este cultivo se identifican grandes diferencias en la fenología del cultivo.

Posteriormente, White y Hoogenboom (2003) hicieron una revisión exhaustiva sobre la incorporación de parámetros genéticos basados en la genómica funcional y desarrollaron el modelo GeneGro. Sin embargo, este enfoque requiere datos extensos sobre la composición genética pocos accesibles. Los modelos deben simular vías bioquímicas complejas como la fotosíntesis, fotoperiodo, reguladores genéticos y otros metabolitos. Este trabajo influyó para desarrollar CSMGeneGro–Common Bean, con base en el modelo Cropping System Model (CSM) y GeneGro. El CSM considera los balances de agua, nitrógeno y carbono del suelo y destacan la importancia y la relación que hay entre las características fenotípicas y los genes de los cultivos. La incorporación de información genética fortalece los supuestos fisiológicos subyacentes del modelo, mejorando su utilidad para la investigación en mejoramiento, manejo y cambio climático (Hoogenboom et al., 2004).

2.4.2. CROPGRO

Este modelo tuvo sus orígenes en los 90's y surgió con la intención de hacer un código genérico y un archivo externo con parámetros individuales para cada cultivo. Se basó en los modelos SOYGRO, PNUTGRO y BEANGRO e inicialmente simulaban el crecimiento de tres cultivos (soya, cacahuates y frijol); Hoogenboom et al., (2019) mencionan que se generó con una estructura de “The Decision Support System for Agrotechnology Transfer” (DSSAT). CROPGRO actualmente considera la simulación de 20 cultivos y el módulo de leguminosas es el más amplio con siete cultivos (DSSAT, 2021). CROPGRO es un modelo mecanicista que predice el crecimiento de biomasa seca de los diferentes órganos de planta, índice a área foliar, balance de agua en el suelo, movilización de nitrógeno, dinámica de carbohidratos y desarrollo del cultivo, con base en un balance de carbón que incluye, fotosíntesis, respiración, transpiración, partición, remoción de proteínas y carbohidratos en los órganos vegetales. El modelo tiene dos opciones para calcular

fotosíntesis: 1) Diaria en el dosel, 2) horaria a nivel de hoja con intercepción de luz en función de temperatura, CO₂ y radiación (Boote et al., 1998). Para el balance de agua en el suelo CROPGRO utiliza el módulo SPAM (Soil-Plant-Atmosphere) de DSSAT y estima la evapotranspiración con tres métodos: Penmann, Penmann-Monteith y Priestley-Taylor. Los requerimientos mínimos de datos de entrada de clima diarios son: radiación solar, temperatura máxima y mínima y precipitación (Figura 2.3.).




Figura 2.3. Diagrama del modelo CROPGRO (Zamora et al., 2009)

El modelo CROPGRO ha sido utilizado ampliamente en muchos países del mundo. Ha calibrado, evaluado y aplicado para estudios de mejoramiento genético y adaptación al cambio climático, manejo de riego y fechas de siembra. Meireles et al. (2002) calibraron y evaluaron el modelo CROPGRO- (DSSAT) usando frijol carioca (*Phaseolus vulgaris* L.) para estimar el rendimiento y el desarrollo del cultivo, sembrado en tres espaciamientos entre hileras y dos dosis de fertilización, en Santo Antônio de Goiás, GO, Brasil. Calibraron diez parámetros genéticos que caracterizan la fenología y morfología del cultivo para antesis predicha, días a madurez fisiológica, índice de área foliar (LAI), materia seca total (TDM),

componentes de biomasa y rendimiento y obtuvieron un coeficiente de determinación con valores 0.95 y 0.98 para LAI y TDM, respectivamente. El siguiente año Flores y Retana (2003) reportaron la calibración y evaluación del modelo CROPGRO-Dry Bean, bajo las condiciones de la zona de Los Chiles, Alajuela, Costa Rica. Más tarde, Chaves de Oliviera (2007) calibraron CROPGRO en tres variedades de frijol en condiciones de riego y secano, después se aplicó para la estimación de fenología y rendimientos por 31 años (1975 - 2006) los autores resaltan la sensibilidad del modelo a los coeficientes genéticos entre variedades, sin embargo, el modelo predice adecuadamente la fenología del cultivo en diferentes ambientes agroclimáticos y la productividad con un error cuadrático medio menor al 5%, y 12.6%. Webber et al. (2010) mostraron evidencia que el modelo CROPGRO es agronómica y fisiológicamente robusto. CROPGRO se modificó para incluir una función de respuesta a la salinidad y se probó para suelos yesíferos. La función de respuesta considera la reducción de rendimiento por la carga de presión del agua osmótica en el suelo. La función de respuesta se calibró y se obtuvo un índice de concordancia de Willmott (i) de 0.98 y en la etapa de evaluación se obtuvieron i de 0.75 y 0.74 para evapotranspiración y rendimiento respectivamente. De igual manera, Dallacort et al. (2011) lo utilizó para analizar los componentes del crecimiento, evapotranspiración y el rendimiento del cultivo de frijol para las condiciones edafoclimáticas de Maringá, Paraná, Brasil y concluyeron que el déficit hídrico durante la floración reduce severamente el rendimiento, el modelo mostró diferencias en la simulación del índice de área foliar, y la humedad del suelo al día siguiente de la lluvia. Los autores reportaron una correlación del 70% para la humedad de suelo y mencionaron que el modelo subestima el rendimiento.

También se ha calibrado y evaluado CROPGRO para fertilización orgánica e inorgánica en Ruanda y los resultados mostraron que cambiando las condiciones de manejo es posible incrementar el rendimiento hasta 0.6 t ha principalmente en suelos con mejores propiedades químicas Bidogeza et al., (2012). Oliveira et al., (2012) lo calibraron en secano y lo evaluaron en riego para tres variedades de frijol en Minas Gerais, Brasil. En la evaluación encontraron un r^2 de 0.97 y 0.99 para días de siembra a floración y días de floración a madurez fisiológica respectivamente, y

un índice de concordancia mayor a 0.88, posteriormente lo utilizaron para pronosticar el rendimiento con 31 años de datos climáticos y para obtener la relación de la fecha de siembra con el rendimiento, concluyendo que las siembras inicien el 20 de febrero para los tres cultivares.

Munz et al. (2014) utilizaron el modelo para simular el rendimiento de frijol intercalado con maíz en Alemania, bajo diferentes niveles de radiación modificando el efecto de sombreado para observar el efecto de la radiación sobre la arquitectura del dosel y área específica de hoja, realizaron simulaciones en escala diaria y horaria e identificaron que la fracción de radiación difusa no es identificada adecuadamente a escala diaria e identificaron que el modelo simula adecuadamente el índice de área foliar, materia seca y rendimiento.

Osorio (2014) lo utilizó para simular la productividad de frijol variedad Amadeus 77 en Honduras con fertilización y sin fertilización y mencionan que las condiciones del experimento permitieron resultados adecuados para la predicción de fechas fenológicas y no simuló adecuadamente el rendimiento. Los autores concluyeron que es necesario tener un conjunto más amplio de datos experimentales distribuidos temporal y espacialmente en la región.

Dos-Santos et al., (2016) calibraron y evaluaron el modelo CROPGRO en Brasil con dos métodos de programación de riego (tensiómetros y evaporación del tanque tipo A) y dos métodos de labranza (convencional y sin labranza). En la etapa de calibración el modelo simuló adecuadamente los días a floración, primera vaina y madurez fisiológica, además, el coeficiente de correlación (R) para índice de área foliar (IAF) fue superior a 0.86 y para biomasa seca (B) el R fue mayor de 0.96 para todos los tratamientos. En la etapa de evaluación los días a primera vaina fue subestimada por el modelo con una diferencia de 12 días. Se obtuvieron R superiores a 0.86 y 0.91 para IAF y B, respectivamente, la simulación de agua en el suelo para todos los tratamientos fue muy baja.

También se ha utilizado para clasificación agroambientales en base a la intensidad y sincronía de la sequía e identificaron zonas con potencial productivo y zonas con rendimientos bajos por efecto de la sequía (Heinemann et al. 2016), por otro lado,

analizaron la pérdida de rendimiento por el efecto de la sequía en países de latino américa, áfrica y medio oriente y concluyeron que variedades con tolerancia a sequia podría incrementar el rendimiento en un 24.7% (Álvarez et al., 2016), además, este modelos se la utilizado para analizar el impacto del cambio climático mediante la simulación del crecimiento y desarrollo del frijol en tres fechas de siembra y se observó una reducción del rendimiento en 10% al 50% dependiendo de la localidad y fechas de siembra y destacan la importancia de la adaptación del cultivo al cambio climático (Eitzinger et al., 2017).

Hwang et al (2017) propone un módulo para el modelo basados en genes para simular cambios en el número de nodos del tallo principal, el tiempo hasta la primera antesis y el número de nudos final en el tallo principal del frijol común (*Phaseolus vulgaris* L). El modelo se basó en datos de 187 genotipos. La evaluación del modelo con genotipos no utilizados en el desarrollo del modelo mostró predicciones confiables en todos los sitios para el tiempo hasta la primera antesis ($R^2 = 0.75$) y el número de nodos del tallo principal durante la fase lineal de la adición de nodos ($R^2 = 0.93$), mientras que la predicción del número final de nodos principales fue menos confiable ($R^2 = 0.27$). El uso de modelos de efectos mixtos para analizar datos en múltiples ambientes de una amplia gama de genotipos es muy prometedor para ayudar al desarrollo de modelos dinámicos de efectos de rasgos cuantitativos QTL capaces de simular el desarrollo vegetativo y reproductivo.

Boote et al., (2018) utilizaron el CROPGRO-Dry Bean para modelar la respuesta de algunos cultivos incluido frijol a diferentes niveles de temperatura cultivadas en cámaras de ambiente controlado iluminadas por el sol. Las funciones de temperatura para los modelos de soja y maní se evaluaron contra los datos de crecimiento y rendimiento en las mismas cámaras y se encontró que predicen adecuadamente el crecimiento y el rendimiento, por lo que no se han modificado desde la publicación de 1998 de V3.5. Las funciones de temperatura para el modelo de garbanzo se modificaron sustancialmente para muchos procesos y se actualizaron para V4.6. El modelo de mijo fue codificado y modificado para sensibilidades a la temperatura, con una nueva función para permitir que el período

de 8 a 10 días antes de la antesis afecte el cuajado de granos, según lo parametrizado a partir de las observaciones de campo. Para el modelo de sorgo, el efecto de la temperatura sobre la tasa de crecimiento del grano se modificó para mejorar el rendimiento y la respuesta del tamaño del grano a la temperatura elevada en comparación con los datos en cámaras de ambiente controlado. Para realizar evaluaciones fiables del impacto del cambio climático, es de vital importancia recopilar datos adicionales de respuesta a la temperatura y actualizar la parametrización y el código de todos los modelos de cultivos, incluido DSSAT.

Mompremier et al., (2021) simularon la respuesta del rendimiento del frijol seco (*Phaseolus vulgaris* L.) a la disponibilidad de agua en un distrito de riego considerando aguas arriba de la cuenca hidrológica en Haití. Después de la calibración el modelo se utilizó para determinar la respuesta a largo plazo del frijol seco a los escenarios de disponibilidad de agua, incluidas quince combinaciones de cinco períodos de crecimiento y tres condiciones de riego. Los resultados mostraron que la productividad del frijol seco estaba estrechamente asociada con la hidrología de la cuenca río arriba y que el cultivo del frijol seco antes del escenario de manejo estándar (diciembre a marzo) aumentó el rendimiento previsto de frijol seco en más del 80% con los recursos hídricos disponibles y la variabilidad temporal asociada. Estos hallazgos indican que un enfoque de sistemas integrados podría mejorar la producción de frijoles secos al identificar prácticas de manejo alternativas para utilizar el agua disponible de manera más eficiente.

2.4.3. WOFOST

El The World Food Studies (WOFOST) es un modelo mecanicista, genérico y jerárquico basado en procesos biofísicos. WOFOST simula principalmente, desarrollo fenológico, biomasa particionada, desarrollo de las hojas, interceptación de la luz, asimilación de CO₂, crecimiento radicular, transpiración, respiración. Los procesos más complejos son desarrollo fenológicos y crecimiento de hojas (senescencia y asimilación) el cual requiere 27 parámetros, mientras, para la formación de raíz, respiración, transpiración formación de órganos de almacenamiento y formación de tallos requieren 24 parámetros. Las variables

climáticas de entrada requeridas son radiación global, temperatura máxima y mínima, presión de vapor, velocidad del viento y precipitación. WOFOST utilizan diferentes enfoques de balance hídrico con diferentes niveles de detalle y requiere un máximo de 13 parámetros del suelo (de Wit et al., 2019; Boogard et al., 2014; Figura 2.4).




Figura 2.4. Diagrama relacional modelo WOFOST

Los primeros y únicos reportes del uso de modelo WOFOST en frijol los reportaron Boons-Prins et al., (1993), en este trabajo se reportan los parámetros al calibrar WOFOST con diferentes experimentos e identificaron que se debe tener especial cuidado con las etapas fenológicas y definieron las fechas de siembra para la unión europea.

2.4.4. DIACROS

Modelo de crecimiento de cultivos genérico, funcional, jerárquico y simple a escala diaria, basado en los principales procesos fisiológicos que afectan el rendimiento como fotosíntesis y respiración. La conceptualización de DIACROS está basada en el modelo de crecimiento diario (FAO, 1979), SUCROS (van Laar et al., 1992) y WOFOST (Supit et al., 1994). Simula etapas de desarrollo, biomasa particionada, índice de área foliar, rendimiento desarrollado por Verdooddt et al., (2004).




Figura 2.5. Diagrama modelo DAICROS

Los mismos autores utilizaron el modelo DAICROS para calcular la producción potencial, rendimiento y materia seca en Rwanda. Los resultados reportados indican que el rendimiento potencial simulado excede los rendimientos reportados local e internacionalmente en la literatura, y mencionan el modelo subestima el rendimiento en tierras altas. Sin embargo, la simulación de rendimiento en varios cultivos está dentro de los reportados por varios autores, evidencian que el modelo predice satisfactoriamente el rendimiento.

2.4.5. SSM-Legumes

El modelo SSM-Legumes simula la acumulación de materia seca, el desarrollo de cultivos y el consumo de agua en diferentes especies de leguminosas de grano, se ha utilizado en soya, garbanzo, lenteja, cacahuate, alubias y frijol. Es un modelo mecanicista genérico de escala diaria, que simula producción limitada por agua y nitrógeno, que requiere 57 parámetros (cultivo, suelo y manejo). SSM-Legumes se

estructura en 5 módulos 1) desarrollo, basado en días foto-térmicos acumulados; 2) desarrollo del área foliar, que se calcula a partir de la tasa de aparición de hojas y la relación entre el número de hojas y el área foliar; 3) producción de materia seca; 4) materia seca particionada, determinada por el balance de nitrógeno, y 5) balance de agua del suelo, donde la transpiración se calcula en función de la producción diaria de materia seca y el déficit de presión de vapor durante el día, las variables de entrada requeridas son temperatura mínima y máxima, radiación solar global y precipitación (Soltani y Sinclair, 2012).

El modelo SSM- Legumes se calibró y evaluó con observaciones de campo registradas durante cinco años en ocho fincas del área de Castelnaudary, Francia para identificar el efecto de diferentes escenarios de riego en el rendimiento de frijol Lingot y el consumo de agua. El modelo mostró buen ajuste en la simulación de materia seca total y el rendimiento con un RMSE = 41 g m⁻² y RMSE = 110 g m⁻², respectivamente y subestima ligeramente el índice de área foliar. Los autores concluyeron que el modelo SSM- Legumes fue robusto bajo las condiciones ambientales probadas, además los autores mencionan que los productores de la región pueden lograr rendimientos ligeramente más altos con menos agua al basar las decisiones de riego en el contenido de agua del suelo, (Marrou et al., 2014).

Por otro lado, Van Loon et al. (2018) lo aplicaron en Etiopía, Kenia y Tanzania, en cinco cultivos de leguminosas incluido frijol. Utilizaron datos meteorológicos locales y parámetros reportados en la literatura y simularon el rendimiento limitado por agua, identificaron fallas en el manejo, reducción del rendimiento y como se afectará la disponibilidad de grano para el año 2050, en un marco espacial y estimaron el rendimiento potencial (Y_w), real de la finca (Y_a) y a escala regional (Y_g). Los resultados mostraron que Y_a fue el 25 % de Y_w para los tres países y 5 leguminosas evaluadas, siendo el 15 % para Kenia, el 23 % para Tanzania y el 41 % para Etiopía. Además, el frijol común tuvo el promedio más grande Y_g de 2,6 Mg ha⁻¹ y el garbanzo el menor (1,4 Mg ha⁻¹). Los autores concluyen que Y_g explotable (es decir, el 80% de Y_w) puede ayudar a satisfacer la demanda futura de leguminosas tanto en Kenia como en Tanzania, mientras que en Etiopía parece no ser suficiente.

2.4.6. SODCOM

El modelo SODCOM (solar driven computational model of crop growth) se basa en los conceptos de ARC-WHEAT1 con tres sub-modelos. Simula la producción potencial y limitada por agua-nutrientes en escala diaria. Las variables de estado son: tiempo térmico, índice de área foliar, interceptación de radiación, fotosíntesis, respiración y materia seca particionada. Las variables de entrada requeridas son: radiación solar, temperatura, además, integra un sub-modelo para el balance de agua en el suelo. El modelo SODCOM tiene siete parámetros, factores de partición y etapas de desarrollo (O'Callaghan et al., 1994^a; Figura 2.6).




Figura 2.6. Diagrama SODCOM

O'Callaghan et al., (1994b) Utilizaron el modelo SODCOM para analizar el cultivo de frijol intercalado con maíz en la región de Kitale en Kenia. Le incorporaron modificaciones que consideren la competencia por luz y agua. Los resultados mostraron un buen ajuste para el rendimiento del cultivo con productores del Distrito Trans Nzoia durante siete años. Concluyeron que los cultivos (maíz y frijol) al ser intercalados incrementan levemente el rendimiento y que el maíz es más sensible al estrés hídrico con respecto al frijol, también reportaron que el único inconveniente de los cultivos intercalado es la mecanización de las labores culturales.

2.4.7. Cereal-Legumes

El modelo Cereal-Legumes está basado en radiación, es un modelo semi-empírico (model of cereal–legume intercropping) basado en uso e intercepción de radiación e incorpora un factor de estrés por agua, para simular biomasa aérea con cultivos intercalados de maíz y frijol en condiciones semiáridas. Considera el índice de área foliar un balance para determinar la luz interceptada para cada cultivo y un balance de agua en el suelo. Tsubo et al., (2005a) también menciona que la relación de radiación fotosintéticamente activa y radiación solar, coeficiente de extinción medido y curva exponencial de decaimiento de humedad en el suelo minimizan el error entre los datos observados y simulados de biomasa con un R^2 de 0.75. Por otro lado, Tsubo et al., (2005b) simularon 81 escenarios, considerando tres niveles iniciales de agua del suelo, fecha de siembra, densidad de maíz y frijol, concluyendo que el agua inicial al momento de la siembra fue el factor más importante.

2.4.8. El modelo SIMPLE.

El modelo SIMPLE es un modelo dinámico, genérico y semi-empírico, de tiempo discreto y paso diario. Las variables de estado (Biomasa y tiempo térmico) se describen mediante ecuaciones en diferencias. Las variables de entrada son: T_{max} , T_{min} , R_s , P_p . El modelo requiere 13 parámetros (T_{sum} , HI , I_{50A} , I_{50B} , T_b , T_{opt} , RUE , I_{50maxH} , I_{50maxW} , T_{max} , T_{ext} , SCO_2 , $Swater$) e incorpora un módulo de balance de agua en el suelo, por tal razón, es conocido como modelo de crecimiento

de cultivos limitado por agua. La biomasa y rendimiento se consideran como variables de salida (Zhao et al., 2019). Los desarrolladores lo probaron con datos experimentales de 14 cultivos incluido frijol. Concluyeron que el modelo presentó buen ajuste y que se puede utilizar a escala regional por su simplicidad y eficiencia.

2.5. Modelos basados en transpiración

2.5.1. El modelo SALTMED

El modelo SALTMED simula la evapotranspiración, absorción de agua por las plantas, transporte de agua y solutos bajo diferentes sistemas de riego, drenaje y la relación entre el rendimiento de los cultivos y el uso del agua. Es un modelo mecanicista genérico, es decir, se puedan usar para una variedad de sistemas de riego, tipos de suelo, estratificaciones del suelo, cultivos y árboles, estrategias de gestión del agua (mezcla o cíclica), requisitos de lixiviación y calidad del agua. Está basado en ecuaciones establecidas de transporte de agua y solutos, evapotranspiración y absorción de agua del cultivo (Ragab, 2002). También, es un modelo de código cerrado con ambiente gráfico codificado en C/C++, que requiere diferentes parámetros que caracterizan la planta, el suelo y sistema de riego. El modelo SALTMED requiere información de evaporación, horas de sol, velocidad del viento, temperatura máxima, temperatura mínima, humedad relativa, radiación solar y precipitación como variables de entrada. El autor menciona que el modelo describió con éxito el efecto del sistema de riego, el tipo de suelo, el nivel de salinidad del agua de riego en la distribución de la humedad y la salinidad del suelo, los requisitos de lixiviación y el rendimiento de los cultivos en todos los casos evaluados.

El modelo SALTMED se ha utilizado con éxito en el cultivo de frijol en dos investigaciones. Mehanna et al. (2015) simularon la distribución de agua y solutos en el suelo. También simularon el rendimiento en tres regímenes de riego y fertilización nitrogenada en Egipto en frijol ejotero. Los resultados mostraron una correlación positiva mayor a 0.8 entre los datos observados y simulados de las distribuciones agua y solutos en el suelo para todos los tratamientos

experimentales. Los rendimientos más altos de 14.9 y 15.2 t ha⁻¹ se obtuvieron aplicando 150 y 112.5 kg ha⁻¹ de N, respectivamente, aplicando 1,542 m³ ha⁻¹.

Dewedar et al. (2020) calibró y evaluó el modelo SALMED para simular humedad del suelo, materia seca total y el rendimiento de frijol sometido a tres niveles de humedad (100%, 80% y 60% de la evapotranspiración del cultivo, ETc) en dos sistemas de riego, superficial y subterráneo en Egipto. Los resultados para la humedad de suelo simulada y medida alcanzaron coeficientes de determinación superiores a 0.9 para ambos sistemas de riego e identificaron que no hubo diferencia significativa en 100% y 80% de la ETc. También, menciona que el rendimiento y la productividad del agua bajo riego subterráneo fue ligeramente mayor con respecto al riego por goteo superficial, para materia seca hubo una diferencia de -5.01% y 0.68 entre los simulados y observados para sistemas de riego superficial y subterráneo, respectivamente. Los autores concluyeron que el modelo SALTMED podría aplicarse como herramienta de gestión de cultivos, agua y tierras en las condiciones climáticas egipcias actuales y futuras.

2.5.2. AQUACROP

AquaCrop es un modelo que simula el crecimiento de los cultivos basado en la ecuación de Doorenbos y Kassam (1979). sin embargo, el enfoque principal de éste es estimar la productividad de agua y así proponer la gestión agronómica para optimizar los recursos hídricos. Es un modelo de código cerrado, genérico de escala diaria y tiene en cuenta un balance hídrico en el suelo y la fisiología de la planta (Steduto et al., 2009; Raes et al., 2009). El modelo simula infiltración de agua, drenaje fuera de la zona de raíces, desarrollo de la zona de raíces y el dosel, la tasa de evaporación y transpiración, la producción de biomasa y el rendimiento de los cultivos limitados por agua. Es decir, simula la producción con limitaciones ya que considera ajustes por estrés hídrico. El modelo considera parámetros de cultivo, suelo y manejo. La temperatura del aire mínima y máxima, evapotranspiración de referencia (ET_o) y precipitaciones son las variables de entrada mínimas requeridas para la simulación (Figura 2.7).




Figura 2.7. Diagrama AquaCrop

El modelo AquaCrop se ha utilizado en el cultivo de frijol para simular cobertura (C), biomasa (Bio) y humedad en el suelo (HA) de frijol en Cuba y obtuvieron valores absolutos a los observados para los estadísticos: R^2 de 0.81; 0.95; 0.99; RMSE de 3.4; 0.45; 7.3; NRMSE de 19.3; 17.0; 7.0; EF de 0.80; 0.94; 0.63, índice de concordancia (d) de 0.95; 0.98; 0.92, para las variables C, Bio y HA respectivamente (Olivera et al., 2016).

Espadafor et al. (2017) presentaron una propuesta de calibración y evaluación del modelo AquaCrop para el cultivo de frijol en Davis, EE. UU. Simularon biomasa seca, cobertura, contenido de agua en el suelo, movimiento de agua en el suelo y evapotranspiración y rendimiento. Las predicciones de rendimiento en una amplia gama de valores (< 1 a 3.5 t ha^{-1}) fueron muy buenas, con un RMSE de 0.16 t ha^{-1} y una d de Willmott de 0.978. El modelo también predijo con precisión la ET estacional (RMSE = 40 mm, d = 0.930), así como también se evidenció al comparar

la ET medida con el lisímetro de 489 mm con la ET simulada con el lisímetro de 501 mm. También se simularon adecuadamente la cobertura del dosel y la curva de biomasa. Aunque la extracción total de agua del suelo se simuló adecuadamente, la distribución del agua del suelo simulada con la profundidad difería de los valores medidos en el tratamiento de tierras secas. Los autores concluyeron que AquaCrop puede ser usado para la simulación del rendimiento del cultivo de frijol en diferentes entornos, y enfatizamos el valor de los experimentos de campo cuidadosamente realizados para la validación de modelos de simulación de cultivos.

Jadhav et al. (2018) aplicaron el modelo para simular el rendimiento de varios cultivos en Maharashtra, India, incluido frijol con riego completo y riego deficitario del 10, 30 y 50% de reducción de agua. Los autores mencionan que el beneficio neto para las estrategias de déficit del 10, 30 y 50 por ciento fue de 23.67, 12.20 y -0.74 millones de rupias, respectivamente. Concluyeron que la estrategia de déficit del 10 por ciento fue mejor en suelos ligeros.

Magalhães et al. (2019) calibraron y evaluaron el modelo para simular crecimiento de materia seca y rendimiento para el cultivo de frijol bajo diferentes niveles de agua de riego en un clima húmedo de Brasil. El modelo mostró buen ajuste con raíz del error cuadrático medio (RMSE) de 3.88 y 3.38 t ha⁻¹, el índice de acuerdo de Willmott (d) de 5.14 y -4.40, el coeficiente de correlación (r) de 0.97 y 0.95 y la desviación porcentual de 15.54 y 5.89% para calibración y evaluación, respectivamente. El modelo mostró un buen desempeño entre los valores observados y simulados para el contenido de agua del suelo, la acumulación de biomasa seca y el rendimiento. Los autores concluyeron que el modelo puede ayudar a la toma de decisiones y al manejo del agua en cultivos de regadío.

Arce-Romero et al. (2020) aplicaron el modelo Aquacrop para modelar el rendimiento de varios cultivos incluido frijol con diferentes escenarios de cambio climático utilizando clima artificial en México. Los resultados sugirieron que el frijol podría tener decrementos de 10 a 40% en el norte del país y concluyen sobre la vulnerabilidad de la agricultura de temporal a los impactos del cambio climático.

Do et al. (2021) simulaban la productividad del agua (WP) y el rendimiento (Y) de frijol establecido en condiciones de riego deficitario en Kenia. Utilizaron riego completo (100% de ET_c) para calibrar y evaluaron AquaCrop con 80, 60 y 50% del requerimiento del riego. La mayor WP y menor reducción de rendimiento (2.4%), se observó en el tratamiento con 80%, esto significó un ahorro de agua de hasta un 20%, lo que se traduce en $750 \text{ m}^3 \text{ ha}^{-1}$. La mayor reducción de rendimiento (59.8%) se obtuvo en el tratamiento con 50% de la ET_c , junto con una caída en la WP. Es decir, el riego deficitario da como resultado una reducción sostenible del rendimiento con un ahorro de agua considerable para regar más tierras o utilizarse en otros lugares. Concluyeron en la necesidad de que Kenia adopte el riego deficitario para garantizar la seguridad alimentaria durante los períodos secos y, al mismo tiempo, garantizar el uso sostenible del agua.

Tornés-Olivera et al. (2021) utilizaron AquaCrop para simular cobertura foliar (CC) y biomasa seca aérea (B) y rendimiento (Y) en tratamientos que combinaron densidad de siembra y demanda evapotranspirativa (ET_c) ($T_1=0.07 \times 0.7 \text{ m}$ y 100%, $T_2=0.07 \times 0.7 \text{ m}$ y 80 % y $T_3=0.05 \times 0.55 \text{ m}$ y 100% para marco de plantación y ET_c respectivamente). El modelo simuló aceptablemente la CC al lograrse valores de R^2 (0.94, 0.94 y 0.92) y valores de d (0.87, 0.77 y 0.73) para los tres tratamientos, respectivamente. Sin embargo, no mostró buen ajuste para B, los menores valores se obtuvieron en T_1 con el $R^2 = 0.99$ y $d = 0.72$. Los autores mencionan que el rendimiento fue simulado de forma aceptable con $R^2 = 98.9$ y error absoluto medio (EAM) de 0.044.

Por otro lado, Tian et al. (2021) utilizó el modelo Agro-Hydrological & chemical and Crop systems simulator (AHC) (Xu et al., 2018) para predecir la respuesta del rendimiento de maíz, trigo y frijol a las cantidades de riego en diferentes años hidrológicos. AHC es un modelo de código cerrado que integra diferentes módulos (clima, riego, drenaje, balance de agua en el suelo, transporte de solutos y el modelo de cultivo EPIC). Los resultados mostraron que el error cuadrático medio (RMSE) del contenido de agua del suelo de trigo de invierno, maíz y frijol fue de 0.026 a $0.083 \text{ cm}^3 \text{ cm}^{-3}$, el error relativo medio (MRE) fue -11.0 -7.5% y el RMSE fue 9.1 -

33.3%, respectivamente. El coeficiente de determinación del rendimiento simulado y medido de trigo de invierno, maíz y frijol alcanzó 0.98. Los autores concluyeron que la cantidad optima de riego para frijol fue de 228, 247 y 300 mm para un año húmedo, normal y seco, respectivamente, en el distrito de riego Fenix en China.

2.5. Conclusiones

El código abierto y la disponibilidad de las ecuaciones de los procesos fisiológicos involucrados de los modelos de la familia Wageningen permite a los investigadores adaptarlos en acuerdo a sus necesidades de simulación, esta ventaja permite que haya una gran variedad de modelos con este enfoque, aunque su uso se limita a usuarios con conocimientos de programación, comparada con los modelos de la familia DSSAT que cuentan con una estructura unificada y versátil lo que permite su amplio uso.

En general los modelos encontrados en la literatura científica tienen problemas para simular el desarrollo del cultivo, sobre todo fechas de cambio de las etapas fenológicas.

No se han reportados trabajos de modelación y simulación dinámicas para el crecimiento y desarrollo del cultivo de frijol en México.

2.6. Literatura citada

- Abrahamsen, P., & Hansen, S. (2000). Daisy: an open soil-crop-atmosphere system model. *Environmental Modelling & Software*, 15(3), 313-330. doi: [https://doi.org/10.1016/S1364-8152\(00\)00003-7](https://doi.org/10.1016/S1364-8152(00)00003-7)
- Acosta-Gallegos, J. A., Vargas-Vazquez, P., & White, J. W. (1996). Effect of sowing date on the growth and seed yield of common bean (*Phaseolus vulgaris* L.) in highland environments. *Field Crops Research*, 49(1), 1-10. doi: [https://doi.org/10.1016/S0378-4290\(96\)01013-1](https://doi.org/10.1016/S0378-4290(96)01013-1)
- Acosta-Gallegos, J.A., Vargas-Vazquez, P., White, J.W., 1996. Effect of sowing date on the growth and seed yield of common bean (*Phaseolus vulgaris* L.) in highland environments. *Field Crops Research* 49: 1–10.
- Álvarez, P., Fischer, M., González, C., Mason-D'Croz, D., Moreno, P., Robertson, R., Rodríguez, J., Prager, S.D. 2016. Technology of drought tolerant beans. A case study in the series: Ex-ante impact assessment of agricultural technologies in the global food system. 2016. Unpublished.
- Annandale, J.G., Benadé, N., Jovanovic, N.Z., Steyn, J.M. and Du Sautoy, N. 1999. Facilitating irrigation scheduling by means of the Soil Water Balance model. Water Research Commission Report No. 753/1/99, Pretoria, South Africa.
- Arce Romero, A., Monterroso Rivas, A. I., Gómez Díaz, J. D., Palacios Mendoza, M. Á., Navarro Salas, E. N., López Blanco, J., & Conde Álvarez, A. C. (2020). Crop yield simulations in Mexican agriculture for climate change adaptation. *Atmósfera*, 33(3), 215-231.
- Beebe S.E. 2012. Common bean breeding in the tropics. *Plant Breeding Reviews* 36: 357–426.
- Beebe, S. E., Rao, I. M., Blair, M. W., & Acosta-Gallegos, J. (2013). Phenotyping common beans for adaptation to drought. *Frontiers Physiol.*, 4(35). <https://doi.org/10.3389/fphys.2013.00035>

- Beebe, S., Ramirez-Villegas, J., Álvarez, P., Ricaurte, J., Mora, A., Guerrero, A., & van de Berg, M. (2017). Modelación del frijol en Latinoamérica: JRC technical reports.
- Beebe, S., Ramirez-Villegas, J., Álvarez, P., Ricaurte, J., Mora, A., Guerrero, A., & van de Berg, M. (2017). Modelación del frijol en Latinoamérica: JRC technical reports.
- Bidogeza, J., Hoogenboom, G., Berensten, P., De Graaff, J., & Oude Lansink, A. (2012). Application of DSSAT crop models to generate alternative production activities under combined use of organic-inorganic nutrients in Rwanda. *Journal of Crop Improvement*, 26(3), 346-363.
- Boogaard, H.L., De Wit, A.J.W., te Roller, J.A., Van Diepen, C.A., 2014. *WOFOST CONTROL CENTRE 2.1; User's guide for the WOFOST CONTROL CENTRE 2.1 and the crop growth simulation model WOFOST 7.1.7*. Wageningen (Netherlands), Alterra, Wageningen University & Research Centre.
- Boons-Prins, E. R., G. H. J. De Koning, and C. A. Van Diepen. Crop-Specific Simulation Parameters for Yield Forecasting across the European Community. CABO-DLO [etc.], 1993.
- Boons-Prins, E., De Koning, G., & Van Diepen, C. (1993). Crop-specific simulation parameters for yield forecasting across the European Community: CABO-DLO [etc.].
- Boote, K., Prasad, V., Allen Jr, L., Singh, P., & Jones, J. (2018). Modeling sensitivity of grain yield to elevated temperature in the DSSAT crop models for peanut, soybean, dry bean, chickpea, sorghum, and millet. *European Journal of Agronomy*, 100, 99-109.
- Boote, K.J., Jones, J.W., Hoogenboom, G., Pickering, N.B., 1998. The CROPGRO Model for Grain Legumes. In: Tsuji, G.Y, Hoogenboom, G., Thornton, P.K. (Eds.), *The CROPGRO Model for Grain Legumes. Understanding Options for Agricultural Production* 99–128.
- Brisson, N., Gary, C., Justes, E., Roche, R., Mary, B., Ripoche, D., Zimmer, D., Sierra, J., Bertuzzi, P., Burger, P., Bussie're, F., Cabidoche, Y.-M., Cellier, P., Debaeke, P., Gaudille're, J.-P., Hénault, C., Maraux, F., Seguin, B., Sinoquet, H., 2003. An overview of the crop model STICS. *Eur. J. Agron.* 18, 309–332.
- Broughton, W. J., Hernández, G., Blair, M., Beebe, S., Gepts, P., & Vanderleyden, J. (2003). Beans (*Phaseolus* spp.) – model food legumes. *Plant and Soil*, 252(1), 55-128. doi: 10.1023/A:1024146710611
- CEDRSSA. (2020). Mercado del frijol, situacion y prospectiva (Vol. Febrero 2020, pp. 20). Camara de Diputados: Centro de Estudios para el Desarrollo Rural Sustentable y la Soberania Alimentaria.
- Chalabi, Z., & Zhou, W. (1994, September). Optimal control methods for agricultural systems. In II IFAC/ISHS Workshop: Mathematical & Control Applications in Agriculture & Horticulture 406 (pp. 221-228).
- Chaves de Oliveira, E. 2007. Desempenho do modelo CROPGRO-Dry Bean em estimar data de semeadura e a produtividade do feijoeiro. Tesis de Magisteria, Universidades Federal de Vicosa.
- Dallacort, R., Freitas, P. S. L. d., Faria, R. T., Goncalves, A. C. A., Rezende, R., & Guimaraes, R. M. L. (2011). Simulation of bean crop growth, evapotranspiration and yield in Paraná State by the CROPGRO-Drybean model. (Journal, Electronic).
- de Wit, A., Boogaard, H., Fumagalli, D., Janssen, S., Knapen, R., van Kraalingen, D., . . . van Diepen, K. (2019). 25 years of the WOFOST cropping systems model. *Agricultural Systems*, 168, 154-167. doi: <https://doi.org/10.1016/j.agsy.2018.06.018>
- Decision Support System for Agrotechnology Transfer (2021) <https://dssat.net/>
- Dewedar, O., Plauborg, F., Marwa, M., El-shafie, A., & Ragab, R. (2020). Improving water saving, yield, and water productivity of bean under deficit drip irrigation: Field and modelling study using the SALTMED model. *Irrigation and Drainage*.
- DO, R., Kosgei, J., & --, E. (2021). Using Drip Irrigation to Mitigate the Effects of Drought in Food Production: A Case Study of Production of Beans during Dry Spells in Uasin Gishu County, Kenya.
- Doorenbos, J., & Kassam, A. H. (1979). Yield response to water. *Irrigation and drainage paper*, 33, 257.
- Dos-Santos, M. G., Faria, R. T. D., Palaretti, L. F., Dantas, G. D. F., Dalri, A. B., & Lopes, A. D. S. (2016). Calibration and testing of CS-CROPGRO model for common beans. *Engenharia Agrícola*, 36(6), 1239-1249.

- Eitzinger, A., Läderach, P., Rodriguez, B., Fisher, M., Beebe, S., Sonder, K., Schmidt, A. 2017. Assessing high-impact spots of climate change: spatial yield simulations with Decision Support System for Agrotechnology Transfer (DSSAT) model. *Mitigation and Adaptation Strategies for Global Change* 22: 743-760. doi:10.1007/s11027-015-9696-2
- Espadafor, M., Couto, L., Resende, M., Henderson, D. W., Garcia-Vila, M., & Fereres, E. (2017). Simulation of the responses of dry beans (*Phaseolus vulgaris* L.) to irrigation. *Transactions of the ASABE*, 60(6), 1983-1994.
- FAO. 1979. Yield response to water by J. Doorenbos & A. Kassam. FAO Irrigation and Drainage Paper No. 33. Rome
- Faostat, F. A. O. (2021). Statistical databases. Food and Agriculture Organization of the United Nations, Retrieved from <http://www.fao.org/faostat/en/#data/QC/visualize/> Acceso, 2021
- Fernandez, F., Gepts, P. L., & López, M. (1985). Etapas de desarrollo en la planta de frijol. Programa de las Naciones Unidas (PNUD).
- Flores, M. L. (2015). El cultivo del frijol en México.
- Flores, R. V., & Retana, J. A. (2003). Validación de CROPGRO-Dry Bean, un modelo de simulación del crecimiento y desarrollo del cultivo de frijol en Los Chiles, Costa Rica.
- Graham, P. H., & Ranalli, P. (1997). Common bean (*Phaseolus vulgaris* L.). *Field Crops Res.*, 53(1), 131-146. [https://doi.org/10.1016/S0378-4290\(97\)00112-3](https://doi.org/10.1016/S0378-4290(97)00112-3)
- Heinemann, A.B., Ramirez-Villegas, J., Souza, T.L.P.O., Didonet, A.D., di Stefano, J.G., Boote, K.J., Jarvis, A., 2016. Drought impact on rainfed common bean production areas in Brazil. *Agricultural and Forest Meteorology* 225: 57–74.
- Hoogenboom, G., J. W. Jones, S. S. Jagtap, and K. J. Boote. 1986. Modeling growth and yield of beans, using soybean as an example. *Annual Report of the Bean Improvement Cooperative* vol. 29 (1985):127-129.
- Hoogenboom, G., J. W., Jones, S.S Jagtap, and K.J. Boote. (1986). Modeling growth and yield of beans, using soybean as an example. *Annu. Rep. Coop.* 29:49-51
- Hoogenboom, G., Porter, C., Boote, K., Shelia, V., Wilkens, P., Singh, U., . . . Jones, J. (2019). The DSSAT crop modeling ecosystem (pp. 173-216).
- Hoogenboom, G., White, J. W., & Messina, C. D. (2004). From genome to crop: integration through simulation modeling. *Field Crops Research*, 90(1), 145-163.
- Hoogenboom, G., White, J. W., Acosta-Gallegos, J., Gaudiel, R. G., Myers, J. R., & Silbernagel, M. J. (1997). Evaluation of a crop simulation model that incorporates gene action. *Agronomy Journal*, 89(4), 613-620.
- Hoogenboom, G., White, J. W., Jones, J. W., & Boote, K. J. (1991). Beangro V1. 01 dry bean crop growth simulation model: users guide: University of Florida, Department of Agricultural Engineering; International
- Hoogenboom, G., White, J.W., Jones, J.W., Boote, K.J., 1994b. BEANGRO: A process-oriented dry bean model with a versatile user interface. *Agronomy Journal* 86, 182 / 190.
- Horacio, E. H., Mota, J. H., & Teixeira, I. R. (2019). Monoculture and intercropping of beans and cassava. *Scientia Agraria Paranaensis*, 18(2), 132-138.
- Huang, J., Pan, J., Zhou, L., Zheng, D., Yuan, S., Chen, J., ... & Lin, W. (2020). An improved double-row rubber (*Hevea brasiliensis*) plantation system increases land use efficiency by allowing intercropping with yam bean, common bean, soybean, peanut, and coffee: A 17-year case study on Hainan Island, China. *Journal of Cleaner Production*, 263, 121493.
- Hwang, C., Correll, M., Gezan, S., Zhang, L., Bhakta, M., Vallejos, C., . . . Jones, J. (2017). Next generation crop models: A modular approach to model early vegetative and reproductive development of the common bean (*Phaseolus vulgaris* L). *Agricultural systems*, 155, 225-239.
- Jadhav, P., Thokal, R., Kadam, S., & Gorantiwar, S. (2018). Evaluation of AquaCrop model for irrigation planning in command area under changing climate.
- Jones, J. W., Hoogenboom, G., Porter, C. H., Boote, K. J., Batchelor, W. D., Hunt, L. A., . . . Ritchie, J. T. (2003). The DSSAT cropping system model. *European Journal of Agronomy*, 18(3), 235-265. doi: [https://doi.org/10.1016/S1161-0301\(02\)00107-7](https://doi.org/10.1016/S1161-0301(02)00107-7)
- Jones, J.W., Hoogenboom, G., Porter, C.H., Boote, K.J., Batchelor, W.D., Hunt, L., Wilkens, P.W., Singh, U., Gijsman, A.J., Ritchie, J.T., 2003. The DSSAT cropping system model. *Eur. J. Agron.* 18, 235–265.

- Jones, J.W.G., Hoogenboom, C.H., Porter, K.J., Boote, W.D., Batchelor, L.A., Hunt, P.W.W., Singh, U., Gijssman, A.J., Ritchie, J.T., 2003. The DSSAT cropping system model. *Eur. J. Agron.* 18, 235–265.
- Keating, B. A., & Thorburn, P. J. (2018). Modelling crops and cropping systems—evolving purpose, practice and prospects. *European journal of agronomy*, 100, 163-176.
- Keating, B.A., Carberry, P.S., Hammer, G.L., Probert, M.E., Robertson, M.J., Holzworth, D., Huth, N.I., Hargreaves, J.N.G., Meinke, H., Hochman, Z., McLean, G., Verburg, K., Snow, V., Dimes, J.P., Silburn, M., Wang, E., Brown, S., Bristow, K.L., Asseng, S., Chapman, S., McCown, R.L., Freebairn, D.M., Smith, C.J., 2003. An overview of APSIM, a model designed for farming systems simulation. *Eur. J. Agron.* 18, 267–288.
- Ma Y and Bliss F A 1978 Seed proteins of common bean. *Crop Sci.* 17, 431–437.
- Magalhães, I. D., Lyra, G. B., de Souza, J. L., Teodoro, I., da Rocha, A. E. Q., Cavalcante, C. A., . . . de Souza Ferraz, R. L. (2019). Performance of the Aquacrop model for bean ('Phaseolus vulgaris' L.) under irrigation condition. *Australian Journal of Crop Science*, 13(7), 1188.
- Marrou, H., Sinclair, T. R., & Metral, R. (2014). Assessment of irrigation scenarios to improve performances of Lingot bean (*Phaseolus vulgaris*) in southwest France. *European Journal of Agronomy*, 59, 22–28. doi:10.1016/j.eja.2014.05.006
- Mehanna, H., Pibars, S. K., & El-Noemani, A.-S. (2015). Validation of SALTMED Model under Different Water Regimes and N Fertilizer Rates for Snap Bean.
- Meireles, E. J. L., Pereira, A. R., Sentelhas, P. C., Stone, L. F., & Zimmermann, F. J. P. (2002). Calibration and test of the cropgro-dry bean model for edaphoclimatic conditions in the savanas of central Brazil. *Scientia Agricola*, 59(4), 723-729.
- Mittler R, Kim Y, Song L, Coutu J, Coutu A, Ciftci-Yilmaz S, Zhu JK. Gain-and loss-of-function mutations in *Zat10* enhance the tolerance of plants to abiotic stress. *FEBS letters*. 2006;580(28):6537-6542. Doi: 0.1016/j.febslet.2006.11.002.
- Mompremier, R., Her, Y., Hoogenboom, G., Migliaccio, K., Muñoz-Carpena, R., Brym, Z., . . . Jeune, W. (2021). Modeling the response of dry bean yield to irrigation water availability controlled by watershed hydrology. *Agricultural Water Management*, 243, 106429.
- Munz, S., Claupein, W., & Graeff-Hönninger, S. (2014). Growth of Bean Strip-Intercropped with Maize: Evaluation of the CROPGRO Model. *Agronomy Journal*, 106(6), 2235-2247.
- Nassary, E. K., Bajjukya, F., & Ndakidemi, P. A. (2020). Productivity of intercropping with maize and common bean over five cropping seasons on smallholder farms of Tanzania. *European Journal of Agronomy*, 113, 125964.
- O'Callaghan, J. R., Hossain, A. H. M. S., Dahab, M. H., & Wyseure, G. C. L. (1994a). SODCOM: a solar driven computational model of crop growth. *Computers and Electronics in Agriculture*, 11(4), 293-308. doi: [https://doi.org/10.1016/0168-1699\(94\)90021-3](https://doi.org/10.1016/0168-1699(94)90021-3)
- O'Callaghan, J. R., Maende, C., & Wyseure, G. C. L. (1994b). Modelling the intercropping of maize and beans in Kenya. *Computers and Electronics in Agriculture*, 11(4), 351-365. doi: 10.1016/0168-1699(94)90026-4
- Oliveira, E. C. d., Costa, J. M. N. d., Paula Júnior, T. J. d., Ferreira, W. P. M., Justino, F. B., & Neves, L. d. O. (2012). The performance of the CROPGRO model for bean (*Phaseolus vulgaris* L.) yield simulation. *Acta Scientiarum. Agronomy*, 34(3), 239-246.
- Olivera, N. T., Manrique, O. B., Masjuan, Y. G., & Alega, A. M. G. (2016). Evaluation of AquaCrop model in crop dry bean growth simulation. *Revista Ciencias Técnicas Agropecuarias*, 25(3), 23-30.
- Osorio, R. J. (2014). Aplicación del modelo DSSAT en cultivos de frijol en El Guayabo y Campus de la EAP Zamorano, Honduras.
- Raes, D., Steduto, P., Hsiao, T. C., Fereres, E., Izzi, G., & Heng, L. K. (2010). AquaCrop (version 3.1) reference manual. FAO, Rome.
- Ragab, R. (2002). A holistic generic integrated approach for irrigation, crop and field management: the SALTMED model. *Environmental Modelling & Software*, 17(4), 345–361. doi:10.1016/s1364-8152(01)00079-2
- Seidel, S. J., Rachmilevitch, S., Schütze, N., & Lazarovitch, N. (2016). Modelling the impact of drought and heat stress on common bean with two different photosynthesis model approaches. *Environmental Modelling & Software*, 81, 111-121.

- Soltani, A., Sinclair, T.R., 2012. Modeling Physiology of Crop Development, Growth and Yield. CABI, Wallingford, Oxfordshire, UK.
- Staggenborg, S.A., Vanderlip, R.L., 2005. Crop simulation models can be used as dryland cropping systems research tools. *Agron. J.* 97, 378–384.
- 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(3), 426–437. doi: <https://doi.org/10.2134/agronj2008.0139s>
- Stöckle, C.O., Donatelli, M., Nelson, R., 2003. CropSyst, a cropping systems simulation model. *Eur. J. Agron.* 18, 289–307.
- Supit, I. Hooijer, A.A., Diepen, C.A. van, 1994. System description of the WOFOST 6.0 crop simulation model implemented in CGMS. Volume 1: Theory and Algorithms. Report EUR 15956, Joint Research Centre, European Commission, Luxembourg
- Tian, L., Wang, J., Li, J., Li, Y., & Guo, X. (2021). Simulation of Optimal Irrigation Amount for Main Crops in different hydrological years of Fenxi Irrigation District, Shanxi Province, China. Paper presented at the 2021 ASABE Annual International Virtual Meeting.
- Tornés Olivera, N., Gómez Masjuan, Y., Boicet Fabr , T., & Brown Manrique, O. (2021). Evaluaci n del modelo AquaCrop en condiciones de riego  ptimo y deficitario en *Phaseolus vulgaris*. *Centro Agr cola*, 48(2), 37–46.
- Thornley, J.H.M., France, J. (2007). Mathematical models in agriculture. Quantitative methods for the plant, animal and ecological sciences. CABI. 906 pp.
- Tsubo, M., Walker, S., & Ogindo, H. (2005a). A simulation model of cereal–legume intercropping systems for semi-arid regions: I. Model development. *Field Crops Research*, 93(1), 10–22.
- Tsubo, M., Walker, S., & Ogindo, H. O. (2005b). A simulation model of cereal–legume intercropping systems for semi-arid regions: II. Model application. *Field Crops Research*, 93(1), 10–22. doi: <https://doi.org/10.1016/j.fcr.2004.09.002>
- van Ittersum, M. K., Leffelaar, P. A., van Keulen, H., Kropff, M. J., Bastiaans, L., & Goudriaan, J. (2003). On approaches and applications of the Wageningen crop models. *European journal of agronomy*, 18(3–4), 201–234.
- van Keulen, EL & Wolf, J. (Eds) 1986. Modelling of ugricultural production: weather, soil and crops. Simulation Monographs, PUDOC, Wageningen.
- Van Keulen, H., Penning de Vries, EW.T. and Drees, E.M. (1982) A summary model for crop growth. In: EW.T. Penning de Vries and H.H. Laar (Editors), *Simulation of Plant Growth and Crop Production*. Simulation Monograph, Pudoc, Wageningen, pp. 87–99.
- Van Laar, H. H., Goudriaan, J., & Van Keulen, H. (1992). Simulation of crop growth for potential and water-limited production situations: as applied to spring wheat (No. 27). CABO-DLO.
- Van Loon, M. P., Deng, N., Grassini, P., Rattalino Edreira, J. I., Wolde-meskel, E., Bajjukya, F., ... van Ittersum, M. K. (2018). Prospect for increasing grain legume crop production in East Africa. *European Journal of Agronomy*, 101, 140–148. doi:10.1016/j.eja.2018.09.004
- Vance C P 1997 Enhanced agricultural sustainability through biological nitrogen fixation. In *Biological Nitrogen Fixation for Ecology and Sustainable Agriculture*. NATO ASI Series, Vol G 39. Eds. A Legocki, H Bothe and A Puhler. pp. 179–186. Springer-Verlag, Berlin, Heidelberg.
- Verdoodt, A., Van Ranst, E., & Ye, L. (2004). Daily simulation of potential dry matter production of annual field crops in tropical environments. *Agronomy Journal*, 96(6), 1739–1753.
- Wang, J., Li, X., Lu, L., Fang, F., 2013. Parameter sensitivity analysis of crop growth models based on the extended Fourier Amplitude Sensitivity Test method. *Environ. Model. Softw.* 48, 171–182.
- Webber, H., Madramootoo, C., Bourgault, M., Horst, M., Stulina, G., & Smith, D. (2010). Adapting the CROPGRO model for saline soils: the case for a common bean crop. *Irrigation science*, 28(4), 317–329.
- White, J. W., & Hoogenboom, G. (1996). Simulating effects of genes for physiological traits in a process-oriented crop model. *Agronomy Journal*, 88(3), 416–422.
- White, J. W., & Hoogenboom, G. (2003). Gene-based approaches to crop simulation: Past experiences and future opportunities. *Agronomy Journal*, 95(1), 52–64.

- White, J. W., Hoogenboom, G., Jones, J. W., & Boote, K. J. (1995). Evaluation of the dry bean model BEANGRO V1. 01 for crop production research in a tropical environment. *Experimental Agriculture*, 31(2), 241-254.
- Xu, X., Sun, C., Neng, F., Fu, J., & Huang, G. (2018). AHC: An integrated numerical model for simulating agroecosystem processes—Model description and application. *Ecological Modelling*, 390, 23-39. doi: <https://doi.org/10.1016/j.ecolmodel.2018.10.015>
- Yuan, M., Ruark, M. D., & Bland, W. L. (2017). A simple model for snap bean (*Phaseolus vulgaris* L.) development, growth and yield in response to nitrogen. *Field Crops Research*, 211, 125-136.
- Zamora, D. S., Jose, S., Jones, J. W., & Cropper, W. P. (2009). Modeling cotton production response to shading in a pecan alley cropping system using CROPGRO. *Agroforestry Systems*, 76(2), 423-435.
- Zhao, C., Liu, B., Xiao, L., Hoogenboom, G., Boote, K. J., Kassie, B. T., . . . Asseng, S. (2019). A SIMPLE crop model. *European Journal of Agronomy*, 104, 97-106. doi: <https://doi.org/10.1016/j.eja.2019.01.009>
- Zúñiga, E. C. T., Cruz, I. L. L., & García, A. R. (2014). Parameter estimation for crop growth model using evolutionary and bio-inspired algorithms. *Applied Soft Computing*, 23, 474-482.

III.- ANÁLISIS DE INCERTIDUMBRE Y SENSIBILIDAD ESPACIOTEMPORAL DEL MODELO PARA CRECIMIENTO DE CULTIVOS SIMPLE APLICADO AL CULTIVO DE FRIJOL

4

3.1.- Resumen

Los modelos de simulación son usados para estimar, pronosticar, optimizar e identificar factores limitantes y analizar cambios en la producción de los cultivos. Con el fin de obtener un modelo matemático funcional y confiable es necesario conocer la fuente de incertidumbre, e identificar los parámetros más influyentes. Los objetivos de este estudio fueron llevar a cabo un análisis de incertidumbre (UA) y un análisis de sensibilidad (SA) global espaciotemporal para los parámetros del modelo SIMPLE, el cual utiliza 13 parámetros tiene dos variables de estado y utiliza datos climáticos diarios para simular crecimiento y desarrollo de los cultivos. Para el UA se realizó una simulación Monte Carlo y para SA se utilizó el método de Sobol. Se analizaron cuatro estaciones que representan las condiciones climáticas de las distintas áreas de producción de frijol en Zacatecas, México y una serie histórica de cuatro años de cada estación para cultivo del frijol de riego y seco. Para la condición de seco, el modelo sobreestimó la biomasa y el rendimiento siendo 29.4% superiores al frijol cultivado bajo riego. La distribución del tiempo térmico fue uniforme en ambos sistemas de producción. Los parámetros más influyentes para riego fueron $T_{sum} < S_{water} < T_{base} < T_{opt} < I_{50A}$. Para el frijol de seco, $T_{sum} < T_{base} < I_{50A} < T_{opt}$, $S_{water} < RUE$, el parámetro I_{50A} fue más influyente, S_{water} baja su importancia y RUE se considera como parámetro influyente. La precipitación, la temperatura acumulada requerida de siembra a madurez (T_{sum}) y el rendimiento fueron los componentes más importantes a considerar para la simulación de crecimiento y desarrollo de frijol para regiones áridas y semiáridas.

⁴ Tesis de Doctorado en Ingeniería, Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Miguel Servin Palestina

Director: Irineo L. López Cruz, PhD

Palabras Clave:

Modelo dinámico, Simulación, Clima árido, frijol (*Phaseolus vulgaris* L.)

Highlights

El modelo SIMPLE predice en forma aceptable biomasa y rendimiento en condiciones de riego y secano en el cultivo de frijol.

La precipitación, la temperatura acumulada requerida de siembra a madurez (Tsum) y el rendimiento, son los factores más significativos para la simulación de crecimiento y desarrollo de frijol con el modelo SIMPLE.

Tsum, Swater, Tbase, I50A, Topt y RUE son los parámetros del modelo SIMPLE que influyen en mayor medida al simular el crecimiento y desarrollo de frijol en condiciones de clima árido y semiárido.

3.2.- Introducción

En México, el frijol (*Phaseolus vulgaris* L.) es considerado como prioritario en la seguridad alimentaria nacional, es básico en la dieta de la población por su alto contenido de proteína, (Hayat et al., 2014). El consumo per cápita es de 8 kg (INEGI, 2012). El estado de Zacatecas es el principal productor de frijol en México, donde se siembra una superficie anual de 603 mil ha con una producción de 330 mil t que provienen de 25 mil ha de riego y 578 mil ha de secano. los rendimientos son, en promedio su ubican entre 1.12 y 2.35 t ha⁻¹ y de 0.22 a 0.69 t ha⁻¹ de frijol bajo riego y secano, respectivamente (SIAP, 2020).

La variabilidad espacial y temporal, de la precipitación, las condiciones climáticas y los diferentes manejos del cultivo (e.g., riego, fertilización y labores culturales) requieren de herramientas que integren todos los componentes (cultivo, clima,

manejo, suelo, etc.) de los sistemas de producción para hacerlos más eficientes. La producción de los cultivos puede simularse con modelos matemáticos de crecimiento y desarrollo, y así, estimar el crecimiento potencial, alcanzable y real (van Ittersum et al., 2003; Thornley y France, 2007).

Los modelos de simulación son usados para estimar la producción, pronosticar la disponibilidad de grano a escala regional, identificar factores limitantes de la producción y analizar cambios en el manejo de los cultivos (López et al., 2005). Asimismo, se pueden establecer fechas y densidades óptimas de siembra para cada condición climática donde se pretende desarrollar un cultivo (Keating & Thorburn, 2018). Con el fin de obtener un modelo matemático funcional y confiable es importante llevar a cabo el procedimiento general de modelación de sistemas propuesto en la Teoría de Sistemas Dinámicos (Ljung & Glad; 1994; Voinov, 2010; Wallach et al., 2019). Esto incluye calibración y evaluación, en estas etapas es necesario conocer la fuente de incertidumbre, e identificar los parámetros de mayor relevancia en el comportamiento del sistema.

El UA y el SA permiten conocer la fuente de incertidumbre y la sensibilidad de los parámetros de un modelo matemático, variables de entrada, condiciones iniciales y estructura matemática (Saltelli et al., 2006). Un SA se utiliza para cuantificar el peso de las relaciones de entrada-salida de los modelos matemáticos, mientras que el UA se utiliza para evaluar la propagación de la incertidumbre de las entradas sobre las salidas del modelo (Saltelli et al., 2004).

Para el UA normalmente se utiliza estadística descriptiva de las variables de salida, obtenidas mediante la simulación Monte Carlo (MC). Algunos autores han utilizado los UA para identificar los efectos del clima sobre los cultivos en los modelos: STICS (Coucherey et al., 2015), WOFOST (Ceglar et al., 2012), CROPSYST (Eitzinger et al., 2012), DSSAT-CERES (Rötter et al., 2012), AquaCrop (Fleisher et al., 2016), Web InfoCrop (Krishnan et al., 2021).

Para los SA de los parámetros se han utilizado diferentes alternativas como: 1) el método de coeficientes de correlación (CC) en el módulo SALUS del modelo DSSAT (DZotsi et al., 2013), 2) el método de coeficiente de regresión estandarizado (CRE)

en el modelo ORYZA (Tan et al., 2017), 3) el método de efectos elementales o Morris (ETT) en el modelo CERES-DSSAT (DeJonge et al., 2012; Corbeels et al., 2016) y AquaCrop (Silvestro et al., 2017), 4) el método basado en varianza en los modelos CERES-DSSAT (DeJonge et al., 2012) y APSIM (Zhao et al., 2014), 5) el método prueba de sensibilidad de amplitud de Fourier (FAST) en el modelo WOFOST (Wang et al., 2013), APSIM (Zhao et al., 2014) y AquaCrop (Silvestro et al., 2017; Guo et al., 2020), todos los anteriores se han utilizado para identificar la sensibilidad de los parámetros. Los UA y SA se debe llevar a cabo de manera conjunta y con una serie de datos lo suficiente grande distribuidos espacial y temporalmente (Saltelli et al., 2019).

El modelo de crecimiento y desarrollo de cultivos SIMPLE es una herramienta genérica evaluada en 14 cultivos (Zhao et al., 2019). Este modelo fue desarrollado para uso regional y utiliza únicamente 13 parámetros. Hasta donde se sabe, un UA o SA no han sido reportados para este modelo aplicado a un cultivo de frijol (*Phaseolus vulgaris* L.). Por consiguiente, los objetivos de este estudio fueron: 1) llevar a cabo un análisis de incertidumbre espacio-temporal de los parámetros del modelo SIMPLE y 2) Realizar un análisis de sensibilidad global para los parámetros del modelo SIMPLE con en el método de Sobol basado en el cálculo de la varianza para el cultivo de frijol bajo condiciones de riego y seco.

3.3.- Materiales y Métodos

3.3.1.- Colección de datos

Los datos climáticos diarios de temperatura máxima (T_{max} , °C), mínima (T_{min} , °C), radiación solar (R_s , Wm^{-2}), precipitación (PP, mm) y evapotranspiración referencia (ETo , mm), se obtuvieron de cuatro estaciones meteorológicas automatizadas Adcon® del Campo Experimental Zacatecas (CEZAC) del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP). Las estaciones están ubicadas en las zonas productoras de frijol del estado de Zacatecas como sigue: 1.- CEZAC (-102.659° O, 22.909° N) ubicada en Calera de Víctor Rosales (CEZAC), 2.- Gonzáles Ortega (-103.452° O, 23.903° N) ubicada en Rio Grande (GONOR), 3.- Colonia Emancipación (-103.036° O, 23.217° N) ubicada en Fresnillo (EMAN), y

4.- El Alpino (-102.289° O, 22.517° N) ubicada en Ojocaliente (ALPINO) (Medina et al., 2007). Las estaciones utilizadas representan las condiciones climáticas de cada distrito de desarrollo rural (DDR). Los cuatro DDR albergan más del 98% de superficie sembrada y producción de frijol (SIAP, 2020). Para cada una de las estaciones se analizaron los datos de cuatro años distribuidos temporalmente y equidistantes (2005, 2010, 2015 y 2020). Para cada año y por estación se realizó un UA y SA para el cultivo de frijol bajo riego y seco. Esto generó un total de 32 escenarios. Para las simulaciones en riego se utilizó un calendario de riego como variable de entrada del modelo, el cual, se estimó mediante un balance hídrico climático. El cultivo de frijol de riego en Zacatecas se siembra en la primera quincena de abril, después de las heladas de invierno, mientras que el frijol de seco la fecha límite de siembra está entre el 10 y 15 de julio (Medina et al., 2003), Cid et al. (2014) mencionan que la siembra es efectuada en junio y julio cuando se presentan las primeras precipitaciones. Por tal razón, las simulaciones se iniciaron el 15 de abril y 01 de julio para los escenarios de riego y seco, respectivamente. Los valores nominales de los 13 parámetros del modelo SIMPLE se obtuvieron de la literatura disponible para el cultivo de frijol.

3.3.1.1.- Calendario de riego

La calendarización del riego se realizó con la metodología del “Sistema para programar y calendarizar el riego de los cultivos en tiempo real” (Servín et al., 2017), basada en la ecuación del balance de agua en el suelo. El contenido de agua del suelo en un día particular (θ_i , mm), se estimó con base en el contenido de agua del día previo (θ_{i-1}).

$$\theta_i = \theta_{i-1} + R_i + Pe_i - ETc_i \quad (1)$$

donde el R_i es el riego del día particular (mm), Pe_i es la precipitación efectiva del día particular (mm), ETc_i es la evapotranspiración del cultivo del día particular (mm día⁻¹).

El balance hídrico se inició el 15 de abril para los años 2005, 2010, 2015 y 2020. El suelo se llevó a capacidad de campo, considerando una textura media con 0.15 y

0.30 (mm³ mm⁻³) para punto de marchites permanente (W_{WP}) y capacidad de campo (W_{FC}), respectivamente y una profundidad radicular (Z) de 600 mm. Cuando la ETc acumulada fue igual o mayor al 40% del abatimiento máximo permisible de agua aprovechable en el suelo (FAM), es decir, se alcanzó al punto crítico (W_c , mm³ mm⁻³) (Ecuación 2) y se aplicó la lámina de riego neta (Ln , mm) (Ecuación 3).

$$W_c = W_{FC} - \frac{FAM}{100} (W_{FC} - W_{WP}) \quad (2)$$

$$Ln = (W_{FC} - W_c) Pr \quad (3)$$

donde Ln es la lámina neta (mm), aplicada cada que se abatía en 40% de agua aprovechable.

Para estimar el ETc (ecuación 4), el coeficiente de cultivo (K_c) para frijol se estimó con la Ecuación 5 (Servin et al., 2017):

$$ETc = K_c \cdot ETo \quad (4)$$

$$K_c = -3.4829x^3 + 4.5973x^2 - 0.8725x + 0.3786 \quad (5)$$

donde ETo es evapotranspiración referencia estimada por el método Penman-Monteith (Allen et al., 2006), x es la de fracción de ciclo vegetativo estimada con el tiempo térmico, donde 0 y 1 se refiere a la siembra y 1 a la madurez fisiológica del cultivo.

3.3.2.- Modelo de crecimiento de cultivos SIMPLE

El modelo dinámico SIMPLE (Figura 1), en tiempo discreto, propuesto por Zhao et al. (2019), simula el crecimiento, el desarrollo y el rendimiento de cultivos utilizando un paso de tiempo diario. El modelo está basado en la interceptación de la radiación, considera el efecto de la temperatura diaria, el estrés por calor, la disponibilidad de agua (lluvia y riego) y el CO₂ atmosférico (Zhao et al., 2019). El tiempo térmico (TTi, °C d-1), la producción de biomasa seca (Bio, t ha-1) son las variables de estado. En tanto el rendimiento de grano (Y en t ha-1) se considera como variable de salida. El modelo SIMPLE requiere de 13 parámetros (Tabla 1), nueve de especies para especificar tipos de cultivos y cuatro de cultivares que caracterizan las diferentes

variedades. Las ecuaciones en diferencias para las variables de estado del modelo SIMPLE se describen a continuación, las ecuaciones auxiliares se describen ampliamente en Zhao et al. (2019).




Figura 3.1. Diagrama del modelo de crecimientos de cultivos SIMPLE, las variables de estado se representan por rectángulos, las tasas de cambio por válvulas, los parámetros con una línea horizontal y un círculo con relleno negro, las variables de entrada un círculo y una línea horizontal y las variables auxiliares con circunferencias. Los flujos de material se representan mediante flechas normales y los flujos de información con líneas discontinuas

3.3.2.1.- Tiempo térmico

El modelo SIMPLE utiliza la temperatura acumulada para determinar el desarrollo fenológico, se calcula de la siguiente manera:

$$TT_{i+1} = TT_i + \Delta TT \quad (6)$$

$$\Delta TT = \begin{cases} T - T_{base}; & T > T_{base} \\ 0 & ; T \leq T_{base} \end{cases} \quad (7)$$

donde TT_i (°C) tiempo térmico o temperatura media acumulada para el i -ésimo día y ΔTT es el incremento diario en temperatura. T (°C) es la temperatura media diaria y T_{base} (°C) es la temperatura base para el desarrollo fenológico de los cultivos.

3.3.2.2.- Biomasa

El crecimiento de biomasa se basa en el concepto de eficiencia en el uso de la radiación (Monteith, 1965), la cual asume que una fracción de la radiación diaria fotosintéticamente activa es interceptada por el dosel de la planta y se traduce en biomasa de cultivos.

$$Bio_{i+1} = Bio_i + \Delta Bio \quad (8)$$

$$\Delta Bio = R_s \cdot f_{Solar} \cdot RUE \cdot f(CO_2) \cdot f(Temp) \cdot \min[f(Heat), f(Water)] \quad (9)$$

donde: ΔBio es la tasa de biomasa o crecimiento diario de la biomasa ($t \text{ ha}^{-1} \text{ día}^{-1}$), y Bio_{i+1} es la biomasa acumulada hasta madurez fisiológica ($t \text{ ha}^{-1}$). f_{Solar} es la fracción de la radiación solar interceptada por un dosel de cultivo, y RUE es la eficiencia del uso de la radiación. $f(heat)$, $f(CO_2)$, $f(Temp)$ y $f(water)$ son el estrés por calor, el impacto del CO_2 , el impacto de la temperatura y el estrés por sequía en el crecimiento de la biomasa, respectivamente.

Por otro lado, el rendimiento del grano se calcula como el producto de la biomasa total acumulada ($Bio - cum_{maturity}$) y el índice de cosecha (HI) (Amir y Sinclair, 1991).

$$Y = Bio - cum_{maturity} \times HI \quad (10)$$

El modelo simula el rendimiento alcanzable limitado por agua, calcula el estrés hídrico en base al agua disponible en el suelo y la evapotranspiración de referencia, usando el índice estandarizado de sequía (ARID), descrito ampliamente por Woli et al., (2012).

3.3.3 Análisis de incertidumbre (UA)

El UA se realizó mediante simulación Monte Carlo (SMC). Esta técnica estadística infiere las características operacionales del sistema, mediante la sustitución de valores de la estradas, parámetros o valores iniciales, se usa en el modelado estocástico y el análisis de la propagación de errores de cálculo, su objetivo es trazar la estructura de las distribuciones de probabilidad de las variables de salida del modelo, estas distribuciones se mapean cuantificando los resultados

deterministas para un gran número de muestreos aleatorios insesgados (Matott et al., 2009) a partir de la función de distribución individual del factor de entrada y los parámetros del modelo (Monod et al., 2006). La SMC básicamente considera lo siguiente: 1) muestreo de variables aleatorias de entrada a partir de funciones de densidad de probabilidad (PDF), 2) calcula la salida determinista para cada valor de entrada muestreado, 3) determina estadísticas de la distribución de salida (media, varianza, asimetría, curtosis) (Walters and Huyse, 2002).

Las ecuaciones del modelo SIMPLE fueron resueltas de manera iterativa. La ejecución de la simulación se realizó con las variables de entrada (Tmax, Tmin, Rg, PP, CO₂, Riego y ETo) de cada escenario; mientras que los vectores de parámetros θ fueron seleccionados con un muestreo de hipercubo latino (LHS) de funciones de densidad de probabilidad (PDF) individualmente uniformes. Estas fueron obtenidas aplicando 20% de incertidumbre para los límites inferior y superior sobre los valores nominales, evitando el traslape de las temperaturas cardinales (**Tabla 2**).

Se realizaron 5,000 (N) simulaciones para cada escenario, hasta que las medias y las varianzas convergieron. Posteriormente, para las variables simuladas, se obtuvo el valor final para las N simulaciones y se calcularon los siguientes estadísticos: media, desviación estándar, coeficiente de variación, asimetría y curtosis.

Finalmente, los estadísticos para las cuatro estaciones de los cuatro años se promediaron y se agruparon por estación (análisis espacial) y por año (análisis temporal).

3.3.6.- Análisis de sensibilidad global

Los métodos de análisis de sensibilidad basados en la varianza (VBSA), por su confiabilidad, usan la descomposición de la varianza según Sobol' (1990). Este autor, utiliza dos índices de sensibilidad para cada factor de entrada, el índice de primer orden y el índice de efectos totales. Este último incluye el efecto principal más las interacciones (Saltelli et al., 2008).

Para este trabajo, el objetivo del SA fue determinar la sensibilidad de los 13 parámetros sobre las variables TT, Bio y Y. Por lo tanto, se generaron las matrices

A y B (11) independientes y de dimensiones (N, k) con un muestreo y un re-muestreo LHS de las PDF's generadas en el UA para cada parámetro, respectivamente.

$$A = \begin{bmatrix} \theta_1^{(1)} & \theta_2^{(1)} & \theta_3^{(1)} & \dots & \theta_k^{(1)} \\ \theta_1^{(2)} & \theta_2^{(2)} & \theta_3^{(2)} & \dots & \theta_k^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ \theta_1^{(N)} & \theta_2^{(N)} & \theta_3^{(N)} & \dots & \theta_k^{(N)} \end{bmatrix} \quad B = \begin{bmatrix} \theta_1^{(N+1)} & \theta_2^{(N+1)} & \theta_3^{(N+1)} & \dots & \theta_k^{(N+1)} \\ \theta_1^{(N+2)} & \theta_2^{(N+2)} & \theta_3^{(N+2)} & \dots & \theta_k^{(N+2)} \\ \dots & \dots & \dots & \dots & \dots \\ \theta_1^{(2N)} & \theta_2^{(2N)} & \theta_3^{(2N)} & \dots & \theta_k^{(2N)} \end{bmatrix} \quad (11)$$

donde N=5,000 simulaciones y θ son del 1 al k-ésimo parámetro (K=13). Posteriormente se generaron las matrices C_i formada por todas las columnas de B excepto la k-ésima columna, que es tomado de A y D_i formada por todas las columnas de A excepto la k-ésima columna, que es tomado de B.

$$C_i = \begin{bmatrix} \theta_1^{(1)} & \theta_2^{(N+1)} & \theta_3^{(N+1)} & \dots & \theta_k^{(N+1)} \\ \theta_1^{(2)} & \theta_2^{(N+2)} & \theta_3^{(N+2)} & \dots & \theta_k^{(N+2)} \\ \dots & \dots & \dots & \dots & \dots \\ \theta_1^{(N)} & \theta_2^{(2N)} & \theta_3^{(2N)} & \dots & \theta_k^{(2N)} \end{bmatrix} \quad D_i = \begin{bmatrix} \theta_1^{(N+1)} & \theta_2^{(1)} & \theta_3^{(1)} & \dots & \theta_k^{(1)} \\ \theta_1^{(N+2)} & \theta_2^{(2)} & \theta_3^{(2)} & \dots & \theta_k^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ \theta_1^{(N+N)} & \theta_2^{(N)} & \theta_3^{(N)} & \dots & \theta_k^{(N)} \end{bmatrix} \quad (12)$$

Posteriormente, se calculó el área bajo la curva de las variables (TT, Bio y Y) del modelo, cambiando el vector de θ de las matrices A, B, C_i y D_i , de lo cual, se derivó:

$$y_A = f(A), \quad y_B = f(B), \quad y_{C_i} = f(C_i), \quad y_{D_i} = f(D_i) \quad (13)$$

Finalmente, los índices de primer orden S_i y de efecto total S_{Ti} fueron calculado como sigue:

$$S_i = \frac{V(E(Y|X_i))}{V(Y)} = \frac{\bar{V}_i - \hat{f}_0^2}{\bar{V} - \hat{f}_0^2} = \frac{\frac{1}{2N} \left(\sum_{j=1}^N y_A^{(j)} y_{C_i}^{(j)} + \sum_{j=1}^N y_B^{(j)} y_{D_i}^{(j)} \right) - \hat{f}_0^2}{\frac{1}{2N} \sum_{j=1}^N \left((y_A^{(j)})^2 + (y_B^{(j)})^2 \right) - \hat{f}_0^2} \quad (14)$$

donde $V(E(Y|X_i))$ es la varianza del i-ésimo factor, el $V(Y)$ representa la varianza total y $\hat{f}_0^2$ es la media expresada de la siguiente manera:

$$\hat{f}_0^2 = \left(\frac{1}{2N} \sum_{j=1}^N (y_A^{(j)} + y_B^{(j)}) \right)^2 \quad (15)$$

Para S_{Ti} se utiliza un estimador propuesto por Jansen (1999) y Saltelli et al. (2010) en la Ecuación (16):

$$S_{Ti} = \frac{\frac{1}{N} \sum_{j=1}^N (y_A^{(j)} - y_{D_i}^{(j)})^2}{\frac{1}{N} \sum_{j=1}^N \left((y_A^{(j)})^2 + (y_{D_i}^{(j)})^2 \right) - \left(\frac{1}{N} \sum_{j=1}^N y_A^{(j)} \right)^2 - \left(\frac{1}{N} \sum_{j=1}^N y_{D_i}^{(j)} \right)^2} \quad (16)$$

Los índices de primer orden S_i y de efecto total S_{Ti} se estimaron para las cuatro estaciones y se agruparon por estación (análisis espacial) y por año (análisis temporal).

El modelo y los métodos de UA y SA, así como el balance de agua en el suelo para obtener el calendario de riego fueron codificados en MATLAB®. Las 5000 simulaciones se determinaron por un análisis de convergencia basado en la simulación con valores de N de 1,500 hasta 10,000 cuando la media y la varianza de las variables se estabilizaron. Los valores nominales utilizados para los parámetros se muestran en la Tabla 1. En este estudio se consideraron como parámetros influyentes aquellos con valores superiores a 10.

Tabla 3.1. Valores nominales de los de los parámetros utilizados en el modelo SIMPLE para el cultivo de frijol variedad Pinto Saltillo.


Parámetro	Descripción	Unidades	Max	Min	Fuente
T_{sum}	Temperatura acumulada de siembra a madurez	°C día	960	1440	B-G
HI	Índice de cosecha	--	0.288	0.432	B-G
I_{50A}	Temperatura acumulada requerida para el desarrollo del área foliar para interceptar el 50% de la radiación	°C día	360	540	Z
I_{50B}	Temperatura acumulativa hasta la madurez para alcanzar el 50% de intercepción de radiación debido a la senescencia de la hoja	°C día	160	240	-
T_b	Temperatura base para el desarrollo y crecimiento de la fenología	°C	6.4	9.6	B-G
T_{opt}	Temperatura óptima para el crecimiento de la biomasa	°C	22	32	B-G
RUE	Eficiencia de uso de radiación (solo sobre el suelo y sin respiración)	G MJ ⁻¹ m ⁻²	2.568	3.852	K
I_{50maxH}	Reducción diaria máxima en I_{50B} debido al estrés por calor	°C día	72	108	Z
I_{50maxW}	Reducción diaria máxima en I_{50B} debido al estrés por sequía	°C día	16	24	Z
T_{max}	Temperatura umbral para comenzar a acelerar la senescencia del estrés por calor	°C	32.1	42	O
T_{ext}	Umbral de temperatura extrema cuando RUE se convierte en 0 debido al estrés por calor	°C	42.1	52.5	Z
SCO_2	Aumento relativo de RUE por ppm de CO ₂ después de 350 ppm.	ppm	0.056	0.084	Z
S_{water}	Sensibilidad de RUE al estrés por sequía	--	0.72	1.08	Z

*°C d grados días de desarrollo B-G=Báez-Gonzales et al., (2020), Z=Zhao et al., (2019), K=Karimzadeh et al., (2018), O=Omae et al., (2012)

3.4.- Resultados

3.4.1.- Condiciones climáticas

La precipitación fue una de las variables climáticas con mayor variación en las 4 estaciones, con valores mínimos y máximos de 268 mm y 838.4 mm en los ciclos 2005 y 2015, respectivamente para la estación ALPINO (Figura 2). Las temperaturas máximas se registraron en los meses entre abril y junio. La temperatura máxima promedio extrema se presentó en la estación ALPINO en mayo de 2010 con 31.0 °C. Las temperaturas mínimas se registraron en diciembre y enero, con un valor mínimo promedio de -1.8 °C en la estación EMAN con en diciembre de 2010. La radiación máxima se registró en la estación GONOR con 34.4 (MJ⁻¹ m⁻²) en mayo de 2010. Finalmente, la evapotranspiración referencia máxima de 7.2 mm se presentó en mayo de 2010 y abril de 2020 en la estación CEZAC (Figura 2).






Figura 3.2. Condiciones climáticas de las cuatro estaciones para los años 2005, 2010, 2015, 2020,

3.4.2.- Análisis de incertidumbre

El TT fue estadísticamente igual ($p < 0.01$) para riego y seco con un promedio general de 1204.8 ± 0.47 °C día⁻¹. Bio y Y de seco fueron superiores en 29.4% con respecto a riego. Los promedios para ambos manejos (riego y seco) de las estaciones con respecto a los años fueron similares, Sin embargo, la desviación estándar fue superior en años con 56%, 39% y 38% para TT, Bio y Y respectivamente, es decir, hubo mayor dispersión de datos en el espacio, lo que indica que existe mayor variabilidad espacial.

En Bio para riego el rango fue de 11.96 a 22.33 t ha⁻¹, en seco fue de 6.90 a 34.11 t ha⁻¹. Para Y fue de 4.31 a 8.03 t ha⁻¹ y 2.48 a 12.29 t ha⁻¹ para riego y seco, respectivamente. La alta dispersión de los datos en seco de esta variable se puede atribuir, principalmente, a las bajas temperaturas que se registraron durante la simulación, esto ocasionó un incremento hasta de 110 días comparadas con las simulaciones para riego. En la variable TT los coeficientes de variación fueron los más bajos de 11.49% y 11.47% para el frijol de riego y seco, respectivamente.

Los valores correspondientes para Y, en ese mismo orden, fueron los más altos 49.52% y 39.71%. Sin embargo, el coeficiente de variación promedio de las tres variables fue 36.32% y 29.67% para el frijol de riego y seco, respectivamente (Figura 3).




Figura 3.3. Promedios ($\pm$ desviación estándar) de las variables de salida, tiempo térmico (A), biomasa (B) y rendimiento (C) del frijol bajo riego o seco para el modelo SIMPLE en ensayos entre estaciones climáticas y entre años en Zacatecas, México.

La curtosis promedio para TT, Bio y Y para el frijol de riego fue, respectivamente, 1.8 ± 0.001 , 4.4 ± 0.3 y 4.8 ± 0.3 ; mientras que para el frijol de seco fue, respectivamente, 1.8 ± 0.001 , 3.8 ± 0.2 y 4.2 ± 0.2 . Estos valores indican que TT presenta mayor concentración de los datos sobre la media y la más baja concentración sobre la media se observa en Y. El promedio de curtosis para años y estaciones son iguales lo que indica una buena robustez del modelo al cambio espacial y temporal de las variables de entrada (Figura 4).




Figura 3.4. Curtosis (barras) y asimetría (líneas) de las variables de salida A) tiempo térmico, B) biomasa y C) rendimiento del modelo SIMPLE en ensayos entre estaciones climáticas y entre años producción de frijol en Zacatecas, México.

Los valores de asimetría cercanos a cero y los altos valores de varianza demuestra que TT se ajusta a una distribución uniforme, para Bio y Y el promedio general fue de 0.9 y 1.0 respectivamente, de acuerdo con valores observados las distribuciones de la variable de salida para estaciones y años tiene asimetría positiva es decir sesgada a la derecha (Figura 4). Lo anterior implica que las variables de salida del modelo no se ajustan a una distribución normal.

3.4.3.- Análisis de sensibilidad

Los índices de primer orden (S_i), fueron inferiores en 7.70%, 16.64% y 10.88% a los índices de efecto total (S_{Ti}) para TT, Bio y Y respectivamente (Figura 5 y 6), lo que indica interacción entre parámetros. S_i y S_{Ti} fueron similares al promediarlos entre estaciones y años para ambos sistemas de producción de frijol, es decir, las

variables de entrada en el tiempo y el espacio tuvieron el mismo efecto sobre los parámetros.

Al promediar lo índices por manejo, se observa que en riego los parámetros más influyentes para TT, Bio y Y fueron: Tsum, Swater, Tbase, Topt y I50A por orden de influencia. La mayor desviación estándar se observó en TT para el parámetro Tsum con un S_{Ti} máximo de 46.22 (CEZAC 2015) y mínimo de 28.28 (EMAN 2020), y en el parámetro Swater con 30.04 y 15.58 para EMAN 2005 y ALPINO 2015, respectivamente (Figura 5 y 6). En CEZAC 2015 la simulación promedio fue de 121 días y EMAN 2020 fue de 108 días. Por otro lado, en CEZAC 2015 se observó, en promedio, una Tmax y Tmin de 25.69 y 11.53°C y de 28.81 y 11.21°C en EMAN respectivamente. En EMAN 2005 y ALPINO 2015 durante la simulación la precipitación efectiva fue de 139.50 mm y 340.30 mm, respectivamente.




Figura 3.5. Índices de sensibilidad de primer orden ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en riego para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.




Figura 3.6. Índices de sensibilidad de efecto total ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en riego para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.

En Secano los parámetros más influyentes fueron: Tsum, Tbase, I50A, Topt, Swater y RUE. El parámetro I50A influyó con más peso, Swater baja su importancia y RUE se considera como parámetro influyente con respecto a riego. I50A presentó S_{Ti} máximo de 29.4 (ALPINO 2010) y un mínimo de 11.11 (GONOR 2005). La simulación promedio fue de 171.5 y 169.5 días para ALPINO 2010 y GONOR 2005 respectivamente, ambos escenarios presentaron una temperatura media similar durante la simulación. Sin embargo, en la estación ALPINO en 2010 se registró una precipitación (Pp) de 219.6 mm, una radiación solar media (Rs) de $59.24 \text{ MJ m}^{-2} \text{ día}^{-1}$ y una evapotranspiración de referencia media (ETo) de 3.85 mm día^{-1} . En la estación GONOR en 2005 durante la simulación se registró una Pp de 570.4 mm, Rs de $65.77 \text{ MJ m}^{-2} \text{ día}^{-1}$ y una ETo de 4.95 mm día^{-1} .

Para Swater se observó un rango en ST de 3.27 a 43.30 en la estación CEZAC en 2020 y 2010 respectivamente, esto sugirió que la variación temporal en esta estación afectó la participación de Swater sobre las variables del modelo. En la estación CEZAC 2020, durante la simulación, se registraron los siguientes valores de: $T_{\text{max}} = 24.13^{\circ}\text{C}$, $T_{\text{min}} = 8.29^{\circ}\text{C}$, $Pp = 405 \text{ mm}$, $Rs = 69.28 \text{ MJm}^{-2} \text{ día}^{-1}$ y $ETo =$

4.35 mm día⁻¹. En esta misma estación, pero en 2010, los valores fueron Tmax = 23.99°C, Tmin = 7.68°C, Pp = 214 mm, Rs = 70.61 MJ m⁻² día⁻¹ y ETo = 4.54 mm día⁻¹.

El parámetro RUE está relacionado directamente con Rs. Durante la simulación, Rs en riego fue 21.1% superior en relación con secano. En RUE, el S_{TI} máximo y mínimo fue de 12.73 (CEZAC 2020) y 5.74 (CEZAC 2010), respectivamente. En la estación CEZAC en 2020, superó 47.16% la precipitación y 7.37% la Tmin de CEZAC 2010, pero es inferior en 1.9% y 4.48% para Rs y ETo respectivamente, además, en CEZAC en el año 2010 la simulación fue de 271 días y 258 días en 2020. La Tsum de 1440 °C día⁻¹, esta diferencia de 35 días de simulación es atribuible a la Tmin de 2.05 y -0.72°C en CEZAC 2010 para los meses de noviembre y diciembre respectivamente. Sin embargo, la influencia de RUE, está relacionada con la variación de Rs de esos últimos 35 días de simulación donde CEZAC en 2010 fue en 11.67% superior a CEZAC en 2020.




Figura 3.7. Índices de sensibilidad de primer orden ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en secano para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.




Figura 3.8. Índices de sensibilidad de efecto total ($\pm$ desviación estándar) con el método de Sobol para el cultivo de frijol en riego para las variables predichas por el modelo SIMPLE, línea punteada denota un umbral del 10%.

3.5.- Discusión

3.5.1.- Condiciones climáticas

El clima de las cuatro regiones del estudio es seco y semiseco (INEGI, 2020), se clasifica como, semiárido frío (Bsk) según Koppen modificado por García (1974), con precipitaciones promedio de 400 mm que se ocurren principalmente en el verano y principios de otoño. Sin embargo, la precipitación muestra considerable variabilidad temporal y espacial, lo que afecta la producción agrícola, principalmente de temporal (Esquivel-Arriaga *et al.*, 2016; Rosenzweig, 2007), e induce reducción en la producción de frijol en el altiplano semiárido templado del centro-norte de México (Osuna-Ceja *et al.*, 2019). Por otro lado, la temperatura mínima de octubre y noviembre en la mayoría de los escenarios fue menor que la T_{base} (8 °C) para frijol (Baez-Gonzales *et al.*, 2020). Esto último, tiene mayor efecto en las simulaciones de temporal para Tsum mayores de 1200 °C d⁻¹, Tbase es de suma importancia para el cálculo de TT (Masle *et al.*, 1989) e influye en los procesos y desarrollo de las plantas (Machado *et al.*, 2006).

3.5.2.- Análisis de incertidumbre

El valor final de la simulación en la variable de salida describe de manera confiable la respuesta de la salida de los modelos dinámicos que fue utilizada por Guo et al. (2020) y se puede utilizar para comparar la simulación en riego y seco. Tigras et al. (2019) mencionan que la sequía tiene efectos importantes en el sector agrícola. Es decir, la producción agrícola es sensible a la distribución espacial y temporal de la precipitación (Lausier and Jain, 2018). Por otro lado, los rendimientos simulados en los escenarios de riego están dentro de los reportados por Kader et al. (2018), de 4.0 y 6.0 t ha⁻¹, en seco Baez-Gonzales et al. (2020) reportan rendimientos de 1.8 t ha⁻¹ para el frijol cv “Pinto Saltillo”, sin embargo, el modelo SIMPLE sobreestima los rendimientos, atribuible a las bajas temperaturas durante la simulación y a la incertidumbre aplicada al parámetro Tsum, que genera ciclos largos de cultivo, incluso fuera del límite del inicio de las heladas en la región. Además, Acosta-Gallegos and White (1995) y Yan and Wallace (1998) mencionan que la temperatura y el fotoperiodo modifican las etapas de crecimiento y desarrollo del cultivo de frijol. Por estas razones se debe tener especial cuidado con el parámetro Tsum e incorporar en la estructura del modelo ecuaciones que represente el efecto del fotoperiodo sobre el rendimiento de frijol.

De acuerdo con el coeficiente de variación la variable menos sensible al 10% de incertidumbre de los parámetros fue TT, mientras que Bio es la más sensible. Valores de CV < 30% significan una dispersión baja de los datos sobre la media de las variables de salida, es decir tiende a la homogeneidad. El modelo SIMPLE puede ser confiable y robusto disminuyendo la incertidumbre de los parámetros más influyentes para que represente la producción de biomasa en Zacatecas. Martínez-Ruiz, et al. (2020) realizaron un SA del modelo HORTSYST mencionan que al disminuir la incertidumbre de los parámetros se observan valores menores de coeficiente de variación.

Los valores de curtosis y asimetría muestran una concentración de los datos a la izquierda, es decir son más frecuentes los valores bajos y muestran un sesgo positivo para Bio y Y. Además, los resultados evidencian la posibilidad de rechazar el supuesto de normalidad (Patel and Read 1996; Joanes and Gill 1998). Pero Harri

et al. (2009) quienes mencionan que el rendimiento de los cultivos puede ser ajustar a diferentes distribuciones (beta, gamma, transformación de función tangente hiperbólica, logística, log-normal y weibull) y no necesariamente a una distribución normal.

3.5.3 Análisis de sensibilidad

Varios autores coinciden que la interacción de los parámetros ejerce influencia sobre las variables predichas por un modelo matemático (DeJonge et al., 2012; Martínez-Ruiz et al., 2021). Por lo anterior, los índices de efectos totales son los valores indicados para determinar la influencia de los parámetros en las salidas del modelo. Este resultado soporta lo indicado por Krishnan et al., (2021). Estos autores estudiaron la influencia de los parámetros en el modelo InfoCrop en condiciones contrastantes y no encontraron evidencias de que las condiciones agro-climáticas y el año tuvieran influencia en la clasificación de los parámetros candidatos para calibración. En este estudio, la disponibilidad de agua en el suelo relacionada con el manejo afecta fuertemente en la clasificación de los parámetros más influyentes del modelo SIMPLE.

El parámetro Tsum está relacionado con la longitud de periodo de crecimiento y para el modelo SIMPLE determina el final de la simulación. Esta variable tiene gran influencia en el tiempo térmico (TT), biomasa (Bio) y rendimiento (Y). Sin embargo, en contraste a lo anterior, Ratjen et al. (2018) mencionan que el tiempo térmico no puede capturar completamente la relación alométrica entre índice de área foliar y biomasa de maíz y trigo. El TT mide el tiempo del cambio de etapa fenológica y depende de gran medida de la temperatura. La distribución uniforme de TT en este estudio, refleja la distribución aplicada en Tsum. Por tal razón, se debe tener total cuidado para seleccionar la incertidumbre y la distribución utilizada en los parámetros de modelo y evitar inferencias erróneas en su influencia. Jin et al. (2010) mencionan que las distribuciones planas indican que los parámetros del modelo que las generan son inciertos.

Tbase tiene una gran importancia en el cálculo de TT (Masle et al., 1989). Barrio-Gómez et al. (2009) mencionan que la Tbase óptima para las diferentes variedades de frijol sembradas en México es de 8.2 y 8.4 °C. Se observa que el 01 junio (inicio de simulación para seco) Tmax y Tmin empiezan a disminuir y Tbase tiene mayor influencia en la simulación de crecimiento y desarrollo en frijol con el modelo SIMPLE y tiene mayor importancia con respecto a riego (15 de abril, inicio de simulación).

Por otro lado, el parámetro Swater relaciona la disponibilidad del agua y su efecto en la producción de biomasa (Zhao et al., 2019). Beebe et al. (2011) menciona que la lámina de riego (Lr) para producción de frijol es de 300 a 500 mm. Esto indica que laminas cercanas a estos valores tendrían S_{Ti} más bajos de Swater. Sin embargo, en la estación de la colonia emancipación en 2005 se registraron valores máximos de 427.2 mm y 139.5 mm y en la estación ALPINO en 2015 se registraron 202.3 y 340.3 mm de Lr y Pe, respectivamente. La precipitación efectiva tiene mayor influencia en el parámetro Swater que la que el agua almacenada en el suelo (Lr más Pe). La Pp es la variable de entrada con mayor efecto en Swater, debido a su distribución estocástica en tiempo y espacio. La precipitación es la variable climática con mayor incertidumbre espacio-temporal en primavera-verano para clima árido y semiárido. Las variaciones más importen fueron para riego (primavera) y seco (verano) lo que influyó en los índices. Sin embargo, no se observó una variación de parámetros con respecto al análisis espacial (estaciones) y análisis temporal (años) muy amplia, por lo que el modelo SIMPLE es muy robusto para simular frijol en riego y seco en Zacatecas. Para el frijol bajo seco, la precipitación de agosto tiene mayor efecto en la influencia de Swater sobre Bio y Y. Osuna-Ceja et al. (2012) menciona que la cantidad y la distribución de la precipitación afecta el rendimiento de frijol 'Pinto Saltillo' en condiciones semiáridas del norte de México. Por otro lado, Padilla et al. (2003) menciona que la precipitación acumulada durante la etapa reproductiva es determinante para el rendimiento de frijol bajo seco, el mes de agosto coincide con dicha etapa, donde el cultivo es más sensible al estrés hídrico (Lang et al., 1996; Acosta-Gallegos y Kohashi-Shibata, 1989). El modelo SIMPLE por ser un modelo basado en la interceptación de la radiación era de esperar que

I50A haya resultado como parámetro influyente para el frijol de riego y seco, ya que define la curva de interceptación de radiación de la siembra a madurez fisiológica (Zhao et al., 2019). Además, La radiación fotosintéticamente activa está altamente asociada con la producción de biomasa (Tesfaye et al., 2006). Para seco la radiación fue inferior por lo que el parámetro RUE toma importancia.

3.6.- Conclusiones

Las incertidumbres de las variables de salida están relacionadas con la precipitación que influyo en gran medida en la simulación del modelo SIMPLE, seguida de la temperatura y radiación solar. Y es recomendable realizar un análisis de incertidumbre de las variables de entrada para hacer mejor inferencia sobre las fuentes de incertidumbre y el desempeño del modelo. También, para mejorar la robustez y la calidad de la predicción tanto para el frijol de riego como para el de seco, es necesario dar especial atención en el parámetro Tsum. Por lo tanto, se sugiere, aplicar una incertidumbre pequeña (>10%) o utilizar una distribución normal al realizar la calibración de los parámetros. Por otro lado, es necesario obtener la curva de intersección para obtener de datos experimentales los parámetros I50A y I50B para cada variedad.

De acuerdo con el análisis de sensibilidad global, el modelo para cultivos SIMPLE con datos climáticos de Zacatecas de primavera (riego) sugiere cinco parámetros influyentes. La Tsum es el índice que más afecta el sistema para simulación de tiempo térmico, biomasa y rendimiento, Swater es más importante en riego, seguido I50A, posteriormente, Tbase y Topt. Para invierno (seco) es importante considerar RUE, dando un total de seis parámetros más influyentes para representar las condiciones climáticas de las cuatro regiones productoras de frijol de Zacatecas.

3.7.-Literatura Citada

- Acosta-Gallegos, J.A., White, J.W., 1995. Phenological plasticity as an adaptation by common bean to rainfed environments. *Crop Sci.* 35, 199–204.
- Gallegos, J. A. A., & Shibata, J. K. (1989). Effect of water stress on growth and yield of indeterminate dry-bean (*Phaseolus vulgaris*) cultivars. *Field Crops Research*, 20(2), 81-93. [https://doi.org/10.1016/0378-4290\(89\)90054-3](https://doi.org/10.1016/0378-4290(89)90054-3)
- Allen, R. G.; Pereira, L. S.; Raes, D. y Smith, M. 2006. Evapotranspiración del cultivo: guía para la determinación de los requerimientos de agua de los cultivos. Estudio FAO Riego y Drenaje. FAO, Roma. 2006. 56-323 pp.

- Amir, J., & Sinclair, T. R. (1991). A model of water limitation on spring wheat growth and yield. *Field Crops Research*, 28(1-2), 59–69. doi:10.1016/0378-4290(91)90074-6
- Attia, A., El-Hendawy, S., Al-Suhaibani, N., Tahir, M. U., Mubushar, M., Vianna, M. d. S., . . . Datta, A. (2021). Sensitivity of the DSSAT model in simulating maize yield and soil carbon dynamics in arid Mediterranean climate: Effect of soil, genotype and crop management. *Field Crops Research*, 260, 107981. doi: <https://doi.org/10.1016/j.fcr.2020.107981>
- Baez-Gonzalez, A. D., Fajardo-Díaz, R., Garcia-Romero, G., Osuna-Ceja, E., Kiniry, J. R., & Meki, M. N. (2020). High Sowing Densities in Rainfed Common Beans (*Phaseolus vulgaris* L.) in Mexican Semi-Arid Highlands under Future Climate Change. *Agronomy*, 10(3), 442.
- Barrios-Gómez, E. J., & López-Castañeda, C. (2009). Temperatura base y tasa de extensión foliar en frijol. *Agrociencia*, 43(1), 29-35.
- Beebe, S., Ramirez, J., Jarvis, A., Rao, I. M., Mosquera, G., Bueno, J. M., & Blair, M. W. (2011). Genetic Improvement of Common Beans and the Challenges of Climate Change Crop Adaptation to Climate Change (pp. 356-369).
- Beven K, Freer J, 2001. Equifinality, data assimilation, and uncertainty estimation in mechanistic modelling of complex environmental systems using the GLUE methodology. *J Hydrol* 249 (1-4): 11-29. [https://doi.org/10.1016/S0022-1694\(01\)00421-8](https://doi.org/10.1016/S0022-1694(01)00421-8)
- Ceglar, A., & Kajfež-Bogataj, L. (2012). Simulation of maize yield in current and changed climatic conditions: Addressing modelling uncertainties and the importance of bias correction in climate model simulations. *European Journal of Agronomy*, 37(1), 83-95. doi: <https://doi.org/10.1016/j.eja.2011.11.005>
- Cid R, J. A.; Reveles H, M.; Velázquez V, R. y Mena C, J. 2014. Producción de semilla de frijol. Folleto Técnico No. 63. Campo Experimental Zacatecas. CIRNOC-INIFAP. Calera, Zacatecas, México, 69 p.
- Cid R, J. A.; Reveles H, M.; Velázquez V, R. y Mena C, J. 2014. Producción de semilla de frijol. Folleto Técnico No. 63. Campo Experimental Zacatecas. CIRNOC-INIFAP. Calera, Zacatecas, México, 69 p.
- Corbeels, M., Chirat, G., Messad, S., & Thierfelder, C. (2016). Performance and sensitivity of the DSSAT crop growth model in simulating maize yield under conservation agriculture. *European Journal of Agronomy*, 76, 41-53. doi: <https://doi.org/10.1016/j.eja.2016.02.001>
- Coucheney, E., Buis, S., Launay, M., Constantin, J., Mary, B., García de Cortázar-Atauri, I., . . . Léonard, J. (2015). Accuracy, robustness and behavior of the STICS soil–crop model for plant, water and nitrogen outputs: Evaluation over a wide range of agro-environmental conditions in France. *Environmental Modelling & Software*, 64, 177-190. doi: <https://doi.org/10.1016/j.envsoft.2014.11.024>
- DeJonge, K. C., Ascough, J. C., Ahmadi, M., Andales, A. A., & Arabi, M. (2012). Global sensitivity and uncertainty analysis of a dynamic agroecosystem model under different irrigation treatments. *Ecological Modelling*, 231, 113-125. doi: <https://doi.org/10.1016/j.ecolmodel.2012.01.024>
- Dzotsi, K. A., Basso, B., & Jones, J. W. (2013). Development, uncertainty and sensitivity analysis of the simple SALUS crop model in DSSAT. *Ecological Modelling*, 260, 62-76. doi: <https://doi.org/10.1016/j.ecolmodel.2013.03.017>
- Eitzinger, J., Thaler, S., Schmid, E., Strauss, F., Ferrise, R., Moriondo, M., . . . Çaylak, O. (2012). Sensitivities of crop models to extreme weather conditions during flowering period demonstrated for maize and winter wheat in Austria. *The Journal of Agricultural Science*, 151(6), 813-835. doi: 10.1017/S0021859612000779
- Esquivel-Arriaga, G., Sánchez-Cohen, I., López-Santos, A., Velásquez-Valle, M. A., & Bueno-Hurtado, P. (2016). Enfoque metodológico para cuantificar el efecto del cambio en patrones de clima sobre el rendimiento del cultivo de frijol en el estado de Durango. *Revista Chapingo Serie Zonas Áridas*, 15(1), 17-28. <https://doi.org/10.5154/r.rchsza.2015.08.011>
- Fleisher, D. H., Condori, B., Quiroz, R., Alva, A., Asseng, S., Barreda, C., . . . Woli, P. (2017). A potato model intercomparison across varying climates and productivity levels. *Global Change Biology*, 23(3), 1258-1281. doi: <https://doi.org/10.1111/gcb.13411>
- García, E. (1974). Distribución de la precipitación en la República Mexicana. *Investigaciones geográficas*, (5), 7-20.

- Guo, D., Zhao, R., Xing, X., & Ma, X. (2020). Global sensitivity and uncertainty analysis of the AquaCrop model for maize under different irrigation and fertilizer management conditions. *Archives of Agronomy and Soil Science*, 66(8), 1115-1133. doi: 10.1080/03650340.2019.1657845
- Guo, D., Zhao, R., Xing, X., & Ma, X. (2020). Global sensitivity and uncertainty analysis of the AquaCrop model for maize under different irrigation and fertilizer management conditions. *Archives of Agronomy and Soil Science*, 66(8), 1115-1133. doi: 10.1080/03650340.2019.1657845
- Harri, A., Erdem, C., Coble, K. H., & Knight, T. O. (2009). Crop Yield Distributions: A Reconciliation of Previous Research and Statistical Tests for Normality. *Applied Economic Perspectives and Policy*, 31(1), 163-182. doi: <https://doi.org/10.1111/j.1467-9353.2008.01431.x>
- Hayat, I., Ahmad, A., Masud, T., Ahmed, A., & Bashir, S. (2014). Nutritional and Health Perspectives of Beans (*Phaseolus vulgaris* L.): An Overview. *Critical Reviews in Food Science and Nutrition*, 54(5), 580-592. doi: 10.1080/10408398.2011.596639
- INEGI (Instituto Nacional De Estadística y Geografía). (2012). Censo Agropecuario 2007. Septiembre, 25, 2016, de INEGI Sitio web: <http://www3.inegi.org.mx>
- INEGI (Instituto Nacional de Estadística y Geografía). (2015). Cuéntame... de México: clima de Zacatecas. Instituto Nacional de Estadística y Geografía [web]. <http://cuentame.inegi.org.mx/monografias/informacion/zac/territorio/clima.aspx?tema=me&e=32>
- Joanes, D. N., & Gill, C. A. (1998). Comparing measures of sample skewness and kurtosis. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 47(1), 183-189. doi:10.1111/1467-9884.00122
- Karimzadeh Soureshjani, H., Nezami, A., Kafi, M., & Tadayon, M. (2019). Responses of two common bean (*Phaseolus vulgaris* L.) genotypes to deficit irrigation. *Agricultural Water Management*, 213, 270-279. doi: <https://doi.org/10.1016/j.agwat.2018.09.038>
- Keating, B. A., & Thorburn, P. J. (2018). Modelling crops and cropping systems—Evolving purpose, practice and prospects. *European journal of agronomy*, 100, 163-176.
- Krishnan, P., Maity, P. P., & Kundu, M. (2021). Sensitivity analysis of cultivar parameters to simulate wheat crop growth and yield under moisture and temperature stress conditions. *Heliyon*, 7(7), e07602. doi: <https://doi.org/10.1016/j.heliyon.2021.e07602>
- Krishnan, P., Maity, P. P., & Kundu, M. (2021). Sensitivity analysis of cultivar parameters to simulate wheat crop growth and yield under moisture and temperature stress conditions. *Heliyon*, 7(7), e07602. doi: <https://doi.org/10.1016/j.heliyon.2021.e07602>
- Lang, M., Lichtenthaler, H. K., Sowinska, M., Heisel, F., & Miehe, J. A. (1996). Fluorescence imaging of water and temperature stress in plant leaves. *Journal of plant physiology*, 148(5), 613-621. [https://doi.org/10.1016/S0176-1617\(96\)80082-4](https://doi.org/10.1016/S0176-1617(96)80082-4)
- Lausier, A. M., & Jain, S. (2018). Overlooked trends in observed global annual precipitation reveal underestimated risks. *Scientific reports*, 8(1), 1-7.
- Ljung, L., & Glad, T. (1994). *Modeling of Dynamic Systems*. Englewood Cliffs, NJ: Prentice-Hall.
- Lopez-Cruz, I. L., Ramirez-Arias, A., & Rojano-Aguilar, A. (2005). Modelos matemáticos de hortalizas en invernadero: trascendiendo la contemplación de la dinámica de cultivos. *Revista Chapingo Serie Horticultura*, 11(2), 257-267.
- "Machado N., N. B., M. Regina P., A. B. Gatti, and V. J. Mendes C. 2006. Temperature effects on seed germination in races of common beans (*Phaseolus vulgaris* L.). *Acta Sci. Agron.* 28:155-164."
- Martínez-Ruiz, A., Ruiz-García, A., Prado-Hernández, J. V., López-Cruz, I. L., Valencia-Islas, J. O., & Pineda-Pineda, J. (2021). Global Sensitivity Analysis and Calibration by Differential Evolution Algorithm of HORTSYST Crop Model for Fertigation Management. *Water*, 13(5). doi: 10.3390/w13050610
- Masle, J., G. Doussinault, G. D. Farquhar, and B. Sun. 1989. Foliar stage in wheat correlates better to photothermal time than to thermal time. *Plant, Cell and Environ.* 12: 235-247.
- Masle, J., Doussinault, G., Farquhar, G. D., & Sun, B. (1989). Foliar stage in wheat correlates better to photothermal time than to thermal time. *Plant, Cell & Environment*, 12(3), 235-247.

- Matott LS, Babendreier JE, Purucker ST, 2009. Evaluating uncertainty in integrated environmental models: A review of concepts and tools. *Water Resour Res* 45 (6):1-14. <https://doi.org/10.1029/2008WR007301>
- Medina, G. G.; Báez, G. A. D. y Ramos, G. J. L. (2007). Red de monitoreo agroclimático del estado de Zacatecas. INIFAP, Campo Experimental Zacatecas, México. Desplegable informativa Núm. 15. 14 p. consultado mayo 2020 <http://www.zacatecas.inifap.gob.mx/historico.php?id=26786>
- Medina-García, G.; Rumayor-Rodríguez, A. F.; Cabañas-Cruz, B.; Luna-Flores, M.; Ruiz-Corral, J. A.; Gallegos-Valdez, C.; Madero-Tamargo, J.; Gutiérrez-Sánchez, J. R.; Rubio-Díaz, S. y Bravo-Lozano, A. G. (2003). Potencial productivo de especies agrícolas en el estado de Zacatecas. Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. Centro de Investigación Regional Norte Centro. Calera de V. R., Zacatecas, México. (Libro Técnico Núm. 2). 15 7 p.
- Monod H, Naud C, Makowski D, 2006. Uncertainty and sensitivity analysis for crop models. In: *Working with dynamic crop models*, Chapt. 3, pp: 55-100. Elsevier. ISBN: 0-444-52135-6.
- Monteith, J.L., 1965. Light distribution and photosynthesis in field crops. *Ann. Bot.* 29 (113), 17–37.
- Omae, H., Kumar, A., & Shono, M. (2012). Adaptation to high temperature and water deficit in the common bean (*Phaseolus vulgaris* L.) during the reproductive period. *Journal of Botany*, 2012.
- Osuna-Ceja, E. S., Reyes-Muro, L., Padilla-Ramírez, J. S., & Martínez-Gamiño, M. Á. (2012). Rendimiento de frijol Pinto Saltillo en altas densidades de población bajo temporal. *Revista mexicana de ciencias agrícolas*, 3(7), 1389-1400.
- Osuna-Ceja, E. S., Figueroa-Sandoval, B., Martínez-Gamiño, M. Á., & Pimentel-López, J. (2019). Un sistema agroforestal de secano para el altiplano semiárido de México. *Revista mexicana de ciencias agrícolas*, 10(SPE22), 89-103. <https://doi.org/10.29312/remexca.v0i22.1861>
- Padilla-Ramírez, J. S.; Ochoa-Márquez, R.; Acosta-Díaz, E.; Acosta-Gallegos, J. A.; Mayek-Pérez; N. and Kelly, J. D. 2003. Grain yield of early and late dry bean genotypes under rainfed conditions in Aguascalientes, México. *Annual Report of the Bean Improvement Cooperative*. 46: 89-90.
- Patel, J. K., & Read, C. B. (1996). *Handbook of the normal distribution* (Vol. 150). CRC Press.
- Purves, R. D. (1992). Optimum numerical integration methods for estimation of area-under-the-curve (AUC) and area-under-the-moment-curve (AUMC). *Journal of pharmacokinetics and biopharmaceutics*, 20(3), 211-226.
- Ratjen, A. M., Lemaire, G., Kage, H., Plénet, D., & Justes, E. (2018). Key variables for simulating leaf area and N status: Biomass based relations versus phenology driven approaches. *European Journal of Agronomy*. doi:10.1016/j.eja.2018.04.008
- Ritchie, J.T., Godwin, D.C., Otter-Nacke, S., 1985. CERES-wheat: A User-oriented Wheat Yield Model. Preliminary Documentation. AGRISTARS Publication No. YM-U3-04442-JSC-18892. Michigan State University, Michigan.
- Rosenzweig, C. (2007). *Climate Change & Agriculture. Learning lessons & proposing solutions*. Iowa State University. U.S.A. Pp 28.
- Ross, J. (2012). *The radiation regime and architecture of plant stands* (Vol. 3). Springer Science & Business Media.
- Rötter, R. P., Palosuo, T., Kersebaum, K. C., Angulo, C., Bindi, M., Ewert, F., . . . Trnka, M. (2012). Simulation of spring barley yield in different climatic zones of Northern and Central Europe: A comparison of nine crop models. *Field Crops Research*, 133, 23-36. doi: <https://doi.org/10.1016/j.fcr.2012.03.016>
- Saltelli, A. (2002). Sensitivity analysis for importance assessment. *Risk analysis*, 22(3), 579-590.
- Saltelli, A., Aleksankina, K., Becker, W., Fennell, P., Ferretti, F., Holst, N., . . . Wu, Q. (2019). Why so many published sensitivity analyses are false: A systematic review of sensitivity analysis practices. *Environmental Modelling & Software*, 114, 29-39. doi: <https://doi.org/10.1016/j.envsoft.2019.01.012>
- Saltelli, A.; Tarantola, S.; Campolongo, F.; Ratto, M. *Sensitivity Analysis in Practice. A Guide to Assessing Scientific Models*; John Wiley & Sons, Ltd.: Hoboken, NJ, USA, 2004
- Saltelli, A.; Ratto, M.; Tarantola, S.; Campolongo, F. *Sensitivity analysis practices: Strategies for model-based inference*. *Reliab. Eng. Syst. Saf.* 2006, 91, 1109–1125.

- Saltelli, A., Ratto, M., Andres, T., Campolongo, F., Cariboni, J., Gatelli, D., ... & Tarantola, S. (2008). *Global sensitivity analysis: the primer*. John Wiley & Sons.
- Servín Palestina, M., Tijerina Chávez, L., Medina García, G., Palacios Velez, O., & Flores Magdaleno, H. (2017). Sistema para programar y calendarizar el riego de los cultivos en tiempo real. *Revista mexicana de ciencias agrícolas*, 8(2), 423-430.
- SIAP. (2021). Servicio de Información y Estadística Agroalimentaria y Pesquera Información Agrícola. Avances mensuales por estado. Estadísticas 2010-2010 <http://www.siap.sagarpa.gob.mx>. (Revisado: 15 mayo 2021)
- Silvestro, P. C., Pignatti, S., Yang, H., Yang, G., Pascucci, S., Castaldi, F., & Casa, R. (2017). Sensitivity analysis of the Aquacrop and SAFYE crop models for the assessment of water limited winter wheat yield in regional scale applications. *PLOS ONE*, 12(11), e0187485. doi: 10.1371/journal.pone.0187485
- 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. *Agron. J.* 101 (3), 426–437.
- Stöckle, C. O., Donatelli, M., & Nelson, R. (2003). CropSyst, a cropping systems simulation model. *European Journal of Agronomy*, 18(3-4), 289–307. doi:10.1016/s1161-0301(02)00109-0
- Tan, J., Cui, Y., & Luo, Y. (2017). Assessment of uncertainty and sensitivity analyses for ORYZA model under different ranges of parameter variation. *European Journal of Agronomy*, 91, 54-62. doi: <https://doi.org/10.1016/j.eja.2017.09.001>
- Tesfaye, K., Walker, S., & Tsubo, M. (2006). Radiation interception and radiation use efficiency of three grain legumes under water deficit conditions in a semi-arid environment. *European Journal of Agronomy*, 25(1), 60–70. doi:10.1016/j.eja.2006.04.014
- Thornley, J. H., & France, J. (2007). *Mathematical models in agriculture: quantitative methods for the plant, animal and ecological sciences*. Cabi.
- Tigkas, D., Vangelis, H., & Tsakiris, G. (2019). Drought characterisation based on an agriculture-oriented standardised precipitation index. *Theoretical and Applied Climatology*, 135(3), 1435-1447. doi: 10.1007/s00704-018-2451-3
- van Ittersum, M. K., Leffelaar, P. A., van Keulen, H., Kropff, M. J., Bastiaans, L., & Goudriaan, J. (2003). On approaches and applications of the Wageningen crop models. *European journal of agronomy*, 18(3-4), 201-234.
- Voinov, A. A. (2010). *Systems science and modeling for ecological economics*. Academic Press.
- Wallach, D., Makowski, D., Jones, J. W., & Brun, F. (2019). *Working with dynamic crop models: methods, tools and examples for agriculture and environment*. Academic Press.
- Walters, R. W., & Huyse, L. (2002). Uncertainty analysis for fluid mechanics with applications. ICASE Report No. 2002-1 NASA/CR-2002-211449. <https://apps.dtic.mil/sti/citations/ADA401486>
- Wang, J., Li, X., Lu, L., & Fang, F. (2013). Parameter sensitivity analysis of crop growth models based on the extended Fourier Amplitude Sensitivity Test method. *Environmental Modelling & Software*, 48, 171-182. doi: <https://doi.org/10.1016/j.envsoft.2013.06.007>
- Yan, W., Wallace, D.H., 1998. Simulation and prediction of plant phenology for five crops based on photoperiod temperature interaction. *Ann. Bot.* 81, 705–716.
- Zhao, G., Bryan, B. A., & Song, X. (2014). Sensitivity and uncertainty analysis of the APSIM-wheat model: Interactions between cultivar, environmental, and management parameters. *Ecological Modelling*, 279, 1-11. doi: <https://doi.org/10.1016/j.ecolmodel.2014.02.003>
- Zhao Chuang, B. L., Liujun Xiao, Gerrit Hoogenboom, Kenneth J. Boote, Belay T. Kassie, Willingthon Pavan, . . . Yan Zhu, S. A. (2019). A SIMPLE crop model. *European Journal of Agronomy*, 104(1161-0301), 97-106.

IV.- ANÁLISIS DE INCERTIDUMBRE GLUE DEL MODELO DE CULTIVOS SIMPLE APLICADO A UN CULTIVO DE FRIJOL (*Phaseolus vulgaris* L.)

5

4.1.-Resumen

Los modelos de cultivo se utilizan para planear la producción y son usados para tomar decisiones en la agricultura, aunque, para tener un modelo de cultivo confiable y funcional es necesario identificar sus fuentes de incertidumbre. El objetivo fue realizar un análisis de incertidumbre (UA) con el método de estimación de incertidumbre de verosimilitud generalizada (GLUE), para el modelo SIMPLE calibrado y sin calibrar e identificar la respuesta de la biomasa (Bio). El UA se realizó para tres escenarios 1) Distribución de probabilidad uniforme y aplicando 10% de incertidumbre (U10), 2) Distribución uniforme y aplicando 20% de incertidumbre (U20) y 3) Distribución normal en los parámetros Tsum y Swater y el resto con 20% de incertidumbre con distribución uniforme (U20N). Posteriormente se realizó un análisis de sensibilidad y se calibraron los parámetros más influyentes utilizado el algoritmo de evolución diferencial DE/rand/1/bin, con el modelo SIMPLE calibrado se realizó un segundo UA para los tres escenarios correspondiente. Para ambos casos se obtuvieron estadísticas descriptivas de la distribución de la biomasa y se realizó un gráfico de dispersión del RMSE de la biomasa, el rango de exploración de cada parámetro. También, se obtuvo el vector de parámetros que minimiza los valores del RMSE. Sin calibrar: El vector en U10 tuvo un RMSE 0.75 t ha⁻¹, En U20 el RMSE fue de 0.57 t ha⁻¹ mostro mejor ajuste, sin embargo, sobre estima el ciclo vegetativo a 134 días y en U20N el RMSE fue de 0.58 t ha⁻¹ y el ciclo vegetativo fue de 124 días. Calibrado: se obtuvo un RMSE > 0.55 en los tres escenarios. Los resultados indican que la incertidumbre aplicada a los parámetros en cada uno de

⁵ Tesis de Doctorado en Ingeniería, Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Miguel Servin Palestina

Director: Irineo L. López Cruz, PhD

los escenarios no tiene influencia en los intervalos de confianza y en el vector de parámetros que minimiza el RMSE.

Palabras clave: Calibración, análisis sensibilidad, modelos dinámicos, curva de biomasa, parámetros influyentes

4.2.- Introducción

Los modelos de cultivo se utilizan ampliamente para planear la producción en áreas con recursos limitados, afectadas por el cambio climático y son usados para tomar decisiones de emergencia en la agricultura (Graeff et al., 2012); por tanto, es necesario contar con un modelo de cultivo confiable y funcional. El proceso de modelado de sistemas dinámicos en su fase de análisis del modelo incluye los siguientes pasos: a) incertidumbre, b) sensibilidad, c) calibración, d) verificación y d) evaluación (Voinov, 2008). El análisis de incertidumbre y sensibilidad se utilizan para conocer y cuantificar las fuentes de variación en el modelo matemático y para identificar los factores que afectan más la salida del sistema (Keesman et al., 2011). La incertidumbre, en las predicciones del modelo, ha sido asociado a errores de medición en las entradas y salidas del sistema, causados por errores estructurales del modelo matemático y estimación de parámetros (Blasone et al., 2008). El objetivo de un análisis de incertidumbre es evaluar los efectos de la incertidumbre en los parámetros sobre la incertidumbre en los resultados calculados (Cacuci, 2005). Es decir, dada la especificación matemática genérica $y = f(x)$, donde $x = [x_1 \ x_2 \ \dots \ x_n]$ y $y = [y_1 \ y \ \dots \ y_m]$ un análisis de incertidumbre intenta responder a la pregunta ¿cuál es la incertidumbre en $y(x)$ dada la incertidumbre en x ? (Helton, 2002). Existen varios métodos que se han utilizado con éxito para realizar el análisis de incertidumbre: el método frecuentista monte Carlo (Zhang et al., 2019; Tan et al., 2021), métodos bayesianos como algoritmos de metrópolis adaptativo (Teweldebrhan et al., 2018; Tan et al., 2019) el método de incertidumbre de verosimilitud generalizada (GLUE) utilizado en análisis de incertidumbre (Martínez-Ruiz et al., 2021; Tan et al., 2021) y calibración (Li et al., 2018; Sheng et al., 2019). El método GLUE es una técnica de estimación de parámetros bayesianos de monte

Carlo que utiliza una función de verosimilitud para medir el ajuste entre los datos observados y los predichos por el modelo (Beven & Binley, 1992).

Por otro lado, la calibración de modelos dinámicos es otro paso importante en el desarrollo de modelos, la cual se puede llevar a cabo, dentro del enfoque frecuentista, a través de un problema de optimización, donde se minimiza una función objetivo (van Straten, 2008) que, a su vez, depende de un conjunto de parámetros. La calibración de un modelo matemático es requerida, debido a que no todos los parámetros se miden directamente (Bhar et al., 2020). Wallach et al., (2011) mencionan que la calibración es la estimación de los parámetros óptimos para ajustar los datos observados a los estimados por modelo. Para la calibración se han utilizado métodos clásicos como el método de prueba y error (Saddique et al., 2021), mínimos cuadrados no lineales (Dzotsi et al, 2015) y evolución diferencial (Trejo-Zúñiga et al 2013; Sheng et al., 2019). La mayoría de los análisis de incertidumbre con el método GLUE se realizan sin calibración previa de los modelos. Por tanto, esto puede generar un sesgo en la selección de parámetros influyentes, y que afectaría la obtención del vector de parámetros que minimiza el error entre los valores observados y simulados. Con base a lo anterior, la presente investigación tuvo como objetivo el realizar un análisis de incertidumbre utilizando el método GLUE con datos de un experimento de frijol común (*Phaseolus vulgaris* L.) establecido en Zacatecas, México, para el modelo de crecimiento de cultivos SIMPLE, explorando el comportamiento del modelo con y sin calibración para identificar la respuesta de la variable de salida biomasa. Aquí la hipótesis que se postuló: las fuentes de incertidumbre tienen la misma respuesta en las variables de salida al utilizar el modelo SIMPLE calibrado y sin calibrar.

4.3.- Materiales y métodos

4.3.1.- Descripción del área de estudio

El experimento se realizó en el Campo Experimental Zacatecas (CEZAC) del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP), Calera, Zacatecas, México (lat. 22°540 N, long. 102°390 W, elevación 2197 msnm).

El sitio experimental tiene una temperatura media anual de 14.6 °C y precipitación media anual de 416 mm, con un 75 % entre julio y octubre. La evaporación media anual de la bandeja es de 1609 mm. El suelo en el lugar es franco arcilloso con un punto de saturación (SP), capacidad de campo (FC) y punto de marchitamiento permanente (PWP) de 0.48 m³ m⁻³, 0.29 m³ m⁻³ y 0.14 m³ m⁻³, respectivamente. Una densidad aparente promedio de 1.1 g cm⁻³. La distribución granulométrica es 35%, 28% y 37% de arena, limo y arcilla, respectivamente, con 1.3% de contenido de materia orgánica en el suelo y pH de 8.2.

4.3.1.1.- Datos climáticos

Los datos climáticos diarios de temperatura máxima (T_{max}, °C), mínima (T_{min}, °C), radiación solar (R_s, MJ⁻¹m⁻²), precipitación (PP, mm) y evapotranspiración de referencia (E_{To}, mm) se obtuvieron de la estación meteorológica automatizada Adcon® ubicada a -102.659° O, 22.909° N en el (CEZAC), ubicada a 1.5 km del sitio experimental. La plataforma Adcon® estima la evapotranspiración de referencia por el método Penman-Monteith (Allen et al., 2006).

4.3.1.2.- Establecimiento del experimento

La curva de crecimiento de biomasa se obtuvo a través de muestreos destructivos recolectando las plantas contenidas en 1 m de un surco de tres parcelas experimentales (tres repeticiones) de frijol 'Pinto Saltillo', sembrado el 16 de abril de 2020; con un arreglo de 0.76 x 0.1 m distancia entre hileras y plantas respectivamente. La parcela se regó realizando un balance hídrico climático con la metodología aplicada por Servin et al., (2017) y utilizando una cintilla de riego auto compensada calibre 6 mil con emisores espaciados a 0.2 m y caudal de emisores de 0.94 l h⁻¹, para determinar la lámina aplicada se colocó un medidor volumétrico. La fertilización se hizo con 40 y 60 unidades de nitrógeno y fósforo, respectivamente, fraccionando la aplicación durante el ciclo del cultivo. Otras labores culturales como control de malezas, enfermedades y plagas, se realizaron cuando fue requerido con base en el manejo convencional estándar recomendado por el INIFAP. Los muestreos de biomasa se realizaron los 13, 25, 36, 48, 62, 77,

89, 104 y 121 días después de la siembra (DAP). Las muestras se dividieron en hojas, tallo y vainas. Posteriormente, las muestras de los diferentes tejidos se secaron en horno a 65 °C a masa constante por 72 h. El rendimiento total de materia seca aérea o biomasa (Bio) se determinó sumando la masa seca de las hojas, tallos y vainas.

4.3.2. Descripción del modelo para crecimiento de cultivos SIMPLE

El modelo SIMPLE, dinámico, propuesto por Zhao et., (2019) simula el crecimiento, el desarrollo y el rendimiento de los cultivos utilizando un paso de tiempo diario, con funciones o ecuaciones que explican el efecto de la temperatura diaria, el estrés por calor, la disponibilidad de agua en el suelo y la concentración atmosférica de CO₂ (Zhao et al., 2019). El tiempo-térmico (TTi, °C d⁻¹) y producción de biomasa seca (Bio, t ha⁻¹) son las variables de estado y el rendimiento de grano (Y, t ha⁻¹) es una variable de salida. El modelo SIMPLE requiere 13 parámetros, nueve para especificar el tipo de cultivo y cuatro para caracterizar las diferencias entre variedades (Figura 4.1).




Figura 4.1. Diagrama relacional de Forrester del modelo SIMPLE, Estados (rectángulos), tasas de cambio (válvulas), parámetros (línea horizontal y círculo con relleno negro) entrada (línea horizontal y círculo). Los flujos de material se representan mediante flechas normales y los flujos de información con líneas discontinuas.

El modelo SIMPLE utiliza la temperatura acumulada para determinar el desarrollo fenológico del cultivo en cuestión (Ritchie et al., 1985) de la siguiente manera:

$$TT_{i+1} = TT_i + \Delta TT \quad (1)$$

$$\Delta TT = \begin{cases} T - T_b; & T > T_b \\ 0 & ; T \leq T_b \end{cases} \quad (2)$$

donde TT_i (°C d) es el tiempo térmico para el i -ésimo día, ΔTT (°C) es el incremento diario en temperatura, T (°C) es la temperatura media diaria y T_b (°C) es la temperatura base para el desarrollo fenológico.

La simulación del incremento de biomasa diaria, aplica el enfoque de la eficiencia del uso de la radiación (RUE) de acuerdo con Monteith, (1965), es decir, una fracción de la radiación fotosintéticamente activa (PAR) diaria es interceptada por la planta y se transforma en biomasa de cultivos.

$$Bio_{i+1} = Bio_i + \Delta Bio \quad (3)$$

$$\Delta Bio = Rs \cdot fSolar \cdot RUE \cdot f(CO_2) \cdot f(Temp) \cdot \min[f(Heat), f(Water)] \quad (4)$$

donde Bio_{i+1} (t ha⁻¹) es la biomasa acumulada diaria hasta madurez fisiológica, ΔBio (t ha⁻¹ día⁻¹) es la tasa de crecimiento diario de la biomasa y $fSolar$ es la fracción de la radiación solar interceptada por un dosel de cultivo, RUE (g MJ⁻¹ m⁻²) es la eficiencia del uso de la radiación y $f(calor)$, $f(CO_2)$, $f(Temp)$ y $f(Agua)$ son factores de corrección que favorecen o inhiben el crecimiento de biomasa.

El rendimiento de grano (Y , t ha⁻¹) es el producto de la biomasa acumulada en la madurez fisiológica por el índice de cosecha (HI). Muchas de las funciones de SIMPLE se han empleado anteriormente en otros modelos, y se describen ampliamente en Zhao et., (2019). Además, el modelo SIMPLE realiza un balance de agua en suelo con la metodología número de curva y escorrentía, utiliza los parámetros de humedad disponible ($AWC=0.123$ m³ m⁻³), coeficiente de drenaje profundo ($DDC=0.5$), número de curva de escorrentía ($RCN=0.81$) y profundidad radicular ($RDZ=600$ mm). Para estimar el estrés hídrico, el modelo utiliza el sub-modelo índice estandarizado de sequía (ARID; Woli et al., 2012).

En este estudio, para el modelo simple se realizó un análisis de incertidumbre del modelo SIMPLE, con tres escenarios de los parámetros y distribuciones uniformes 1) 10% (U_{10}), 2) 20% (U_{20}) y 3) Tsum (requerimiento de temperatura de la siembra a madurez) y Swater (estrés por agua) aplicando una distribución normal y, el resto distribución uniforme, con 20% de incertidumbre (U_{20N}), utilizando el método GLUE y datos observados de biomasa seca de cultivo de frijol. Posteriormente, el modelo se calibró utilizando un algoritmo evolución diferencial (DE). Finalmente, un segundo análisis de incertidumbre se realizó utilizando el método GLUE del modelo calibrado con los mismos datos observados de biomasa de frijol para identificar la incertidumbre de la biomasa en los tres escenarios.

4.3.3. Procedimiento Estimación de la Incertidumbre de Verosimilitud

Generalizada (GLUE).

La metodología GLUE fue desarrollada como un método de calibración y estimación de incertidumbre, la cual usa una medida de probabilidad generalizada (Beven and Binley, 1992). Ésta está basada en la simulación de monte Carlo y en la aplicación del teorema de Bayes, donde, para estimar la incertidumbre son necesarios los datos observado. GLUE permite realizar el análisis de incertidumbre de los parámetros, condiciones iniciales, condiciones de frontera o estructuras matemáticas un modelo (Ratto et al., 2001). Los pasos específicos del procedimiento GLUE aplicados al modelo SIMPLE para cada uno de los escenarios fueron:

- 1) Las funciones de distribución de probabilidad (PDF's) de los $k = 1, \dots, 13$ parámetros se establecieron considerando el límite superior e inferior de incertidumbre según el escenario (Tabla 1) y distribución uniforme (Niven, 1961) para todos los parámetros del modelo SIMPLE a excepción de Tsum y Swater en U_{20N} donde la distribución fue normal.
- 2) Se generó un conjunto aleatorio de parámetros (θ^k) a partir de las funciones de densidad de probabilidad (PDFs) previas, se obtuvieron 10,000 muestras de parámetros (N), mediante un muestreo de hipercubo latino (Mckay et al., 2000),

dando como resultado una matriz de parámetros (Θ_N^k) con dimensiones (10 000, 13).

Tabla 4.1. Valores nominales y límites de exploración de los parámetros para cada escenario, utilizados en el modelo SIMPLE para el cultivo de frijol variedad Pinto Saltillo.

Parámetro	Descripción	Nominal	U_{10}^*	U_{20}	U_{20N}	Unidades	Fuente
T_{sum}	Temperatura acumulada de siembra a madurez	1200	1080 - 1320	960 - 1440	N(1200,1500)	°C d**	B-G
HI	Índice de cosecha	0.36	0.32 - 0.4	0.29 - 0.43	0.29 - 0.43	-	B-G
I_{50A}	Temperatura acumulada requerida para el desarrollo del área foliar para interceptar el 50% de la radiación	450	405 - 495	360 - 540	360 - 540	°C d	Z
I_{50B}	Temperatura acumulativa hasta la madurez para alcanzar el 50% de intercepción de radiación debido a la senescencia de la hoja	200	180 - 220	160 - 240	160 - 240	°C d	-
T_b	Temperatura base para el desarrollo y crecimiento de la fenología	8	7.2 - 8.8	6.4 - 9.6	6.4 - 9.6	°C	B-G
T_{opt}	Temperatura óptima para el crecimiento de la biomasa	30	26 - 31	22 - 32	22 - 32	°C	B-G
RUE	Eficiencia de uso de radiación (solo sobre el suelo y sin respiración)	3.21	2.89 - 3.53	2.57 - 3.85	2.57 - 3.85	g MJ ⁻¹ m ⁻²	K
I_{50maxH}	Reducción diaria máxima en I _{50B} debido al estrés por calor	90	81 - 99	72 - 108	72 - 108	°C d	Z
I_{50maxW}	Reducción diaria máxima en I _{50B} debido al estrés por sequía	20	18 - 22	16 - 24	16 - 24	°C d	Z
T_{max}	Temperatura umbral para comenzar a acelerar la senescencia del estrés por calor	35	31.5 - 38.5	32.1 - 42	32.1 - 42	°C	O
T_{ext}	Umbral de temperatura extrema cuando RUE se convierte en 0 debido al estrés por calor	45	40.5 - 49.5	42.1 - 52.5	42.1 - 52.5	°C	Z
S_{CO2}	Aumento relativo de RUE por ppm de CO ₂ después de 350 ppm.	0.07	0.06 - 0.08	0.06 - 0.08	0.06 - 0.08	ppm	Z
S_{water}	Sensibilidad de RUE al estrés por sequía	0.9	0.81 - 0.99	0.72 - 1.08	N(0.9,0.01)	-	Z

*izquierda límite máximo y derecha límite mínimo, ** grados día. B-G=Báez-Gonzales et al., (2020), Z=Zhao et al., (2019), K=Karimzadeh et al., (2018), O=Omae et al., (2012)

3) Las N simulaciones del modelo SIMPLE se ejecutaron cambiando el vector de parámetros. En este paso se incluye el vector de datos observados de biomasa (Qobs; t ha⁻¹) de dimensiones (1,Q) para cada tiempo de muestreo de campo (j),

para cada simulación se extraen la biomasa simulada ($Q_{sim}; t_{ha-1}$), donde coincide el tiempo de muestreo (j) y el tiempo de simulación (i) y se obtuvo una matriz de biomasa simulada (N, Q), de siembra a madurez fisiológica para cada tiempo j .

4) Se calcularon los valores de verosimilitud y probabilidad. Se utilizó la raíz cuadrada del error medio (RMSE), para definir la función de verosimilitud generalizada $L(S_i|O)$. El RMSE es una estadística de bondad de ajuste que mide el grado de error existente entre las variables observadas o medidas (Q_{obs}) y la variable de salida simulada por el modelo (Q_{sim}) y fue utilizado por Pianosi et al., (2015) y Martínez-Ruiz et al., (2021a). El RMSE se calculó con la ecuación:

$$L(S_i|O) = RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{j=1}^q (O_i - S_i)^2} \quad (5)$$

donde O_i representa el valor observado, S_i el valor predicho por el modelo SIMPLE, y n el número de observaciones.

También se definió la frecuencia de muestreo aceptadas (ASR; Tan et al., 2019), la cual es una medida de aptitud como variable de decisión para realizar un muestreo aceptable e identificar los vectores de parámetros que generen los mejores valores de $L(S_i|O)$. Considerando el 10% de los mejores valores se consideran como ASR (Etminan et al., 2022) para este estudio los 1000 valores más bajos de $L(S_i|O)$ se consideraron aceptables.

Para obtener la función de probabilidad acumulada $p(S_i)$, de cada conjunto de $L(S_i|O)$ se utilizó la siguiente ecuación bayesiana:

$$p(S_i) = \frac{L(S_i|O)}{\sum_{i=1}^N L(S_i|O)} \quad (6)$$

En este paso los $L(S_i|O)$ se escalan para tener la probabilidad acumulada total igual a 1.

Para describir la variabilidad de los valores simulados y observados se obtuvieron los intervalos de confianza superior (L. Superior) e inferior (L. Inferior) con un intervalo de confianza ($\alpha = 0.05$).

$$L.Inferior = p(S_i) < a \quad (7)$$

$$L.Superior = p(S_i) > (1 - a) \quad (8)$$

5) Se determinaron estadísticas de la distribución de salida (media, desviación estándar, coeficiente de variación, asimetría, curtosis) Se realizó un gráfico de dispersión del RMSE de la biomasa, el rango de exploración de cada parámetro y se obtuvo el vector de parámetros que minimiza los valores del RMSE.

El análisis de incertidumbre con el procedimiento GLUE se implementó en el ambiente de programación MATLAB con la herramienta Sensitivity Analysis for Everybody (SAFE) (Pianosi et al., 2015).

4.3.4.- Calibración del modelo SIMPLE

Previo a la calibración del modelo SIMPLE, se realizó un Análisis de Sensibilidad Global (GSA) con el método de Sobol (Saltelli et al., 2008) aplicando el 20% de incertidumbre y los parámetros (Tsum, Swater, Tbase, Topt, I50A y I50maxW) que mostraron valores de índice de sensibilidad total mayores al 10% en tiempo térmico y biomasa fueron seleccionados.

La calibración se realizó con el algoritmo de evolución deferencial (DE). Ésta es una técnica heurística de búsqueda estocástica de estructura simple, eficiente, robusta y usa la codificación de punto flotante. Además, uno de los optimizadores más potentes en el campo de computación evolutiva (Qin and Li., 2013). DE se inspira en el algoritmo evolutivo y se resuelve iterativamente, inicia con una población aleatoria, que luego se combinan y actualizan para mejorarla mediante operaciones de selección, mutación y cruce. También, es utilizado para revolver problemas complejos (Trejo-Zúñiga et al., 2014; Martínez-Ruiz et al., 2021b), DE minimiza la función objetivo mapeando un vector de parámetros estratégicos (Storn and Price 1997). Donde la función objetivo y las medidas de desempeño juegan un papel preponderante para identificar el vector de parámetros óptimos del modelo.

El modelo de cultivo SIMPLE se calibró resolviendo un problema de optimización, buscando los parámetros que minimizan la distancia entre los datos observados y simulados, la función objetivo-empleada es de la siguiente manera:

$$\hat{p} = \arg \min J(p) \quad (9)$$

$$J(p) = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i(t_i, p) - O_i(t_i))^2} \quad (10)$$

donde: $S_i(t_i, p)$ es la biomasa predicha por el modelo SIMPLE en el tiempo t_i y $O_i(t_i)$ es la variable medida en el tiempo t_i , N es el número de muestras durante el período de crecimiento, p es el vector de parámetros establecidos para la calibración y $\hat{p}$ es el vector de parámetros que produce el valor mínimo de $J(p)$.

Para evaluar el impacto de la función objetivo en los resultados de calibración, se utilizaron las siguientes funciones como medidas de desempeño: 1) el sesgo de simulación (BIAS), 2) el error absoluto medio (MAE), 3) la raíz del error cuadrático medio (RMSE) (Heng et al., 2009), y 4) la eficiencia propuesta por Nash y Sutcliffe (EF) (Krause et al., 2005).

4.4.- Resultados y discusión

4.4.1.- Datos de clima

La precipitación durante el ciclo del cultivo fue de 405 mm. Si bien en los últimos 17 años (2002 a 2019), en promedio, la precipitación fue de 287.8 mm, esto sugiere que el experimento se estableció en un año atípico en cuanto a precipitación pluvial. Esto, último fue particularmente especialmente para el mes julio, donde se registró 57 % más de precipitación que el promedio histórico mensual (104.3 mm). Esta situación fue generada en parte por el Huracán Hanna (23 al 27 de julio) que impacto Texas, E.U., la cual se desplazó hacia el norte de México y produjo lluvias significativas (Pascual et al., 2021). En cuanto a las temperaturas medias para el ciclo vegetativo fueron de 28.49 y 9.07 °C y las medias históricas de 28.6 y 8.12 °C para Tmax y Tmin respectivamente, observándose un aumento de Tmin (Figura 2).

La calendarización del riego, mediante balance hídrico climático resultó en la aplicación de 16 riego durante el desarrollo del cultivo desde siembra hasta madures fisiológica. La lámina de riego acumulada para el tratamiento fue de 356 mm; mientras que 244 mm fueron atribuidos a la precipitación efectiva acumulada. Así

hubo un total de 600 mm de agua almacenada en la zona radicular. La humedad residual después de la cosecha se estimó en 21 mm. Allen et al. (1998) citado por Beebe et al., (2011), mencionan que dependiente de medio ambiente, los requerimientos hídricos para el frijol oscilan entre 300 y 500 mm.




Figure 4.2. Variables climáticas recolectadas durante la estación de crecimiento con medias históricas (17 años) de la estación CEZAC-INIFAP *quincenal




Figure 4.3. Irrigation water applied (mm) during the growing season.

4.4.2.- Incertidumbres sin calibración

Los promedios ($\pm$ desviación estándar) de RMSE de la variable de salida biomasa fueron de 2.26 ± 0.50 , 2.34 ± 0.87 y 2.33 ± 0.73 con coeficientes de variación (CV) de 0.22, 0.37 y 0.30, curtosis. 2.70, 7.78 y 3.84 y asimetría 0.17, 1.28 y 0.77 para U10, U20 y U20N, respectivamente. Se observa una tendencia en el incremento de la media y mayor dispersión de los datos a medida que se incrementa la incertidumbre, sin embargo, al aplicar una distribución normal en los parámetros más influyentes (U20N) la media y la desviación estándar disminuye con respecto a U20. El CV en U20 es muestra heterogeneidad, es decir hubo mayor dispersión y la media no fue representativa de los datos. Brown (1998) mencionó que CV superiores al 30% indica problemas en la recolección de los datos o no se tuvo un adecuado control en el experimento. La curtosis indicó que la media aritmética fue mayor que la mediana, en U10 hay una caída lenta, mientras que en U20 y U20N la caída es abrupta; también, los datos se cargaron levemente a la izquierda en U20 y U20N, mientras que en U20 los datos presenta una asimetría moderada positiva. El comportamiento del RMSE de la biomasa simulada y observada sugirió falta de normalidad (Figura 3).




Figura 4.4. Histograma de RMSE de los valores de biomasa observados y simulados por el modelo SIMPLE para los tres escenarios: a) escenarios U10 b) escenario U20 c) escenario U20N

Los valores máximos de RMSE fueron 4.00, 9.43 y 7.46 y el 10% de las funciones de verosimilitud aceptadas (RSA) se presentaron por debajo de 1.61, 1.35 y 1.51 de RMSE, para U10, U20, U20N, respectivamente. Los valores máximos fueron proporcionales a la incertidumbre y las RSA fueron inversamente proporcionales a la incertidumbre, aplicada en U10 y U20. Sin embargo, en U20N no se observó dichas tendencias. Lo que implica que el rango de exploración de los parámetros al 20% favorece el ajuste, pero el RMSE máximo es mayor con respecto a U10, aunque, aplicar distribución normal a los parámetros más sensibles evitamos que los valores de los parámetros salgan la barrera física. Martínez-Ruiz et al., (2021a) evaluaron un 10% y 20% de incertidumbre en los parámetros del modelo HORTSYST y, concluyeron que, con un intervalo de incertidumbre más pequeño, hubo menos incertidumbre en todas las variables predichas.

Los intervalos de confianza fueron más amplios cuando se asignó mayor incertidumbre a los parámetros (Figura 4). En U10 los datos de biomasa observados quedaron fuera de los límites de confianza, es decir, la incertidumbre aplicada a los parámetros para este escenario no contempla completamente a los datos observados. Sin embargo, aplicar el 20% de incertidumbre en U20, el límite superior muestra una función sigmoidea y no representa la tendencia del crecimiento de un cultivo anual. Pascual-Ramírez et al. (2012) mencionaron que el crecimiento de la biomasa es expo-lineal con tres etapas 1) crecimiento exponencial, 2) etapa de transición y 3) modelo lineal. Tal como y como se muestra el comportamiento en el escenario U20N, Etminan et al. (2022) indicaron que a mayor ancho de los intervalos es indicativo de mayor sensibilidad en la variable de salida, Por otro lado, Lu et al., (2009) mencionan que cambiar la distribución de los parámetros más influyentes se puede hacer mejor inferencia sobre los parámetros.




Figura 4.5. Intervalos de confianza con GLUE del modelo SIMPLE con datos observado de frijol en Zacatecas para los tres escenarios. A) U10, B) U20 y C) U20N.

El vector de parámetros que minimizan el RMSE con el modelo sin calibrar (Vmin1) obtenidos mediante la metodología GLUE, muestra una tendencia de Tsum, RUE y Tbase en los límites superiores y Topt, I50maxW en los límites inferiores para U10 y U20. Para U20N, Tsum estuvo cercano al valor nominal, sin embargo, I50A, Tbase y SCO2 se acercan a los valores del límites superior y I50B, Topt y I50maxW al límite inferior (Tabla 3). Por otro lado, El Vmin1 mostro un RMSE fue de 0.75, 0.57 y 0.58 t ha⁻¹, la eficiencia de 0.96, 0.98 y 0.98 y un tiempo de simulación de 126, 134 y 124 días para U10, U20 y U20N respectivamente, para simular la biomasa. Tsum es el parámetro que está relacionado con la longitud de ciclo vegetativo, por tal razón, al aplicar incertidumbre a este parámetro se debe considerar que los días después de siembra (dds) este en un rango aceptable. Sánchez, (2001) menciona que el ciclo vegetativo para frijol ‘Pinto Saltillo’ oscila entre 115 y 123 dds. Es decir, al incrementar la incertidumbre da pie a hacer inferencias erróneas sobre este parámetro. No obstante, conviene explorar otros límites u otras distribuciones para los parámetros que tienden a los extremos. Es imperativo cuidar las fronteras de la física debido a que los procesos de la naturaleza, no son deterministas, sino estocásticos (Wilkinson, 2006; Wallach et al., 2018); además, otros vectores de parámetros pueden llevar a los misma medidas de desempeño (Beven and Binley, 1992).

Tabla 4.2. Vector de parámetros que minimiza el RMSE en cada uno del escenario con el modelo SIMPLE en frijol establecido en Zacatecas, México

Escenario	Tsum	HI	I50A	I50B	Tbase	Topt	RUE	I50maxH	I50maxW	Theat	Text	SCO2	Swater
U10	1312.62	0.34	480.54	196.30	8.78	28.22	3.42	96.78	18.28	37.88	46.24	0.08	0.83
U20	1376.71	0.36	510.42	171.92	9.03	23.68	3.05	94.68	17.69	36.48	49.32	0.06	1.02
U20N	1221.23	0.33	535.95	177.96	9.40	23.72	3.03	85.73	17.79	38.47	47.71	0.08	0.74

La incertidumbre de los parámetros del modelo para cada uno de los escenarios fue analizada usando las gráficas de puntos y representan la superficie de respuesta de bondad de ajuste proyectada sobre las dimensiones de los parámetros individuales (Figura 5). Los valores de RMSE están disperso en toda la gama de exploración de los parámetros HI, I50B, I50maxH, Theat, Text y SCO2, por otro lado, Topt, I50maxW y Swater se proyectaron a los valores más bajos, mientras que Tsum, I50A, Tbase y RUE se proyectaron a los valores más altos. Los valores que se proyectaron a los extremos tuvieron mayor influencia en el modelo y es conveniente estimarlos, mientras el resto fueron indiferentes. Una distribución en forma parabólica de los errores en el parámetro es indicativa de alta precisión de estimación; mientras que una distribución plana indica un parámetro incierto (Jin et al. 2010).




Figura 4.6. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U10, los puntos negros representan el 10% de los valores más bajos.

Al aplicar 20% de incertidumbre en los parámetros se observó que el valor de RMSE aceptado de 10% de los valores más bajos, disminuye, sin embargo, los valores de RMSE estuvieron dispersos en toda la gama de exploración de los parámetros, excepto en Tsum (Figura 6). Tsum fue uno de los parámetros más influyentes del modelo, lo que sugirió que al aplicar más incertidumbre afectó el desempeño de los demás parámetros, debido a la interacción que existe entre dos o más parámetros. Teweldebrhan et al. (2018) realizaron un análisis de correlación entre parámetros y observaron interacción entre los parámetros de un modelo hidrológico. Esto último indicó que, individualmente, los parámetros fueron pocos sensibles, pero en interacción con otros parámetros fueron altamente sensibles.




Figura 4.7. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U20, los puntos negros representan el 10% de los valores más bajos.

En U20N se observó que el 10% de los valores de RMSE (RSA) de los parámetros se distribuyeron a los extremos de exploración, es decir, los parámetros se pueden estimar con mayor precisión contrario a U20 donde los RSA distribuyen en toda el área de exploración y su estimación es incierta. En la figura 7 se observa que el parámetro Tbase y RUE se proyectaron hacia los valores más altos, mientras que I50B, Topt y I50maxW hacia los valores más bajos, Tsum y Swater se ubicaron sobre el valor nominal y el resto estuvieron dispersos en toda la gama de exploración. Confalonieri et al. (2016) mencionaron que la importancia de los usuarios de un modelo para generar distribuciones de los parámetros significativas y confiables; sin embargo, hasta ahora, no hay registro de análisis de incertidumbre del modelo SIMPLE para frijol.




Figura 4.8. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U25N, los puntos negros representan el 10% de los valores más bajos.

4.4.3. Resultados de la calibración del modelo SIMPLE

El modelo de cultivo SIMPLE se calibró resolviendo el problema de optimización con los parámetros Tsum, I50A, Tbase, Topt, I59maxW y Swater, Parámetros influyente de acuerdo al resultado de un análisis de sensibilidad global por el método de Sobol (Saltelli et al., 2008). Los valores de los parámetros calibrados y los estadísticos al modelo de desempeño se indican en la Tabla 4.4 El RMSE más bajo y la eficiencia (EF) más alta indican una buena predicción de la biomasa con el modelo SIMPLE. Martínez-Ruiz et al., (2021b) mencionaron que los valores de RMSE cercanos a cero muestran un excelente desempeño.

Table 4.3. Parameter values after the differential evolution (DE) calibration process and goodness of fit statistics of the SIMPLE model for bean in Zacatecas, Mexico.

Parámetros	Vector sub-óptimo
Tsum	$1313.22 \pm (2.35 \times 10^{-13})$
I50A	$539.97 \pm (1.18 \times 10^{-13})$
Tbase	$8.96 \pm (1.84 \times 10^{-15})$
Topt	$24 \pm (7.35 \times 10^{-15})$
I50maxW	$18.55 \pm (0.01 \times 10^{-15})$
Swater	$0.52 \pm (0.01 \times 10^{-15})$
Bias	-0.10
MAE	0.45
RMSE	0.60
EF	0.98

Para el análisis de incertidumbre con el modelo calibrado se utilizaron los valores parámetros calibrados (Tabla 4.4) y los valores nominales (Tabla 4.2) según corresponda para generar el nuevo vector de parámetros nominales, El análisis GLUE se realizó para los mismos tres escenarios.

4.4.4.- Análisis de incertidumbre con calibración

Los promedios de RMSE de la variable de salida biomasa se incrementaron en 20% y la desviación estándar en 64%, El CV se encontró por encima del 30% para los tres escenarios con respecto a los datos descritos en el capítulo 3.2 del análisis de incertidumbre con el modelo sin calibración. Es decir, hubo mayor dispersión de los datos, los valores máximos de RMSE fueron superiores al 40% con respecto al análisis sin calibrar. Esto último, evidenció que hubo muchos valores inciertos con una reducción del 20% del RMSE de las RSA. También, se observaron distribuciones planas con decaimiento lento de los datos fueron observadas en U10 y U20N. En contraste, el escenario U20 tuvo un decaimiento abrupto, todos los escenarios tuvieron una asimetría positiva (Figura 9).




Figura 4.9. Histograma de RMSE de los valores de biomasa observados y simulados por el modelo SIMPLE usando parámetros calibrados, para los tres escenarios: a) escenarios U10 b) escenario U20 c) escenario U25N

Para el análisis GLUE con el modelo calibrado, independientemente de la incertidumbre aplicada, los datos observados se ubicaron dentro de los intervalos de confianza (Figura 10). Los límites superiores muestran funciones sigmoideas, mientras que los límites inferiores presentaron una tendencia sigmoidea, pero con una meseta más marcada. No obstante que a los 36 y 89 dds se observó una desviación en la tendencia de los datos observados de biomasa, los intervalos de confianza estuvieron directamente relacionados con los datos observados. Esa discrepancia pudo deberse a un error de muestreo lo cual a su vez generó mayor

incertidumbre los valores de biomasa observados. Eso constituye un tema pendiente en la mayoría de los análisis de incertidumbre (Chapagain et al., 2022).




Figura 4.10. Intervalos de confianza con GLUE del modelo calibrado SIMPLE con datos observado de frijol en Zacatecas para los tres escenarios. A) U10, B) U20 y C) U20N.

El vector de parámetros que minimizan el RMSE con el modelo calibrado (Vmin2) generados con la metodología GLUE, se observa que los valores del parámetro Tsum tienden hacia el valor nominal, HI, I50A, I50B, I50maxW y Swater, los cuales estuvieron más cercanos a los límites superiores para el escenario U10. En tanto que, I50A y RUE estuvieron cercanos al límite superior y I50B y Tbase al límite inferior en el escenario U20. En el escenario U20N, Text tendió al límite superior y I50maxH y I50maxW al límite inferior (Tabla 5). Por otro lado, El Vmin2 mostro un RMSE fue de 0.56, 0.47 y 0.55 t ha⁻¹, la eficiencia de 0.98, 0.98 y 0.98 y un tiempo de simulación de 118, 101 y 114 días para U10, U20 y U20N respectivamente, para simular la biomasa. Los resultados indican que, la incertidumbre aplicada y las distribuciones utilizadas, no afectaron los intervalos de confianza, pero si incide en el vector de los parámetros que minimizan el RMSE. Por lo tanto, especial cuidado debe darse a la definición de los parámetros influyentes cuando se utilice la metodología GLUE para calibración de modelos de crecimiento.

Tabla 4.4. Vector de parámetros que minimiza el RMSE en cada uno del escenario con el modelo SIMPLE en frijol establecido en Zacatecas, México

Escenario	Tsum	HI	I50A	I50B	Tbase	Topt	RUE	I50maxH	I50maxW	Theat	Text	SCO2	Swater
U10	1259.38	0.39	587.12	218.73	8.67	24.72	3.23	93.63	20.17	36.31	46.40	0.06	0.56
U20	1182.01	0.32	637.16	170.84	7.81	26.57	3.72	82.05	20.25	38.58	46.16	0.07	0.46
U20N	1188.72	0.33	587.03	197.60	8.94	23.07	3.52	74.55	15.72	34.75	51.64	0.08	0.72

Al realizar el grafico de dispersión del RMSE para cada parámetro (Figura 4.10, 4.11 y 4.12) se observó una baja resolución debido a los valores altos de RMSE y las tendencias de las RSA se distribuyen en toda el área de exploración y es difícil identificar su influencia en el modelo, sin embargo, los Tsum y RUE se extienden a los valores más bajos, Topt, I50A, Swater y I50maxW se dispersan a los valores más altos para el escenario U10. En U20 con el modelo calibrado los valores de RMSE están disperso a los valores más bajos en los parámetros Tsum y RUE, mientras que los parámetros Topt, I50A y Swater los valores de RMSE se extiende a los valores más altos, los valores que se extienden a los extremos son más influyentes, aunque se observa que al aplicar 20% de incertidumbre el RMSE de I50maxW se distribuye en toda la gama de exploración con respecto a U10, por lo tanto, aplicar demasiada incertidumbre parámetros que son influyentes no expresan su efecto en el modelo. Para el escenario U20N los parámetros I50A, Swater, I50masW y Topt se dispersan a los valores más bajos y Tsum y RUE a los valores más altos y el resto están dispersos en toda la gama de exploración. Los resultados indican que, si se quiere hacer inferencia sobre las distribuciones de la variable de salida biomasa, se deben considerar únicamente el 10% de los valores más bajos de RMSE considerados en este estudio para determinar la RSA y evitar sesgo.




Figura 4.11. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U10 con el modelo calibrado, los puntos negros representan el 10% de los valores más bajos (RSA).




Figura 4.12. Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U20 con el modelo calibrado, los puntos negros representan el 10% de los valores más bajos (RSA).




Figura 4.13.- Proyección de RMSE de la salida sobre el rango de exploración en cada parámetro identificados mediante la metodología GLUE para el escenario U25N con el modelo calibrado, los puntos negros representan el 10% de los valores más bajos (RSA).

4.5.- Conclusiones

Es necesario aplicar distribución normal a los parámetros más influyentes (Tsum y Swater) para identificar los parámetros más sensibles en el análisis de incertidumbre con el modelo SIMPLE sin calibrar, garantizan la expresión de los parámetros que se enmascaran al aplicar demasiada incertidumbre.

Calibrar los parámetros, Tsum, I50A, Tbase, Topt, I50maxW y Swater muestran un buen desempeño para simular el rendimiento de la biomasa de frijol en condiciones de riego.

El análisis de incertidumbre con el método GLUE utilizando el modelo SIMPLE calibrado indican que la incertidumbre aplicada a los parámetros en cada uno de los escenarios no tiene influencia en los intervalos de confianza, sin embargo, al utilizar el modelo SIMPLE sin calibrar se recomienda utilizar distribución normal en Tsum y Swater.

Al utilizar el grafico de puntos del RMSE para cada parámetro se recomienda utilizar únicamente las funciones de verosimilitud aceptadas (RSA) ya que los valores

atípicos de RMSE bajan la resolución, esto ocasiona que se observe una colocación de las RSA sobre toda la gama de exploración del parámetro, lo que orillaría a hacer inferencias erróneas sobre los parámetros.

El utilizar el modelo calibrado para realizar el análisis de incertidumbre con el método GLUE se observaron algunos valores atípicos (valores de RMSE muy altos), aunque, los valores de RMSE de las RSA fueron menores, sin embargo, utilizar distribución normal en los parámetros Tsum y Swater se observó menos valores atípicos, además, cuando Tsum es muy cercano al valor nominal garantiza que las simulaciones del modelo SIMPLE sean más confiables y alineadas a la realidad.

4.6.- Referencias

- Allen, R. G.; Pereira, L. S.; Raes, D. y Smith, M. (2006). Evapotranspiración del cultivo: guía para la determinación de los requerimientos de agua de los cultivos. Estudio FAO Riego y Drenaje. FAO, Roma. 2006. 56-323 pp.
- Baez-Gonzalez, A. D., Fajardo-Díaz, R., Garcia-Romero, G., Osuna-Ceja, E., Kiniry, J. R., & Meki, M. N. (2020). High Sowing Densities in Rainfed Common Beans (*Phaseolus vulgaris* L.) in Mexican Semi-Arid Highlands under Future Climate Change. *Agronomy*, 10(3), 442.
- Beebe, S., Ramirez, J., Jarvis, A., Rao, I. M., Mosquera, G., Bueno, J. M., & Blair, M. W. (2011). Genetic Improvement of Common Beans and the Challenges of Climate Change Crop Adaptation to Climate Change (pp. 356-369).
- Beven, K., & Binley, A. (1992). The future of distributed models: model calibration and uncertainty prediction. *Hydrological processes*, 6(3), 279-298.
- Beven, K., & Freer, J. (2001). Equifinality, data assimilation, and uncertainty estimation in mechanistic modelling of complex environmental systems using the GLUE methodology. *Journal of hydrology*, 249(1-4), 11-29. [https://doi.org/10.1016/S0022-1694\(01\)00421-8](https://doi.org/10.1016/S0022-1694(01)00421-8)
- Bhar, A., Kumar, R., Qi, Z., & Malone, R. (2020). Coordinate descent based agricultural model calibration and optimized input management. *Computers and Electronics in Agriculture*, 172, 105353. <https://doi.org/10.1016/j.compag.2020.105353>
- Blasone, R.-S., Vrugt, J. A., Madsen, H., Rosbjerg, D., Robinson, B. A., & Zyvoloski, G. A. (2008). Generalized likelihood uncertainty estimation (GLUE) using adaptive Markov Chain Monte Carlo sampling. *Advances in Water Resources*, 31(4), 630-648. doi: <https://doi.org/10.1016/j.advwatres.2007.12.003>
- Brown, C. E. (1998). Coefficient of Variation. *Applied Multivariate Statistics in Geohydrology and Related Sciences*, 155–157. doi:10.1007/978-3-642-80328-4_13.
- Cacuci, D. G., Ionescu-Bujor, M., & Navon, I. M. (2005). Sensitivity and uncertainty analysis, volume II: applications to large-scale systems. CRC press.

- Chapagain, R., Remenyi, T. A., Harris, R. M., Mohammed, C. L., Huth, N., Wallach, D., ... & Ojeda, J. J. (2022). Decomposing crop model uncertainty: A systematic review. *Field Crops Research*, 279, 108448.
- Confalonieri, R., Orlando, F., Paleari, L., Stella, T., Gilardelli, C., Movedi, E., . . . Acutis, M. (2016). Uncertainty in crop model predictions: What is the role of users? *Environmental Modelling and Software*, 81, 165-173. doi: 10.1016/j.envsoft.2016.04.009
- Dzotsi, K. A., Basso, B., & Jones, J. W. (2015). Parameter and uncertainty estimation for maize, peanut and cotton using the SALUS crop model. *Agricultural Systems*, 135, 31-47. doi: 10.1016/j.agsy.2014.12.003
- Etminan, S., Jalali, V., Mahmoodabadi, M., Khashei Siuki, A., & Pourreza Bilondi, M. (2022). GLUE algorithm capability in estimating the van Genuchten soil–water characteristic parameters and their uncertainties. *Paddy and Water Environment*. doi: 10.1007/s10333-021-00886-z
- Graeff, S., Link, J., Binder, J., & Claupein, W. (2012). Crop Models as Decision Support Systems in Crop Production. *Crop Production Technologies*, Sharma, P.(ed.), 1-28.
- Helton, J. C., & Davis, F. J. (2002). Illustration of sampling-based methods for uncertainty and sensitivity analysis. *Risk analysis*, 22(3), 591-622.
- Heng, L. K., Hsiao, T., Evett, S., Howell, T., & Steduto, P. (2009). Validating the FAO AquaCrop model for irrigated and water deficient field maize. *Agronomy journal*, 101(3), 488-498. <https://doi.org/10.2134/agronj2008.0029xs>
- Jin X, Xu CY, Zhang Q, Singh VP (2010) Parameter and modeling uncertainty simulated by GLUE and a formal Bayesian method for a conceptual hydrological model. *J Hydrol* 383(3–4):147–155
- Karimzadeh Soureshjani, H., Nezami, A., Kafi, M., & Tadayon, M. (2019). Responses of two common bean (*Phaseolus vulgaris* L.) genotypes to deficit irrigation. *Agricultural Water Management*, 213, 270-279. doi: <https://doi.org/10.1016/j.agwat.2018.09.038>
- Keesman, K. J., Koskela, J. J., Guillaume, J., Norton, J., Croke, B., & Jakeman, A. (2011). Uncertainty modelling and analysis of environmental systems: a river sediment yield example.
- Krause, P., D. P. Boyle, and F. Bäse. 2005. Comparison of different efficiency criteria for hydrological model assessment. *Adv. Geosci.* 5: 89-97.
- Li, Z., He, J., Xu, X., Jin, X., Huang, W., Clark, B., . . . Li, Z. (2018). Estimating genetic parameters of DSSAT-CERES model with the GLUE method for winter wheat (*Triticum aestivum* L.) production. *Computers and Electronics in Agriculture*, 154, 213-221. doi: <https://doi.org/10.1016/j.compag.2018.09.009>
- Lu L, Jun X, Chong-Yu X, Jianjing C, Rui W (2009) Analysis of the sources of equifinality in hydrological models using GLUE methodology. *Hydro informatics in hydrology, hydrogeology and water resources*. Paper presented at symposium JS.4 Hyderabad, India, September
- Martínez-Ruiz, A., López-Cruz, I. L., Ruiz-García, A., Pineda-Pineda, J., Sánchez-García, P., & Mendoza-Pérez, C. (2021). Uncertainty analysis of the HORTSYST model applied to fertigated tomatoes cultivated in a hydroponic greenhouse system. 2021, 19(3). doi: 10.5424/sjar/2021193-17842
- Martínez-Ruiz, A., Ruiz-García, A., Prado-Hernández, J. V., López-Cruz, I. L., Valencia-Islas, J. O., & Pineda-Pineda, J. (2021b). Global Sensitivity Analysis and Calibration

- by Differential Evolution Algorithm of HORTSYST Crop Model for Fertigation Management. *Water*, 13(5). doi: 10.3390/w13050610
- Mckay, M. D., Beckman, R. J., & Conover, W. J. (2000). A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output From a Computer Code. *Technometrics*, 42(1), 55–61. doi:10.1080/00401706.2000.10485979
- Monteith, J.L., 1965. Light distribution and photosynthesis in field crops. *Ann. Bot.* 29 (113), 17–37.
- Niven, Ivan. “Uniform Distribution of Sequences of Integers. 1961,” *Transactions of the American Mathematical Society*, vol. 98, no. 1, American Mathematical Society, pp. 52–61, <https://doi.org/10.2307/1993512>.
- Omae, H., Kumar, A., & Shono, M. (2012). Adaptation to high temperature and water deficit in the common bean (*Phaseolus vulgaris* L.) during the reproductive period. *Journal of Botany*, 2012.
- Pascual Ramirez Reynaldo , Lopez Quiroz Minerva , Chable Pech Luis A, Yenifeer, L. D., I., L. L. J., G., Z. F. A., & E., M. i. M. A. (2021). Reporte del Clima en Mexico In 2020 (Ed.), (Aurora Guadalupe Zavala Fajardo ed., Vol. 1, pp. 98): Comision Nacional del Agua y Coordinacion General del Servicio Meteorológico Nacional. <https://smn.conagua.gob.mx/es/reportes-del-clima-en-mexico>
- Pascual-Ramírez, F., Paz-Pellat, F., & Bolaños-González, M. (2012). Estimation of aerial biomass on crops using remote sensing. *Terra Latinoamericana*, 30(1), 17-28.
- Pianosi, F., Sarrazin, F., Wagener, T., (2015). A Matlab toolbox for global sensitivity analysis. *Environ. Model. Softw.* 70, 80e85. <http://dx.doi.org/10.1016/j.envsoft.2015.04.009>.
- Qin, A. K., & Li, X. (2013). Differential evolution on the CEC-2013 single-objective continuous optimization testbed. 2013 IEEE Congress on Evolutionary Computation. doi:10.1109/cec.2013.6557689
- Ratto, M., Tarantola, S., & Saltelli, A. (2001). Sensitivity analysis in model calibration: GSA-GLUE approach. *Computer Physics Communications*, 136(3), 212-224. doi: [https://doi.org/10.1016/S0010-4655\(01\)00159-X](https://doi.org/10.1016/S0010-4655(01)00159-X)
- Ritchie, J.T., Godwin, D.C., Otter-Nacke, S., 1985. CERES-wheat: A User-oriented Wheat Yield Model. Preliminary Documentation. AGRISTARS Publication No. YM-U3-04442-JSC-18892. Michigan State University, Michigan.
- Saddique, Q., Zou, Y., Ajaz, A., Ji, J., Xu, J., Azmat, M., . . . Cai, H. (2020). Analyzing the performance and application of ceres-wheat and apsim in the Guanzhong plain, China. *Transactions of the ASABE*, 63(6), 1879-1893. doi: 10.13031/TRANS.13631
- Saltelli, A., Ratto, M., Andres, T., Campolongo, F., Cariboni, J., Gatelli, D., ... & Tarantola, S. (2008). *Global sensitivity analysis: the primer*. John Wiley & Sons.
- Sánchez, V. I. (2001). Pinto Saltillo: nueva variedad de frijol para el sureste del Estado de Coahuila. INIFAP Campo Experimental “Saltillo”. Folleto Técnico Núm. 8. 2 p. <http://www.inifapcirne.gob.mx/Biblioteca/Publicaciones/678.pdf>
- Servín Palestina, M., Tijerina Chávez, L., Medina García, G., Palacios Velez, O., & Flores Magdaleno, H. (2017). Sistema para programar y calendarizar el riego de los cultivos en tiempo real. *Revista mexicana de ciencias agrícolas*, 8(2), 423-430.
- Sheng, M., Liu, J., Zhu, A. X., Rossiter, D. G., Liu, H., Liu, Z., & Zhu, L. (2019). Comparison of GLUE and DREAM for the estimation of cultivar parameters in the APSIM-maize model. *Agricultural and Forest Meteorology*, 278. doi: 10.1016/j.agrformet.2019.107659

- Sheng, M., Liu, J., Zhu, A. X., Rossiter, D. G., Liu, H., Liu, Z., & Zhu, L. (2019). Comparison of GLUE and DREAM for the estimation of cultivar parameters in the APSIM-maize model. *Agricultural and Forest Meteorology*, 278. doi: 10.1016/j.agrformet.2019.107659
- Storn, R., & Price, K. (1997). Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4), 341-359. <https://doi.org/10.1023/A:1008202821328>
- Tan, J., Cao, J., Cui, Y., Duan, Q., & Gong, W. (2019). Comparison of the generalized likelihood uncertainty estimation and markov chain Monte Carlo methods for uncertainty analysis of the oryza_v3 model. *Agronomy Journal*, 111(2), 555-564. doi: 10.2134/agronj2018.05.0336
- Tan, J., Zhao, S., Liu, B., Luo, Y., & Cui, Y. (2021). Global sensitivity analysis and uncertainty analysis for drought stress parameters in the ORYZA (v3) model. *Agronomy Journal*, 113(2), 1407-1419. doi: 10.1002/agj2.20580
- Teweldebhran, A. T., Burkhart, J. F., & Schuler, T. V. (2018). Parameter uncertainty analysis for an operational hydrological model using residual-based and limits of acceptability approaches. *Hydrology and Earth System Sciences*, 22(9), 5021-5039.
- Trejo-Zúñiga, E. C., López-Cruz, I. L., & Ruíz-García, A. (2013). Parameter estimation for crop growth model using evolutionary and bio-inspired algorithms. *Agrociencia*, 47(7), 671-682.
- Trejo-Zúñiga, E. C., López-Cruz, I. L., & Ruiz-García, A. (2014). Parameter estimation for crop growth model using evolutionary and bio-inspired algorithms. *Applied Soft Computing*, 23, 474-482. doi: <https://doi.org/10.1016/j.asoc.2014.06.023>
- van Straten, G. (2008). What can systems and control theory do for agricultural science?. *Automatika: Journal for Control, Measurement, Electronics, Computing & Communications*, 49.
- Voinov, A. A. (2010). *Systems science and modeling for ecological economics*. Academic Press.
- Wallach, D., Buis, S., Lecharpentier, P., Bourges, J., Clastre, P., Launay, M., ... & Justes, E. (2011). A package of parameter estimation methods and implementation for the STICS crop-soil model. *Environmental Modelling & Software*, 26(4), 386-394. <https://doi.org/10.1016/j.envsoft.2010.09.004>
- Wallach, D., Makowski, D., Jones, J.W., Brun, F., 2018. *Working With Dynamic Crop Models: Methods, Tools and Examples for Agriculture and Environment*. Academic Press.
- Walters, R. W., & Huyse, L. (2002). *Uncertainty analysis for fluid mechanics with applications*.
- Wilkinson, D.J., 2006. *Stochastic Modelling for Systems Biology*. Chapman and Hall/CRC. <https://doi.org/10.1201/9781420010664>.
- Woli, P., Jones, J., Ingram, K., Fraisse, C., (2012). Agricultural reference index for drought (ARID). *Agron. J.* 104 (2), 287–300.
- Zhang, T., Su, J., Liu, C., & Chen, W. H. (2019). Bayesian calibration of AquaCrop model for winter wheat by assimilating UAV multi-spectral images. *Computers and Electronics in Agriculture*, 167. doi: 10.1016/j.compag.2019.105052
- Zhao Chuang, B. L., Liujun Xiao, Gerrit Hoogenboom, Kenneth J. Boote, Belay T. Kassie, Willingthon Pavan, . . . Yan Zhu, S. A. (2019). A SIMPLE crop model. *European Journal of Agronomy*, 104(1161-0301), 97-106.

V.- CALIBRACIÓN Y EVALUACIÓN DEL MODELO DE CULTIVO SIMPLE PARA FRIJOL (*Phaseolus vulgaris* L.) BAJO DIFERENTES NIVELES DE RIEGO

6

5.1.-Resumen

La producción de frijol está en riesgo debido al cambio climático, disminución de los recursos hídricos y un manejo inadecuado del cultivo. Sin embargo, los modelos dinámicos que predicen el crecimiento y desarrollo de los cultivos son herramientas fundamentales para generar conocimiento básico y aplicado como la gestión de la producción y el soporte para la toma de decisiones. El objetivo de este estudio fue calibrar y evaluar el modelo SIMPLE bajo condiciones de riego para las condiciones agroclimáticas de Zacatecas y simular el tiempo térmico (TT), la biomasa (Bio) y el rendimiento (Y) de frijol 'Pinto Saltillo' usando datos experimentales de cuatro tratamientos (R₁₂₅, R₁₀₀, R₇₅, R₅₀) de demanda atmosférica conducidos durante los ciclos 2020 y 2021. La calibración del modelo se realizó planteando y resolviendo un problema de optimización con el algoritmo de evolución diferencial y datos experimentales de 2020; mientras que la evaluación se realizó con datos experimentales de 2021. Para Bio, se obtuvieron valores de calibración de RMSE < 0.58 t ha⁻¹ y EF > 0.93. Los valores de calibración fueron RMSE > 1.80 t ha⁻¹ y EF > 0.89 en evaluación. Los tratamientos R₁₀₀ y R₅₀ mostraron mejor ajuste en calibración, mientras que en la evaluación lo fueron los tratamientos R₇₅ y R₅₀.

⁶ Tesis de Doctorado en Ingeniería, Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Miguel Servin Palestina

Director: Irineo L. López Cruz, PhD

Para Y la predicción del modelo no fue pobre ya que se observaron errores promedio de 37% y 22% en calibración y evaluación, respectivamente. Por lo anterior, se propuso un modelo empírico para estimar el índice de cosecha, el cual produjo un error relativo promedio de 6.9% para estimar rendimiento de frijol. El modelo SIMPLE fue capaz de predecir biomasa de frijol bajo riego en climas árido y semiárido. También, el uso de la biomasa y la transpiración del cultivo para calcular el índice de cosecha

Keywords:

Algoritmo Evolución diferencial, índice de cosecha, modelo dinámico, rendimiento de grano, evapotranspiración

Highlights

Por primera vez se lleva a cabo la estimación de parámetros (calibración) y evaluación del modelo SIMPLE en frijol con diferentes niveles de humedad.

El modelo SIMPLE es capaz de predecir adecuadamente la biomasa de frijol de bajo condiciones de riego, cuando se calibra usando datos experimentales de diferentes niveles de humedad del suelo.

El modelo empírico desarrollado para estimar índice de cosecha mejora significativamente la predicción de rendimiento.

La biomasa y transpiración del cultivo son adecuados para estimar índice de cosecha de frijol sometido a diferentes niveles de humedad del suelo.

5.2.- Introducción

Por el alto contenido proteínico, el frijol (*Phaseolus vulgaris* L) es la legumbre de mayor producción y consumo en el mundo. México ocupa el noveno lugar en producción a nivel mundial (FAOSTAT, 2022). El consumo anual *per cápita* es de 8 kg (INEGI, 2012). El estado de Zacatecas es el principal productor de esta

leguminosa cultivada bajo un clima semiárido (Bs) o árido (Bw) (García, 2004). Este clima es característico del altiplano Semiárido del norte de México con precipitaciones erráticas durante la estación de crecimiento y alta demanda evapotranspirativa, características que demandan el uso de riego complementario para la producción de frijol (Schwartz et al., 2015). En Zacatecas se cultivan 55 mil ha de riego con un rendimiento entre 1 500 y 2 100 kg ha⁻¹ (SIAP, 2015), unos de los rendimientos más bajos a nivel mundial. Además de las condiciones climáticas adversas, los bajos rendimientos son producto del abatimiento de los mantos acuíferos, suelos degradados y manejo inadecuado del cultivo. Sin embargo, los rendimientos pueden mejorarse entendiendo el manejo del cultivo en el continuo suelo-planta-atmósfera, donde los modelos de crecimiento y desarrollo de los cultivos cobran relevancia.

Los modelos matemáticos son herramientas eficaces para describir y comprender sistemas complejos, pero también son utilizados para la gestión de cultivos, generación de políticas gubernamentales, evaluación y adaptación al impacto del cambio climáticos (Seidel et al., 2018). Los modelos matemáticos dinámicos se componen de un conjunto de ecuaciones diferenciales ordinarias de primer orden o ecuaciones en diferencias (Chalabi et al 1996). Estas ecuaciones tienen un conjunto de coeficientes que representan parámetros fisiológicos difíciles de medir directamente (Bhar et al., 2020) y de estimar (Wallach, 2011), cuyos valores deben estimarse con precisión para poder ser usados en los modelos. Por tanto, se recurre a procesos de calibración o estimación de parámetros en los modelos dinámicos para el crecimiento y desarrollo de los cultivos.

La calibración de modelos o la estimación de parámetros del cultivo es un proceso clave para ajustar las variables medidas y las predicciones generadas por el modelo (Wallach et al., 2011). Este paso es un proceso demandante y crítico para desarrollar y aplicar un modelo (Seidel et al., 2018), el cual se puede resolver optimizando una función objetivo (van Straten, 2008; Wallach et al., 2019) que minimiza la diferencia entre predicciones y mediciones. La optimización se resuelve manualmente con el método de prueba y error o con algún algoritmo de búsqueda

(local o global). La calibración del total de parámetros de los modelos no es una práctica adecuada, por ello, es necesario e importancia determinar los parámetros influyentes candidatos a calibrar (Wallach et al., 2020). Además, para determinar la calidad de la calibración del modelo es necesario verificar la predicción del modelo con un nuevo conjunto de variables medidas, este proceso es llamado evaluación (Voinov and Gaddis, 2008; Bala et al., 2017).

Para la calibración algunos investigadores han utilizado OptimiSTICS una herramienta de optimización basada en mínimos cuadrados no lineales para estimar parámetros en el modelo STICS aplicado al cultivo de haba (Falconnier et al., 2019) y en cultivos intercalados trigo-garbanzo (Kherif et al., 2022). También, se han usado la herramienta Parameter ESTimation (PEST) en el modelo DSSAT para estimar los parámetros en los cultivos: maíz, soya, trigo, arroz y algodón (Ma et al., 2020). En frijol han estimado parámetros y evaluado en el modelo CROPGRO-Dry Bean (Dallacort et al, 2011; Oliveira et al, 2012; Mompremier et al, 2021) y en el modelo SSM- Legumes (Marrou et al., 2014; Van Loon et al., 2018). Además, han calibrado y evaluado el modelo SALMED (Dewedar et al., 2020) y el modelo Aquacrop (Olivera et al., 2016; Magalhães, et al., 2019) para simular la biomasa de frijol en diferentes condiciones de humedad en el suelo.

El método utilizado para la calibración debe considerar en su desempeño, problemas de optimización con funciones no lineales y multimodales, características de los modelos dinámicos de cultivos. El problema de optimización ha sido resuelto exitosamente usando el método Evolución Diferencial (ED). Este último, es un método de búsqueda global eficiente y eficaz. Trejo-Zúñiga et al. (2013) evaluaron varios métodos de búsqueda globales y concluyeron que ED es el método fue el más eficiente en la calibración de 25 parámetros para el modelo SUCROS. También, en la evolución diferencial Metrópolis adaptativa (DREAM) ha sido utilizada para ajustar seis parámetros en el modelo APSIM-maize (Sheng et al., 2019). También, el modelo HORTSYST ha sido utilizado para calibrar nueve parámetros, con eficiencias mayores a 0.96 para cuatro variables de estado (Martínez-Ruiz et al 2021).

Por otro lado, gran parte de los modelos utilizados para la simulación del crecimiento y desarrollo de los cultivos demandan un número grande de parámetros difíciles de obtener como consecuencia de la amplia diversidad de ambientes agroecológicos, cultivos y variedades. Es aquí donde se destaca la importancia de los modelos que utilizan pocos parámetros (Wang et al., 2013). El modelo de simulación simple (SSM, Simple Simulation Models) desarrollado por Soltani and Sinclair (2012) involucra cinco variables de estado y 27 parámetros. El modelo HORTSYST incluye siete variables de estado y sólo requiere 24 parámetros (Martínez-Ruiz et al., 2019). Recientemente, Zhao et al., (2019) propusieron el modelo SIMPLE con dos variables de estado y 14 parámetros para cultivos en campo abierto. SIMPLE fue desarrollado como modelo genérico basado en la radiación interceptada y simula el tiempo térmico ($TT\text{ }^{\circ}\text{C día}$) y biomasa ($Bio\text{ t ha}^{-1}$), pero, además, calcula el rendimiento ($Y\text{ t ha}^{-1}$) (Zhao et al., 2019).

La problemática de bajos rendimientos que actualmente presenta la producción de frijol a nivel regional y nacional, la importancia económica de este cultivo, así como la carencia de modelos de crecimiento y desarrollo aplicados a esta especie, motivo el desarrollo de la presente investigación con el objetivo de estimar parámetros del modelo SIMPLE y llevar a cabo su evaluación. Para esto se llevaron a cabo dos experimentos de crecimiento bajo diferentes niveles de riego durante dos ciclos de cultivo en las condiciones agroclimáticas de Zacatecas, México. La hipótesis subyacente es que el modelo SIMPLE puede ser una herramienta para la planificación de las actividades productivas para el cultivo de frijol con menos riesgos por efectos climáticos adversos y escasez física del agua para la aplicación del riego oportunamente.

5.3.- Materiales y métodos

5.3.1.-Descripción del área de estudio

Los experimentos se realizaron de abril a agosto de 2020 y 2021 en el Campo Experimental Zacatecas del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP) ubicado en Calera de Víctor Rosales, Zacatecas, México (lat. 22°540 N, long. 102°390 W, elevación 2197 msnm). El sitio experimental

tiene una temperatura media anual de 14.6 °C y recibe una precipitación media anual de 416 mm, de la cual, 75 % de ella ocurre entre julio y octubre. La evaporación media anual de la bandeja es de 1609 mm. El suelo del sitio experimental es franco arcilloso con un punto de saturación (SP), capacidad de campo (FC), punto de marchitamiento permanente (PWP) y densidad aparente promedio de 0.48 m³ m⁻³, 0.29 m³ m⁻³ y 0.14 m³ m⁻³ y 1.1 g cm⁻³, respectivamente. La distribución granulométrica es 35%, 28% y 37% para la arena, limo y arcilla, respectivamente. El contenido de materia orgánica del suelo es bajo (1.3%) con un pH de 8.2.

5.3.2-. Material genético y manejo del cultivo

La variedad indeterminada de frijol seco 'Pinto Saltillo' se sembró el 16 de abril y 21 de abril en 2020 y 2021, respectivamente. La distancia entre hileras fue a 0.76 m y 0.1 m entre plantas. La densidad de siembra fue de 131, 578 por ha. La profundidad de siembra fue entre 0.06 y 0.07 m. La fertilización mineral consistió de 40 y 60 unidades de nitrógeno y fósforo, respectivamente; la cual se fraccionó durante el ciclo del cultivo. Otras labores culturales como control de malezas, enfermedades y plagas se realizaron cuando fue requerido de acuerdo a lo sugerido por el INIFAP.

5.3.3. Tratamientos de riego y diseño experimental

Los experimentos en 2020 y 2021 consistieron en la aplicación de cuatro tratamientos riego con base en la demanda atmosférica: 125, 100, 75 y 50% de la evapotranspiración del cultivo (ET_c). Los tratamientos de riego fueron aplicados con base en un balance hídrico climático propuesto por Servín et al. (2017). El diseño experimental se dispuso en bloques completos al azar en función de la pendiente del terreno, con tres repeticiones. La unidad experimental fue de 12 surcos de 11 m de largo.

La aplicación de agua de riego por tratamiento fue por cintilla de riego autocompensada de calibre 6 mil con emisores espaciados a 20 cm y 0.94 lph de

gasto por emisor. El riego de pre-siembra y de establecimiento fue el mismo para todos los tratamientos. Para determinar la lámina aplicada en cada tratamiento se colocó un medidor volumétrico. La curva de acumulación de biomasa se obtuvo con un muestreo destructivo recolectando plantas contenidas en 1 m de un surco. Las muestras se dividieron en hojas, tallo y vainas. Las muestras de órganos de las plantas se secaron en horno a 65 °C por 72 h a masa constante. La biomasa (Bio) se estimó con la sumatoria de cada uno de los órganos. El rendimiento de grano se obtuvo por triplicado (sub-muestreo) por cada unidad experimental. Las plantas contenidas en 1.5 m lineales de los surcos centrales fueron usadas para la recolección de los granos de frijol. El grano fue secado a temperatura ambiente y pesado hasta que alcanzó aproximadamente 12% de humedad.

5.3.4. Información climática

Los datos climáticos diarios de temperatura máxima (T_{max}), mínima (T_{min}), radiación solar (R_s), precipitación (P_p) y evapotranspiración potencial (E_{To}) para los dos ciclos se obtuvieron de la estación meteorológica automatizada Adcon® ubicada en el CEZAC (22.909° N; -102.659° O) a una distancia de 1.5 km del sitio experimental. La plataforma Adcon® estima la evapotranspiración potencial por el método Penman-Monteith (Allen et al., 2006).

5.3.5. Descripción del modelo SIMPLE

El modelo dinámico SIMPLE y en tiempo discreto, propuesto por Zhao et. Al., (2019) simula el crecimiento limitado por agua, el desarrollo y el rendimiento de los cultivos utilizando un paso de tiempo diario, con funciones o ecuaciones que explican el efecto de la temperatura diaria, el estrés por calor, la disponibilidad de agua en el suelo y la concentración atmosférica de CO_2 . El tiempo térmico (TT_i , °C d⁻¹) y producción de biomasa seca (Biomasa, t ha⁻¹) son las variables de estado y el rendimiento de grano (Y , t ha⁻¹) es una variable de salida. El modelo SIMPLE tiene 13 parámetros (Tabla 2), nueve relacionados con el tipo de cultivo y cuatro que especifican diferencias entre variedades (Figura 1).

El modelo SIMPLE utiliza la temperatura acumulada para determinar el desarrollo fenológico (Ritchie et al., 1985) de la siguiente manera:

$$TT_{i+1} = TT_i + \Delta TT \quad (1)$$

$$\Delta TT = \begin{cases} T - T_b; & T > T_b \\ 0 & ; T \leq T_b \end{cases} \quad (2)$$

donde TT_i (°C d) es el tiempo térmico para el i -ésimo día, ΔTT (°C) es el incremento diario en temperatura, T (°C) es la temperatura media diaria y T_b (°C) es la temperatura base para el desarrollo fenológico de los cultivos.

El crecimiento de biomasa se basa en la eficiencia en el uso de la radiación (Monteith, 1965), es decir, una fracción de la radiación fotosintéticamente activa diaria es interceptada por la planta y se transforma en biomasa de cultivos.

$$Bio_{i+1} = Bio_i + \Delta Bio \quad (3)$$

$$\Delta Bio = R_s \cdot fSolar \cdot RUE \cdot f(CO_2) \cdot f(Temp) \cdot \min[f(Heat), f(Water)] \quad (4)$$

donde: Bio_{i+1} (t ha⁻¹) es la biomasa acumulada diaria hasta madurez fisiológica, ΔBio (t ha⁻¹ día⁻¹) es la tasa de crecimiento diario de la biomasa y $fSolar$ es la fracción de la radiación solar interceptada por un dosel de cultivo, RUE (g MJ⁻¹ m⁻²) es la eficiencia del uso de la radiación y $f(calor)$, $f(CO_2)$, $f(Temp)$ y $f(Agua)$ son factores de corrección por estrés a altas temperaturas, impacto del CO₂, impacto a temperaturas cardinales y a sequía respectivamente, factores que pueden o no favorecer la acumulación de biomasa.

El rendimiento del grano se calcula como el producto de la biomasa total acumulada ($Bio - cum_{maturity}$) y el índice de cosecha (HI) (Amir and Sinclair, 1991).

$$Y = Bio - cum_{maturity} \times HI \quad (5)$$

El modelo SIMPLE realiza un balance de agua en el suelo basándose en la metodología de la curva número y escorrentía. Para este balance se utilizan cuatro parámetros para caracterizar el suelo de la parcela experimental: 1) humedad disponible (AWC=0.123 m³ m⁻³), 2) coeficiente de drenaje profundo (DDC=0.5), 3) curva número de escorrentía (RCN=0.81) y 4) profundidad radicular (RDZ=600 mm),

además, el modelo utiliza el índice estandarizado de sequía ARID (Woli et al., 2012) para relacionar el efecto de agua en el suelo con la acumulación de biomasa. Muchas de las funciones de SIMPLE han sido usadas en otros modelos de cultivos, descritas ampliamente por Zhao et al. (2019).




Figura 5.1. Diagrama del modelo de crecimientos de cultivos SIMPLE, las variables de estado se representan por rectángulos, las tasas de cambio por válvulas, los parámetros con una línea horizontal y un círculo con relleno negro, las variables de entrada un círculo y una línea horizontal y las variables auxiliares con circunferencias. Los flujos de material se representan mediante flechas normales y los flujos de información con líneas discontinuas

5.3.6. Calibración del modelo

De acuerdo con el procedimiento de modelación de sistemas dinámicos (Ljung and Glad, 1994; Voinov, 2010; Bala et al., 2017), previo a la calibración es necesario identificar los parámetros más influyentes, en el modelo, mediante un análisis de sensibilidad (Saltelli et al., 2004; 2006). Por esto, previo a la calibración se realizó un Análisis de Sensibilidad Global (GSA) con el método de Sobol (Saltelli et al., 2008). Para el GSA se aplicó una incertidumbre de $\pm 20\%$ en la mayoría de los parámetros evitando traslape de la temperatura cardinales y utilizando distribución uniforme a excepción de Tsum y Swater donde se utilizó una función normal (Tabla

1). Los parámetros más influyentes candidatos a la calibración fueron I50A, T_{opt}, Swater, T_{base}, I50maxW y T_{sum}.

Tabla 5.1. Parámetros del modelo SIMPLE con sus valores nominales y límites de exploración usado para GSA y calibración en frijol 'Pinto Saltillo'.

Parameter	Description	nominal	Umbral*	Units	Source
T _{sum}	Accumulated temperature from planting to maturity	1200	1047 - 1356 &	°C d**	B-G
HI	Harvest index	0.36	0.29 - 0.43	-	B-G
I _{50A}	Accumulated temperature required for leaf area development to intercept 50% of radiation	450	360 - 540	°C d	Z
I _{50B}	Accumulated temperature to maturity to reach 50% radiation interception due to leaf senescence	200	160 - 240	°C d	-
T _b	Baseline temperature for phenology development and growth	8	6.4 - 9.6	°C	B-G
T _{opt}	Optimum temperature for biomass growth	30	22 - 30	°C	B-G
RUE	Radiation use efficiency (above ground only and no respiration)	3.21	2.57 - 3.85	g MJ ⁻¹ m ⁻²	K
I _{50max}	Maximum daily reduction in I _{50B} due to heat stress	90	72 - 108	°C d	Z
H					
I _{50max}	Maximum daily reduction in I _{50B} due to drought stress	20	16 - 24	°C d	Z
W					
T _{max}	Threshold temperature to start accelerating heat stress senescence	35	32.1 - 42	°C	O
T _{ext}	Extreme temperature threshold when RUE becomes 0 due to heat stress	45	42.1 - 52.5	°C	Z
SCO ₂	Relative increase in RUE per ppm of CO ₂ after 350 ppm	0.07	0.06 - 0.08	ppm	Z
S _{water}	Sensitivity of RUE to drought stress	0.9	0.48 - 1.28 &	-	Z

*izquierda límite máximo y derecha límite mínimo, & Parámetros que se les aplicó función normal, ** grados día. Los resaltados son los parámetros más influyentes, B-G=Báez-Gonzales et al., (2020), Z=Zhao et al., (2019), K=Karimzadeh et al., (2018), O=Omae et al., (2012)

5.3.6.1. Algoritmos de evolución diferencial

La calibración se realizó con un algoritmo de evolución diferencial (DE) el cual es considerado como un método de búsqueda heurística, simple, eficaz y eficiente, inspirado en la evolución natural (Price et al., 2005). En los últimos años, el algoritmo DE ha ganado una mayor atención y ha sido utilizado ampliamente en la investigación científica. El algoritmo DE incluye una población de soluciones potenciales y explora el espacio de búsqueda mediante los operadores de mutación, cruzamiento y selección. DE tiene solamente tres parámetros que deben ser especificados para poder aplicarlo en un problema de optimización, estos son:

tamaño de población (NP), factor de mutación (F) y probabilidad de cruzamiento (CR).

Las características del algoritmo DE aplicado en la simulación fueron el número de parámetros estimados (D) fue de 6, un tamaño de población (NP) fue de D*10, número de generaciones de 1000, los valores mínimos se tomaron de la media de 25 ejecuciones y la estrategia del algoritmo DE/rand/1/bin. Este algoritmo fue programado en el ambiente MATLAB. Los valores de los parámetros del algoritmo DE fueron F=0.6, CR=0.9 y NP=60. Los límites de exploración de los parámetros calibrados se especifican en Tabla 5.2.

5.3.6.2. Función objetivo

Una función objetivo del problema de optimización se definió como:

$$\hat{p} = \arg \min J(p) \quad (6)$$

$$J(p) = \sqrt{\frac{1}{N} \sum_{i=1}^N (\bar{y}(t_i, p) - y(t_i))^2} \quad (7)$$

donde: $y(t_i, p)$ es la biomasa predicha por el modelo SIMPLE en el tiempo t_i y $y(t_i)$ es la variable medida en el tiempo t_i , N es el número de muestras durante el período de crecimiento, p es el vector de parámetros establecidos para la calibración y $\hat{p}$ es el vector de parámetros que produce el valor mínimo de $J(p)$.

5.3.7. Evaluación del modelo

Después de realizar la calibración del modelo SIMPLE, se usaron los valores estimados promedio y valores nominales de los parámetros, según correspondió. La evaluación consistió en simular con el nuevo vector de parámetros de TT, Bio y Y de frijol usando los datos climáticos y del cultivo recolectados en el año 2021.

5.3.8. Medidas para el grado de ajuste

Para medir la calidad de la calibración y de la evaluación del modelo SIMPLE, se utilizaron las siguientes medidas de concordancia (Wallach et al., 2019) entre los

valores observados y simulados 1) el sesgo (BIAS; Ecuación 8), 2) el error absoluto medio (MAE; Ecuación 9), 3) la raíz del error cuadrático medio (RMSE; Ecuación 10) (Heng et al., 2009), y 4) la eficiencia Nash y Sutcliffe (EF; Ecuación 11).

$$BIAS = \left(\frac{1}{n}\right) \sum_{i=1}^N (y_i - \hat{y}_i) \quad (8)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

$$EF = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (11)$$

donde y_i representa el valor observado, $\hat{y}_i$ es el valor predicho por el modelo SIMPLE, $\bar{y}$ es el promedio de los valores observados y n el número de observaciones.

5.4.- Resultados

5.4.1.-Clima y calendario de riego

El promedio histórico de precipitación (2002-2019) durante el ciclo del cultivo fue 223.3 mm, inferior a los registrados para ambos ciclos considerados en el presente estudio. El 2021, la precipitación fue 10% superior y 9% inferior en evapotranspiración con respecto a 2020. La temperatura máxima se presentó en junio y mayo, la temperatura mínima en mayo y abril para el año 2020 y 2021, respectivamente. La temperatura media del ciclo 2020 fue superior en 4% con respecto al 2021 (Figura 2). Sin embargo, las temperaturas registradas durante todo el ciclo, determinaron el desarrollo del cultivo, cuya floración inició a los 54 y 50 días después de siembra (dds) para los ciclos de 2020 y 2021, respectivamente.

La precipitación efectiva (Pe), es decir, la cantidad de lluvia que se almacena en la zona radicular estimada mediante la metodología de Serna et al. (2011), fue de 244.1 y 270.4 para el año 2020 y 2021 respectivamente. Por otro lado, la radiación solar promedio fue de 28.1 MJm² día⁻¹ para ambos años, 3% inferior al promedio histórico.




Figure 5.2. Variables climáticas recolectadas durante la estación de crecimiento y media histórica de la estación CEZAC INIFAP-Zacatecas. *medias quincenales

Las condiciones climáticas, principalmente precipitación (Pp) y evapotranspiración de referencia (ET_o) influyeron en las láminas de riego aplicadas en cada tratamiento (Tabla 2). En el 2020 se registró menor Pp y mayor ET_o lo que originó mayor demanda de agua por el cultivo. El riego se aplicó mayormente en la etapa reproductiva con 66% y 82% en 2020 y 77% y 100% en 2021, para R125 y R50 respectivamente.

Tabla 5.2. Riego y productividad de frijol con diferentes niveles de agua en el suelo en Zacatecas, México

Tratamientos	Lamina Aplicada (mm)	Precipitación efectiva (mm)	Evapotranspiración (mm)	EUA (Kg m ⁻³)	WP (Kg m ⁻³)
2020					
R ₁₂₅	349	352	701	1.4	0.7
R ₁₀₀	293		645	1.6	0.7
R ₇₅	234		586	1.3	0.5
R ₅₀	183		535	1.8	0.6
2021					
R ₁₂₅	276	387	663	1.6	0.6
R ₁₀₀	219		606	2.2	0.8
R ₇₅	174		561	2.3	0.7
R ₅₀	133		520	2.8	0.7

EUA = eficiencia en el uso de agua; rendimiento de grano sobre agua aplicada (Katerji et al., 2018), WP = productividad del agua rendimiento de grano sobre evapotranspiración (agua aplicada mas precipitación efectiva; Zhou et al., 2021)

5.4.2. Curva de acumulación de biomasa

El crecimiento de biomasa durante los primeros 25 días después de siembra fue muy lenta y no hubo diferencia significativa ($p>0.05$) entre tratamientos ya que la emergencia se presentó a los 8 y 7 dds para 2020 y 2021 respectivamente. Al aplicar los tratamientos de riego se observó una dinámica de crecimiento proporcional a la lámina aplicada hasta inicio de floración a los 54 y 50 dds para 2020 y 2021 respectivamente. Posteriormente, en llenado de grano la variación en el incremento de biomasa entre tratamientos se puede atribuir a la presencia de lluvias. Los eventos de precipitación de mayor intensidad se registraron a la mitad del ciclo reproductivo y al inicio de floración para los ciclos 2020 y 2021, respectivamente (Tabla 5.3 y 5.4).

Tabla 5.3. Producción promedio ($\pm$ desviación estándar) de biomasa de frijol CV ‘Pinto Saltillo’ en Zacatecas, México del ciclo 2020, usados para la calibración.

	Días después de la siembra						
T	13	25	36	48	62	77	89
R ₁₂₅	0.021 $\pm$ 0.002	0.082 $\pm$ 0.006	0.222 $\pm$ 0.016b	1.714 $\pm$ 0.028a	5.06 $\pm$ 1.1a	9.27 $\pm$ 1.48a	8.01 $\pm$ 0.33a
R ₁₀₀	0.021 $\pm$ 0.002	0.082 $\pm$ 0.006	0.277 $\pm$ 0.011a	0.972 $\pm$ 0.135b	2.96 $\pm$ 0.99ab	8.74 $\pm$ 0.38a	9.18 $\pm$ 1.35a
R ₇₅	0.021 $\pm$ 0.002	0.082 $\pm$ 0.006	0.239 $\pm$ 0.01ab	1.119 $\pm$ 0.175b	1.91 $\pm$ 0.12b	4.02 $\pm$ 1.02b	6.62 $\pm$ 1.93ab
R ₅₀	0.021 $\pm$ 0.002	0.082 $\pm$ 0.006	0.22 $\pm$ 0.028b	0.989 $\pm$ 0.223b	2.07 $\pm$ 0.47b	--	3.41 $\pm$ 0.95b
CV			7.987	11.703	28.865	17.449	21.315
RMSE			0.019	0.140	0.866	1.035	1.450
MSD			0.049	0.360	2.222	2.655	3.718

T= Tratamiento, CV = coeficiente de variación, RMSE = raíz del error cuadrático medio MSD =Diferencia mínima significativa

Tabla 5.4. Producción promedio ($\pm$ desviación estándar) de biomasa de frijol cv ‘Pinto Saltillo’ en Zacatecas, México del ciclo 2021, usados para la evaluación.

	Días después de la siembra						
T	17	31	43	57	75	85	100
R ₁₂₅	0.029 $\pm$ 0.009	0.287 $\pm$ 0.015a	1.19 $\pm$ 0.29a	3.16 $\pm$ 0.52 ^a	6.03 $\pm$ 0.65ab	11.92 $\pm$ 0.27a	12.01 $\pm$ 0.66b
R ₁₀₀	0.029 $\pm$ 0.009	0.273 $\pm$ 0.015a	0.10 $\pm$ 0.16a	2.70 $\pm$ 0.48ab	7.91 $\pm$ 1.21a	7.63 $\pm$ 0.19c	11.55 $\pm$ 0.45b
R ₇₅	0.029 $\pm$ 0.009	0.286 $\pm$ 0.054a	1.04 $\pm$ 0.10a	2.45 $\pm$ 0.41ab	6.52 $\pm$ 0.68ab	7.67 $\pm$ 0.79c	15.23 $\pm$ 0.23a
R ₅₀	0.029 $\pm$ 0.009	0.285 $\pm$ 0.027a	0.863 $\pm$ 0.02a	1.91 $\pm$ 0.15b	5.28 $\pm$ 0.83b	9.20 $\pm$ 0.30b	--
CV		12.33	18.133	18.283	14.126	5.589	3.698
RMSE		0.035	0.185	0.466	0.909	0.509	0.507
MSD		0.090	0.48	1.196	2.331	1.305	1.300

T= Tratamiento, CV = coeficiente de variación, RMSE = raíz del error cuadrático medio MSD =Diferencia mínima significativa

5.4.3. Calibración y Evaluación

Con el método de evolución diferencial (ED), se hicieron 20 optimizaciones cuyo promedio de cada parámetro por tratamiento se indica en la Tabla 5.2. La mayor desviación estándar en el conjunto de parámetros fue observada en 1.17×10^{-16} . Este valor es indicativo de que el proceso de calibración convergió al máximo global, por tanto, los resultados fueron considerados como confiables. Por otro lado, para la evaluación del modelo SIMPLE se utilizó el promedio de los valores de los parámetros calibrados (**Tabla 5.5**) con datos del año 2020 y los valores nominales (**Tabla 5.1**) según correspondió: Con ello se generó el nuevo vector de parámetros, posteriormente simuló la biomasa y se obtuvieron las medidas de desempeño en la etapa de evaluación para los datos observados del 2021.

Al utilizar los umbrales de exploración de la Tabla 2 para los seis parámetros en el proceso de calibración, se observó que los valores Tsum, I50A y I50maxW son

cercanos a los valores extremos (**Tabla 5.5**). Tsum se desplazó al extremo superior con un valor de 1354 a 1356 °C día, cabe mencionar que, se probó con otros valores mayores a 1356 °C día (resultados no reportados). Sin embargo, se observó un sobre ajuste, es decir, se mejoran los estadísticos en la calibración para algunos tratamientos, pero en la etapa de evaluación los estadísticos indican la poca confiabilidad del modelo SIMPLE para simular la biomasa de frijol. Topt es inversamente proporcional al tratamiento de riego, es decir, el tratamiento con mayor disponibilidad de agua tuvo el valor más bajo. Swater es el parámetro que relaciona la disponibilidad de agua dentro del modelo SIMPLE sin embargo, no se observó una tendencia lineal con respecto a los tratamientos. Por otro lado, la Tbase fue 8.7 °C y 9.6 °C para R₁₂₅ y R₇₅ respectivamente (**Tabla 5.5**).

Tabla 5.5. Vector de parámetros, resultado de la calibración del modelo SIMPLE con el algoritmo de Evolución Diferencial

Tratamiento Calibración	Parámetros Óptimos						Estadísticas	
	Tsum	I50A	Tbase	Topt	I50maxW	Swater	RMSE*	S ² **
R ₁₂₅	1356	540	8.7	24.0	16	1.00	0.51	3E-17
R ₁₀₀	1356	540	9.6	27.1	16	0.74	0.43	0E+00
R ₇₅	1354	540	9.6	29.8	16	0.79	0.59	1E-16
R ₅₀	1356	526	9.5	30.0	16	0.85	0.09	0E+00
Promedio	1356	536	9.3	27.8	16	0.84	0.40	4E-17

*valor de la función objetivo mínimo alcanzado por el algoritmo DE (raíz del error cuadrático medio), ** desviación estándar. Tsum =Temperatura acumulada de siembra a madurez Índice de cosecha, I50A = Temperatura acumulada requerida para el desarrollo del área foliar para interceptar el 50% de la radiación, Tbase = Temperatura base para el desarrollo y crecimiento de la fenología, Topt = Temperatura óptima para el crecimiento de la biomasa, I50maxW = Reducción diaria máxima en I50B debido al estrés por sequía, Swater = Sensibilidad de RUE al estrés por sequía

En la calibración. la biomasa simulada acumulada no presentó una tendencia lineal con respecto al tratamiento de riego. Los valores fluctuaron entre 10.2 t ha⁻¹ y 3.47 t ha⁻¹ para R₁₀₀ y R₅₀ respectivamente. Por otro lado, el RMSE tuvo un valor máximo de 0.59 t ha⁻¹ en R₇₅. En la etapa de evaluación, la biomasa de frijol predicha se ajustó adecuadamente a los datos observados para los cuatro tratamientos de riego con RMSE < 1.80 t ha⁻¹ y EF > 0.89, con valores promedio de 1.48 t ha⁻¹ y 0.92 para RMSE y EF, respectivamente. Además, el tratamiento de riego R₅₀ tuvo el mejor ajuste en la calibración y evaluación de acuerdo a los estadísticos utilizados para medir el desempeño del modelo (Tabla 6).

Tabla 5.6. Estadísticos de evaluación del modelo SIMPLE para la simulación de biomasa de frijol sometido a diferentes niveles de humedad.

Estadísticos	Calibración					Evaluación				
	R ₁₂₅	R ₁₀₀	R ₇₅	R ₅₀	Promedio	R_125	R_100	R_75	R_50	Promedio
Bias	-0.06	-0.11	-0.11	-0.02	-0.08	-0.91	-1	-0.28	-0.46	-0.66
MAE	0.36	0.34	0.43	0.07	0.30	1.01	1.04	0.99	0.47	0.88
RMSE	0.51	0.43	0.59	0.09	0.41	1.74	1.8	1.49	0.89	1.48
EF	0.98	0.99	0.93	0.99	0.97	0.91	0.89	0.91	0.95	0.92

Bias = sesgo, MAE = error absoluto medio, RMSE = raíz del error cuadrático medio, EF = eficiencia

Para el desempeño individual en calibración y evaluación por tratamiento, la biomasa simulada respondió a una línea de tendencia sigmoidea. En la primera etapa tuvo crecimiento lento antes de floración hasta formación de vainas un crecimiento acelerado y nuevamente un crecimiento lento en llenado de grano hasta madurez. La biomasa simulada en evaluación respondió a una tendencia lineal al tratamiento, es decir a mayor humedad disponible mayor biomasa acumulada. Además, la biomasa fue superiores a los reportados en calibración para los cuatro tratamientos. Esta condición se puede atribuir a que durante el ciclo del cultivo en 2020 (datos calibración) la precipitación fue < 35.4 mm y la evapotranspiración >62.6 mm que en 2021 (datos evaluación). Asimismo, los estadísticos Bias, MAE, RMSE y EF fueron superiores en calibración con respecto a evaporación. En la evaluación de R100 fue el que mostró valores más bajos con 1.8 t ha⁻¹ y 0.89 de RMSE y EF respectivamente. Sin embargo, eficiencia global para los cuatro tratamientos fue de 0.92, aceptable para simular biomas de los cultivos.




Figura 5.3. Biomasa observada vs simulada para los cuatro tratamientos de riego. Calibración (datos 2020) y Evaluación (datos 2021)

El desempeño general del conjunto de datos utilizados para la calibración y evaluación se muestra en la **Figura 5.4**. Donde se observa la relación entre la biomasa observada (eje de las abscisas) y simulada (eje de las ordenadas). Las evidencias confirmaron que en la etapa de calibración se presenta mejor ajuste entre biomasa observada y simulada con respecto a la evaluación (Fig. 4a). En calibración, los valores más alejados a la línea 1:1 correspondieron a los datos obtenidos en 77 y 89 dds del tratamiento R_{125} y R_{75} , (Fig. 4b). Sin embargo, se observó un ajuste adecuado para la biomasa con un valor promedio de $RMSE = 0.40 \text{ t ha}^{-1}$ y una $EF = 0.97$. Es decir, las estadísticas generales son evidencia de que el modelo simula adecuadamente la biomasa de frijol en diferentes condiciones de humedad en el suelo. En evaluación (Fig. 4b), los valores menores a 4 t ha^{-1} se sobrepusieron en la línea 1:1. Es decir, presentó un buen ajuste para la etapa vegetativa; mientras que los valores en la etapa reproductiva los valores estimados fueron subestimados. No obstante, los estadísticos indican un buen desempeño del modelo SIMPLE para pronosticar biomasa de frijol con diferentes condiciones de humedad en su etapa de evaluación.




Figura 5.4. Calibración (a) y evaluación (b) de la biomasa observada y simulada - En cada punto, las barras verticales indican la desviación estándar (n = conjunto de datos).

La estimación del rendimiento de grano ($Y \text{ t ha}^{-1}$) con modelo SIMPLE usando el parámetro HI de 0.36 para frijol 'Pinto Saltillo', no fue satisfactoria, el promedio de los errores para los cuatro tratamientos fue 37.12% y 21.60% para la etapa de

calibración (datos 2020) y evaluación (2021) respectivamente. El rango de valores fluctuó de 12.7% a 61.78 % para el tratamiento R100 en 2020 y R50 en 2021 respectivamente, esto es atribuible a que el modelo SIMPLE calcula el Y similar a CropSys (Stöckle et al., 2003) y AquaCrop (Steduto et al., 2009) sin considerar algún otro factor ambiental o de manejo (Zhao et al., 2019). Sin embargo, en la presente investigación, el índice de cosecha (HI) no fue linealmente proporcional a la biomasa acumulada a maduración. Además, se han propuesto varios métodos para calcular HI, los cuales consideran la acumulación de biomasa posterior a la antesis, cuyos comportamientos fueron no lineales (Kemanian et al., 2007). El HI de frijol se relaciona con la acumulación de fotoasimilados los cuales son exportados a los órganos de interés económico (Morales-Rosales et al., 2008). Estos, a su vez, están directamente relacionados con la radiación interceptada por el cultivo y la disponibilidad de agua en el suelo que afecta la transpiración del cultivo. Por tal razón, se propuso un modelo de regresión múltiple que involucra la biomasa y transpiración para estimar el índice de cosecha (HI).

5.4.4. Índice de cosecha

El desarrollo del modelo de regresión para la estimación del índice de cosecha ($\widehat{HI}$) consta de dos etapas: 1) Selección del modelo regresión y 2) Etapa de calibración.

En la primera etapa se generó un modelo regresión, para ello, se utilizó un conjunto de datos observados de biomasa (B_{ij}) y rendimiento de grano (Y_j), obtenidos en el último muestreo del experimento del 2021 (100 dds) por ser los más consistentes para el cálculo de índice de cosecha. El conjunto de datos es por triplicado para cada tratamiento y el HI_j se calculó al relacionar el Y_j entre B_{ij} . También, se utilizó la suma de transpiración (ST_j) resultado de los últimos 100 días de simulación de modelo SIMPLE. Posteriormente, se obtuvimos los valores relativos, relacionando B_{ij} , Y_j y HI_j con sus valores máximos correspondientes. El modelo de regresión múltiple de primer orden (Ecuación 12) se realizó en el sistema de análisis estadístico (SAS, 2011). El modelo fue significativo ($p < 0.05$) y explicó (R^2) 50% de la variabilidad (de qué') con un coeficiente de variación de 18.3% y 0.13 de RMSE.

$$\frac{HI_j}{HI_{j_max}} = \left[\beta_0 - \beta_1 \left(\frac{Bio_j}{Bio_{j_max}} \right) + \beta_2 \left(\frac{Bio_j}{Bio_{j_max}} \cdot \frac{ST_j}{ST_{j_max}} \right) \right] \therefore$$

$$HI_j = \left[0.64 - 2.34 \left(\frac{Bio_j}{Bio_{j_max}} \right) + 2.66 \left(\frac{Bio_j}{Bio_{j_max}} \cdot \frac{ST_j}{ST_{j_max}} \right) \right] \cdot HI_{j_max} \quad (12)$$

donde, HI_{j_max} es el índice de cosecha máximo observado (0.29), Bio_{j_max} biomasa acumulada máxima observada (16.7 t ha⁻¹) y ST_{j_max} es la suma de la transpiración simulada (419 mm).

En la segunda etapa se utilizó la biomasa acumulada simulada (BioSim) y la suma de transpiración simulada (STSim) al final del ciclo para cada uno de los tratamientos para 2020 y 2021. BioSim y STSim fueron el resultado de la simulación para todos los tratamientos con el modelo SIMPLE utilizando los parámetros calibrados de la Tabla 6.

Consecutivamente los valores de β_0 , β_2 , Bio_{j_max} y ST_{j_max} se optimizaron hasta alcanzar un RMSE mínimo entre el rendimiento observado y simulado. Para el análisis de optimización se utilizó el toolbox 'lsqnonlin' de MatLab®. HI_{j_max} se mantuvo fijo, sin embargo, hubo mejor ajusté cuando se utilizó el índice de cosecha base HI_o de 0.36 obtenido para la variedad 'Pinto Saltillo' en condiciones climáticas similares a este estudio (Báez-Gonzales et al., 2020). El modelo para estimar el índice de cosecha resultante fue:

$$\widehat{HI} = \left[2.29 - 2.34 \left(\frac{Bio_{Sim}}{9.04} \right) + 1.31 \left(\frac{Bio_{Sim}}{9.04} \cdot \frac{ST_{Sim}}{423.2} \right) \right] \cdot 0.36 \quad (13)$$

Para determinar el desempeño del modelo se utilizó el error relativo corregido (REC), para evitar valores negativos. El REC mide la calidad de la estimación, donde valores >10% se consideran 'excelentes' y $10 > REC < 20$ son 'buenos' para estimar el rendimiento de grano.

$$ERC = \left[\frac{\max(Y_{sim}, Y_{obs}) - \min(Y_{sim}, Y_{obs})}{\max(Y_{sim}, Y_{obs})} \right] \cdot 100 \quad (14)$$

donde Y_{obs} representa el rendimiento observado y Y_{sim} el valor predicho por el modelo en función de BioSim y $\widehat{HI}$.

El modelo de regresión propuesto simula índice de cosecha de manera confiable, En la mayoría del tratamiento se observa un REC menor al 10% y se obtuvo un error promedio con un error promedio global de 7% y errores de 9.4% y 4.6% para el ciclo 2020 y 2021 respectivamente (Tabla 7).

Tabla 5.7. Rendimiento de grano de frijol cv 'Pinto Saltillo' simulado y observado

Año	Trata- miento	Y_{obs} (t ha⁻¹)	ST_{sim} (mm)	Bio_{Sim} (t ha⁻¹)	$\widehat{HI}$	Y_{Sim} (t ha⁻¹)	REC (%)
2020	R ₁₂₅	4.88±0.82a	483.0	10.2	0.48	4.89	0.08
	R ₁₀₀	4.64±0.79ab	456.3	8.1	0.52	4.24	8.69
	R ₇₅	3.12±0.66b	423.4	5.8	0.59	3.40	8.34
	R ₅₀	3.27±0.69ab	391.5	4.1	0.64	2.62	19.90
	CV	16.39					
	RMSE	0.65					0.17 t ha ⁻¹
2021	R ₁₂₅	4.30±0.69ab	479.9	19.0	0.26	4.30	0.00
	R ₁₀₀	4.75±0.51a	457.0	17.7	0.27	4.06	14.57
	R ₇₅	3.95±0.53ab	437.2	16.4	0.29	3.95	0.04
	R ₅₀	3.74±0.48b	417.7	15.2	0.33	3.88	3.58
	CV	13.00					
	RMSE	0.12					0.12 t ha ⁻¹

Y_{obs} = rendimiento de grano observado a madurez, ST = suma de transpiración durante el ciclo, HI= índice de cosecha.
Bio =Biomasa acumulada a madurez, CV = coeficiente de variación, RMSE=raíz cuadrada del error medio, REC=error relativo corregido

5.5.- Discusión

5.5.1. Clima y calendario de riego

La temperatura es uno de los factores ambientales que influye en el crecimiento y desarrollo de los cultivos (Luo, 2011). Barrios et al. (2011) mencionan que el cultivo de frijol puede desarrollarse con temperaturas promedio que oscilan entre 15 y 27 °C, con una temperatura óptima de 25 °C. En contraste Beebe et al. (2011) señalan que la temperatura óptima para este cultivo se encuentra entre 17.5 y 23.1 °C. Ambos rangos de temperatura coincidieron con la temperatura media registrada durante gran parte de los ciclos del cultivo en los experimentos de esta investigación (Figura 5.2).

Las variedades tardías de frijol bajo secano sembradas en el norte de México, requieren más de 240 mm de precipitación durante el ciclo de producción con

rendimientos de 0.6 t ha⁻¹, pero en años con precipitaciones de 323 mm podrían alcanzarse rendimientos de 1.4 t ha⁻¹ (Martínez-Gamiño et al., 2008). Precipitaciones mayores fueron registradas durante el ciclo del cultivo en ambos años en presente estudio. Sin embargo, la precipitación se distribuyó durante la etapa vegetativa en 96% y 87% para 2020 y 2021, respectivamente (Figura 5.2). Lynch and van Beem, (1993) consignaron que el cultivo de frijol puede experimentar estrés hídrico debido a lo errático de la precipitación, siendo la etapa reproductiva la más sensible (Boutraa and Sanders, 2001), lo cual, no ocurrió durante el periodo experimental.

Beebe et al. (2011) aseguran que el cultivo de frijol requiere de 363 a 450 mm de lámina de riego en todo el ciclo. Rai et al. (2020) aplicaron 375 mm en el tratamiento mayor irrigado en condiciones semi áridas de Wyoming, Estados Unidos de América. En los experimentos aquí descritos, las láminas aplicadas fueron inferiores a la indicada por Rai et al. (2020). Sin embargo, al considerar la precipitación efectiva más las láminas aplicadas se estimó un almacenamiento de 404 mm y 594 mm de agua en la zona radicular para R125 durante el ciclo 2020 y R50 durante el ciclo 2021, respectivamente (Tabla 5.2).

5.5.2. Curva de acumulación de biomasa

En ciclo 2020, los tratamientos acumularon menos biomasa total en comparación con sus homólogos del ciclo 2021 y menor rendimiento de grano (excepto R₁₂₅) (Tabla 3 y 4). Atribuible a que la disponibilidad de agua fue inferior en la etapa de floración en el ciclo 2020, los resultados concuerdas con los de Boutraa and Sanders et al. (2001) que evaluaron estrés en floración y en llenado de grano y concluyeron que el estrés en floración reduce número de hojas, longitud de tallo y peso de grano por planta. En 2021 las condiciones climáticas fueron más favorables para la producción de frijol cultivar 'Pinto Saltillo'. Sin embargo, se observó que las etapas de desarrollo para esta variedad no están bien definidas, es decir, tuvo alta variabilidad genética, además al ser una variedad de crecimiento indeterminada, las etapas fenológicas se traslapan, lo que ocasiona variabilidad temporal de la biomasa después de floración. Fernández et al. (1985) señalan que el crecimiento

y desarrollo es afectado por la interacción genotipo x ambiente, lo cual finalmente se refleja en el rendimiento.

5.5.3. Parámetros calibrados

La desviación estándar y el valor de la función objetivo son indicadores confiables para determinar la eficacia de los algoritmos de búsqueda (Trejo-Zúñiga et al., 2013). Además, el algoritmo de ED ofrece mejores aproximaciones al óptimo global comparado con otros algoritmos de búsqueda (Civicioglu and Besdok, 2013; Trejo-Zúñiga et al., 2013). Por otro lado, Tsum es el parámetro que indica los grados día el término del ciclo, es decir, temperatura acumulada de siembra a madurez fisiológica. Sin embargo, la madurez fisiológica de cultivo de frijol esta determina principalmente por el hábito de crecimiento, variedad y fotoperiodo; por lo tanto, valores de Tsum dentro del rango entre 950 y 2700 °C día pueden ser registrados (Ghassemi-Golezani and Mardfar, 2008; Ghassemi-Golezani et al., 2014; Zhao et al., 2019; Báez-Gonzales et al., 2020; Rai et al., 2020). I50A es la temperatura acumulada requerida para el desarrollo de área foliar para interceptar el 50% de la radiación, en frijol se han reportado valores de 450 °C día (Zhao et al 2019). Tbase es la temperatura en la cual se detiene o inicia el crecimiento y desarrollo de un cultivo. Para frijol, se han reportado Tbase de 5 °C (Rai et al., 2020), 8 °C (Báez-Gonzales et al., 2020) y 12 °C (Ghassemi-Golezani et al., 2014). Topt es la temperatura optima en la cual el crecimiento alcanza su máxima expresión, así, valores de 25 °C (Masaya y White, 1991), 27 °C (Zhao et al., 2019) y 30 °C (Báez-Gonzales et al., 2020), además, el frijol es capaz de soportar temperaturas extremas entre 5 y 40 °C (Fernández et al., 1985). Los valores de Tsum Topt y Tbase reportados como resultado de la calibración en este estudio están dentro de los rangos mencionados por otros autores anteriormente citados (Tabla 5.5).

Por otro lado, Swater es el parámetro de la sensibilidad de RUE al índice ARID (Zhao et al., 2019). Es decir, incorpora el efecto de la disponibilidad de agua en el cultivo, donde un ARID igual a cero indica que el cultivo está a su máxima demanda hídrica (sin estrés) (Woli et al., 2012). Sin embargo, los valores promedio para el tratamiento con mayor lamina de riego (R_{125} en 2020) en la etapa entre el

crecimiento vegetativo e inicio de floración fue de 0.39 (estrés moderado) y de inicio de floración a madurez fisiológica fue de 0.09 (sin estrés), lo cual coincidió con la estación lluviosa. Además, no se observó un comportamiento lineal de los valores de Swater y la lámina de riego aplicada. Es decir, Swater por sí solo no reflejó el efecto de agua en el modelo, evidencia de que existe interacción entre parámetros, por otro lado, no fue posible explorar un rango más amplio de láminas de riego debido al establecimiento de la estación lluviosa, misma que igualó el almacenamiento de agua en el suelo enmascarando el efecto los tratamientos de riego. Teweldebrhan et al. (2018) sostienen que existe interacción multiplicativa entre los parámetros de un modelo; es decir que el efecto de un parámetro se ve reflejado en las variables de salida, siempre y cuando intervenga otro parámetro. Bulatewicz et al. (2009) evaluando el modelo EPIC, concluyeron que para que haya cambios sustanciales en la simulación del modelo, explorar un rango amplio de láminas de riego de riego, sería deseable.

5.5.4. Calibración y evaluación

En el desempeño individual (Figura 3), la curva de biomasa obtenida, coincidió con el modelo clásico de crecimiento de frijol previamente establecido (White e Izquierdo, 1991; Silva et al., 2005; Lépiz-Ildefonso et al., 2018). Por otro lado, las estadísticas de la calibración y evaluación estuvieron dentro de un rango aceptable para los cuatro tratamientos de riego (Soltani et al., 2020; Mathobo et al., 2017). También, el RMSE observado fue ligeramente superior a los registrados en frijol sometido a diferentes niveles de humedad evaluados con el modelo SALTMED, específico para el balance hídrico (Dewedar et al., 2020). En general, los estadígrafos observados en este estudio (Figura 4) fueron considerados aceptables en la simulación de la biomasa de los cultivos, considerando que los valores estimados de los parámetros son solo aproximaciones a los valores reales y probablemente tengan un error bastante sustancial (Wallach, 2011). Esto considerando que, el cultivo de frijol presenta una gran interacción genotipo x ambiente (Barrios et al., 2011) y el modelo SIMPLE no considera parámetros genéticos.

En la etapa de calibración, los valores de biomasa observados fueron inferiores con respecto a los reportados en la evaluación, dichos resultados son atribuibles a las condiciones climáticas del 2021 que favorecieron el desarrollo frijol. Al respecto, Eman et al. (2010) señalan que la biomasa o rendimiento del frijol decrece al incrementar los niveles de déficit hídrico. Sin embargo, los valores de biomasa encontrados en este estudio son soportados por otros autores. Por ejemplo, Dewedar et al. (2020) reportaron valores de 14.6 t ha^{-1} en frijol de riego, mientras que Morales-Rosales et al. (2018) obtuvieron valores máximos de 13.0 t ha^{-1} , pero Acosta-Gallegos y Rosales-Serna, (1989) indicaron valores entre 4.0 y 8.0 t ha^{-1} para distintas variedades de frijol.

5.5.5. Índice de cosecha

Los datos de rendimiento generados en ambos experimentos concuerdan con los de Ranjan et al. (2019). Estos autores evaluando niveles de humedad y labranza en frijol 'Pinto Saltillo', obtuvieron rendimientos de grano entre 3.0 y 5.8 t ha^{-1} . Por otro lado, El modelo propuesto en este estudio para estimar el rendimiento de grano (Y) presentó excelentes resultados, comparados con los reportados: con el modelo CROPGRO Dry-bean, Dallacort et al. (2011) mencionan que dicho modelo subestimó el Y entre 19% y 29%, de frijol en condiciones de estrés hídrico, Monpremier et al., (2021) también utilizaron CROPGRO Dry-bean para simular Y de diferentes variedades de frijol con errores relativos de 32.1% y 15.6% en la etapa de calibración y evaluación respectivamente, por otro lado, en el modelo SSM-Legumes reportan un RMSE de 0.41 t ha^{-1} en la simulación de rendimiento de grano (Marrou et al., 2014), en el modelo SALMED reportaron diferencias relativas $< 4.86\%$ entre rendimiento observado y simulado de frijol en diferentes condiciones de riego (Dewedar et al., 2020). De igual manera, con el modelo Aquacrop se encontró un $\text{RMSE} > 0.28 \text{ t ha}^{-1}$ (Espadafor et al., 2017).

5.6.- Conclusiones

El modelo SIMPLE simula en forma correcta la dinámica de la biomasa en el cultivo de frijol ya que al calibrar los parámetros I50A, T_{opt}, S_{water}, T_{base}, I50_{maxW} y T_{sum} se obtuvo un buen ajuste entre las predicciones y mediciones. A pesar de ser

un modelo con pocos parámetros, el modelo SIMPLE mostró potencial para simular la biomasa de frijol sometido a diferentes condiciones de humedad y sirve como una herramienta de planificación de actividades productivas para el cultivo de frijol. Sin embargo, cuando los cambios de humedad son muy pequeños, el modelo no tiene la capacidad para expresar estas variaciones en la simulación de la biomasa.

En la etapa de evaluación en condiciones distintas de precipitación y evapotranspiración el modelo SIMPLE simula biomasa de cultivo adecuadamente. Los resultados indican que el modelo SIMPLE es una herramienta confiable y robusta para simular biomasa. Éste puede usarse para calcular la demanda hídrica diaria de frijol en función de los grados días de desarrollo. Por lo tanto, el riego puede ser programado en tiempo real para condiciones de clima árido y semiárido del norte de México.

La biomasa acumulada de frijol con respecto a la lámina aplicada respondió a un modelo lineal; mientras que la curva de acumulación de biomasa mostró un comportamiento sigmoideo, pero el rendimiento de grano tuvo un comportamiento incierto. No obstante, con el modelo de regresión lineal múltiple propuesto, es posible obtener una buena estimación de rendimiento de frijol.

Además, es recomendable utilizar distribuciones normales en parámetros más sensibles como Tsum y Swater para el análisis de sensibilidad y calibración. Aplicar demasiada incertidumbre y distribuciones uniformes en todos los parámetros la selección de los parámetros influyentes puede ser inadecuada y en la etapa de calibración los valores de los parámetros pueden salir de la frontera de la física.

5.6.- Referencias bibliográficas

- Acosta-Gallegos, J. A., Rosales-Serna, R., 1989. Biomasa y sus componentes en variedades indeterminadas de frijol. Memoria. In 35a Reunión Anual de PCCMCA. Programa Cooperativo Centroamericano para Mejoramiento de Cultivos y Animales. San Pedro Sula, Honduras.
- Allen, R. G., Pereira, L. S., Raes, D., Smith, M., 2006. Evapotranspiración del cultivo: guía para la determinación de los requerimientos de agua de los cultivos. Estudio FAO Riego y Drenaje. FAO, Roma. 2006. 56-323 pp. <http://www.fao.org/docrep/009/x0490s/x0490s00.htm>
- Amir, J., Sinclair, T. R., 1991. A model of water limitation on spring wheat growth and yield. Field Crops Research, 28(1-2), 59–69. doi:10.1016/0378-4290(91)90074-6
- Asseng, S., Foster, I., Turner, N.C., 2011. The impact of temperature variability on wheat yields. Glob. Change Biol. 17 (2), 997–1012. <https://doi.org/10.1111/j.1365-2486.2010.02262.x>

- Baez-Gonzalez, A. D., Fajardo-Díaz, R., Garcia-Romero, G., Osuna-Ceja, E., Kiniry, J. R., Meki, M. N., 2020. High Sowing Densities in Rainfed Common Beans (*Phaseolus vulgaris* L.) in Mexican Semi-Arid Highlands under Future Climate Change. *Agronomy*, 10(3), 442. <https://doi.org/10.3390/agronomy10030442>
- García B. G., E. J., López Castañeda, C., Kohashi Shibata, J., Acosta Gallegos, J. A., Miranda Colín, S., Mayek Pérez, N., 2011. Avances en el mejoramiento genético del frijol en México por tolerancia a temperatura alta ya sequía. *Revista fitotecnia mexicana*, 34(4), 247-255. <http://www.scielo.org.mx/pdf/rfm/v34n4/v34n4a6.pdf>
- Beebe, S., Ramirez, J., Jarvis, A., Rao, I. M., Mosquera, G., Bueno, J. M., Blair, M. W., 2011. Genetic Improvement of Common Beans and the Challenges of Climate Change Crop Adaptation to Climate Change (pp. 356-369).
- Bhar, A., Kumar, R., Qi, Z., Malone, R., 2020. Coordinate descent based agricultural model calibration and optimized input management. *Computers and Electronics in Agriculture*, 172, 105353. <https://doi.org/10.1016/j.compag.2020.105353>
- Boutraa, T., Sanders, F. E., 2001. Influence of water stress on grain yield and vegetative growth of two cultivars of bean (*Phaseolus vulgaris* L.). *Journal of Agronomy and Crop Science*, 187(4), 251-257 <https://doi.org/10.1046/j.1439-037X.2001.00525.x>
- Bulatewicz, T., Jin, W., Staggenborg, S., Lauwo, S., Miller, M., Das, S., ..., Welch, S. M., 2009. Calibration of a crop model to irrigated water use using a genetic algorithm. *Hydrology and Earth System Sciences*, 13(8), 1467-1483. <https://doi.org/10.5194/hess-13-1467-2009>
- Cadena-Hernández, D., Gaxiola-Ariza, R., & Mora-Avilés, M. A. (2019). Tolerancia a estrés hídrico en frijol cv. Pinto Saltillo modificado con el gen pirofosfatasa vacuolar-1 de *Arabidopsis thaliana*. *Revista mexicana de ciencias agrícolas*, 10(6), 1231-1245.
- Chalabi, Z., Zhou, W., 1994. Optimal control methods for agricultural systems. In II IFAC/ISHS Workshop September: Mathematical & Control Applications in Agriculture & Horticulture 406 (pp. 221-228). DOI:10.17660/ActaHortic.1996.406.22
- Civicioglu, P., Besdok, E., 2013. A conceptual comparison of the Cuckoo-search, particle swarm optimization, differential evolution and artificial bee colony algorithms. *Artificial intelligence review*, 39(4), 315-346.
- Dallacort, R., Freitas, P. S. L. d., Faria, R. T., Goncalves, A. C. A., Rezende, R., Guimaraes, R. M. L., 2011. Simulation of bean crop growth, evapotranspiration and yield in Paraná State by the CROPGRO-Drybean model. (*Journal, Electronic*). DOI: 10.4025/actasciagron.v33i3.11793
- Dewedar, O., Plauborg, F., Marwa, M., El-shafie, A., Ragab, R., 2020. Improving water saving, yield, and water productivity of bean under deficit drip irrigation: Field and modelling study using the SALTMed model. *Irrigation and Drainage*. <https://doi.org/10.1002/ird.2539>
- Emam, Y., Shekoofa, A., Salehi, F., Jalali, A. H., 2010. Water stress effects on two common bean cultivars with contrasting growth habits. *American-Eurasian Journal of Agricultural & Environmental Sciences*, 9(5), 495-499.
- Espadafor, M., Couto, L., Resende, M., Henderson, D. W., Garcia-Vila, M., Fereres, E., 2017. Simulation of the responses of dry beans (*Phaseolus vulgaris* L.) to irrigation. *Transactions of the ASABE*, 60(6), 1983-1994.
- Falconnier, G. N., Journet, E. P., Bedoussac, L., Vermue, A., Chlebowski, F., Beaudoin, N., Justes, E., 2019. Calibration and evaluation of the STICS soil-crop model for faba bean to explain variability in yield and N₂ fixation. *European Journal of Agronomy*, 104, 63-77. <https://doi.org/10.1016/j.eja.2019.01.001>
- FAOSTAT., 2022. FAO Statistics, Food and Agriculture Organization of the United Nations. <http://www.fao.org/faostat/en/> (Retrieved Jan 20, 2022)
- Fernández, F., Gepts, P., Lopez, M., 1985. Etapas de desarrollo en la planta de frijol . In: López Genes, Marceliano; Fernández O., Fernando O.; Schoonhoven, Aart van (eds.). *Frijol: Investigación y producción* . Programa de las Naciones Unidas (PNUD); Centro Internacional de Agricultura Tropical (CIAT), Cali, CO. p. 61-78.
- García, E. 2004. Modificaciones al sistema de clasificación climática de Köppen (Quinta ed.). México, DF: Instituto de Geografía-Universidad Nacional Autónoma de México (UNAM). <http://www.publicaciones.igg.unam.mx/index.php/ig/catalog/view/83/82/251-1>

- Ghassemi-Golezani, K., Abriz, S. F., Hassanpour-Bourkheili, S., 2014. Development of mung-bean seed vigour under different irrigations and plant densities. *International Journal of Plant, Animal and Environmental Sciences*, 4(3), 208-211.
- Ghassemi-Golezani, K., Mardfar, R. A., 2008. Effects of limited irrigation on growth and grain yield of common bean. *J. Plant Sci*, 3(3), 230-235.
- Heng, L. K., Hsiao, T., Evett, S., Howell, T., Steduto, P., 2009. Validating the FAO AquaCrop model for irrigated and water deficient field maize. *Agronomy journal*, 101(3), 488-498. <https://doi.org/10.2134/agronj2008.0029xs>
- INEGI (Instituto Nacional De Estadística y Geografía)., 2012. Censo Agropecuario 2007. <http://www3.inegi.org.mx> (Retrieved May 15, 2022)
- Karimzadeh Soureshjani, H., Nezami, A., Kafi, M., Tadayon, M., 2019. Responses of two common bean (*Phaseolus vulgaris* L.) genotypes to deficit irrigation. *Agricultural Water Management*, 213, 270-279. doi: <https://doi.org/10.1016/j.agwat.2018.09.038>
- Katerji, N., Mastrorilli, M., & Rana, G. (2008). Water use efficiency of crops cultivated in the Mediterranean region: Review and analysis. *European Journal of Agronomy*, 28(4), 493–507. doi:10.1016/j.eja.2007.12.003
- Kemarian, A. R., Stöckle, C. O., Huggins, D. R., Viegas, L. M., 2007. A simple method to estimate harvest index in grain crops. *Field Crops Research*, 103(3), 208-216. <https://doi.org/10.1016/j.fcr.2007.06.007>
- Kherif, O., Seghouani, M., Justes, E., Plaza-Bonilla, D., Bouhenache, A., Zemmouri, B., ... , Latati, M., 2022. The first calibration and evaluation of the STICS soil-crop model on chickpea-based intercropping system under Mediterranean conditions. *European Journal of Agronomy*, 133, 126449. <https://doi.org/10.1016/j.eja.2021.126449>
- Krause, P., D. P. Boyle, and F. Bäse., 2005. Comparison of different efficiency criteria for hydrological model assessment. *Adv. Geosci.* 5: 89-97. <https://doi.org/10.5194/adgeo-5-89-2005>
- Lépiz-Ildefonso, R., Chavarín-Espinoza, I. E., López-Alcocer, J. D. J., Rodríguez-Guzmán, E., 2018. Dry matter accumulation during developmental stages of common bean cultivars. *Revista fitotecnia mexicana*, 41(3), 275-282. <https://doi.org/10.35196/rfm.2018.3.275-283>.
- Ljung, L., and Glad, T., 1994. Modeling of dynamic systems, PTR Prentice Hall, Englewood Cliffs, N.J.
- Luo, Q., 2011. Temperature thresholds and crop production: a review. *Climatic change*, 109(3), 583-598. <https://doi.org/10.1007/s10584-011-0028-6>
- Lynch, J., van Beem, J. J., 1993. Growth and architecture of seedling roots of common bean genotypes. *Crop Science*, 33(6), 1253-1257. <https://doi.org/10.2135/cropsci1993.0011183X003300060028x>
- Ma, H., Malone, R. W., Jiang, T., Yao, N., Chen, S., Song, L., ..., He, J., 2020. Estimating crop genetic parameters for DSSAT with modified PEST software. *European Journal of Agronomy*, 115, 126017. <https://doi.org/10.1016/j.eja.2020.126017>
- Magalhães, I. D., Lyra, G. B., de Souza, J. L., Teodoro, I., da Rocha, A. E. Q., Cavalcante, C. A., . . . , de Souza Ferraz, R. L., 2019. Performance of the Aquacrop model for bean ('*Phaseolus vulgaris* L.') under irrigation condition. *Australian Journal of Crop Science*, 13(7), 1188. doi: 10.21475/ajcs.19.13.07.p1790
- Marrou, H., Sinclair, T. R., Metral, R., 2014. Assessment of irrigation scenarios to improve performances of Lingot bean (*Phaseolus vulgaris*) in southwest France. *European Journal of Agronomy*, 59, 22–28. doi:10.1016/j.eja.2014.05.006
- Martínez-Gamiño, M. A., Osuna-Ceja, E. S., Padilla-Ramírez, J. S., Acosta-Gallegos, J. A., Laredo-Osti, C., 2008. Tecnología para la producción de frijol en el norte centro de México. *Libro Técnico*, (4).
- Martínez-Ruiz, A., López-Cruz, I.L., Ruiz-García, A., Pineda-Pineda, J., Prado-Hernández, J.V., 2019. HortSyst: A dynamic model to predict growth, nitrogen uptake, and transpiration of greenhouse tomatoes. *Chil. J. Agric. Res*, 79, 89–102. <http://dx.doi.org/10.4067/S0718-58392019000100089>
- Martínez-Ruiz, A., Ruiz-García, A., Prado-Hernández, J. V., López-Cruz, I. L., Valencia-Islas, J. O., Pineda-Pineda, J., 2021. Global Sensitivity Analysis and Calibration by Differential Evolution Algorithm of HORTSYST Crop Model for Fertigation Management. *Water*, 13(5). doi: 10.3390/w13050610

- Masaya, P., White, J. W., 1991. Adaptation to photoperiod and temperature. In: Common Beans: Research for Crop Improvement. A V Schoonhoven, O Voysest (eds). C. A. B. Intl. U. K. and CIAT, Cali, Colombia. pp:445-500.
- Mathobo, R., Marais, D., Steyn, J. M., 2018. Calibration and validation of the SWB model for dry beans (*Phaseolus vulgaris* L.) at different drought stress levels. *Agricultural Water Management*, 202, 113-121. <https://doi.org/10.1016/j.agwat.2018.02.018>
- Mompremier, R., Her, Y., Hoogenboom, G., Migliaccio, K., Muñoz-Carpena, R., Brym, Z., . . . , Jeune, W., 2021. Modeling the response of dry bean yield to irrigation water availability controlled by watershed hydrology. *Agricultural Water Management*, 243, 106429. <https://doi.org/10.1016/j.agwat.2020.106429>
- Monteith, J.L., 1965. Light distribution and photosynthesis in field crops. *Ann. Bot.* 29 (113), 17–37. <https://doi.org/10.1093/oxfordjournals.aob.a083934>
- Morales-Rosales, E. J., Escalante-Estrada, J. A. S., López-Sandoval, J. A., 2008. Crecimiento, índice de cosecha y rendimiento de frijol (*Phaseolus vulgaris* L.) en unicultivo y asociado con girasol (*Helianthus annuus* L.). *Universidad y ciencia*, 24(1), 1-10.
- Oliveira, E. C. d., Costa, J. M. N. d., Paula Júnior, T. J. d., Ferreira, W. P. M., Justino, F. B., Neves, L. d. O., 2012. The performance of the CROPGRO model for bean (*Phaseolus vulgaris* L.) yield simulation. *Acta Scientiarum. Agronomy*, 34(3), 239-246. Doi: 10.4025/actasciagron.v34i3.13424
- Olivera, N. T., Manrique, O. B., Masjuan, Y. G., Alega, A. M. G., 2016. Evaluation of AquaCrop model in crop dry bean growth simulation. *Revista Ciencias Técnicas Agropecuarias*, 25(3), 23-30. <https://www.redalyc.org/articulo.oa?id=93246970003>
- Omae, H., Kumar, A., Shono, M., 2012. Adaptation to high temperature and water deficit in the common bean (*Phaseolus vulgaris* L.) during the reproductive period. *Journal of Botany*, vol.2012. doi:10.1155/2012/803413
- Price, K.V., Storn, R.M., Lampinen, J. A., 2005. Differential Evolution. A practical approach to global optimization. Springer-Verlag Berlin Heidelberg. 538 pp.
- Rai, A., Sharma, V., Heitholt, J., 2020. Dry bean [*phaseolus vulgaris* L.] growth and yield response to variable irrigation in the arid to semi-arid climate. *Sustainability*, 12(9), 3851. <https://doi.org/10.3390/su12093851>
- Ranjan, R., Chandel, A. K., Khot, L. R., Bahlol, H. Y., Zhou, J., Boydston, R. A., Miklas, P. N., 2019. Irrigated pinto bean crop stress and yield assessment using ground based low altitude remote sensing technology. *Information Processing in Agriculture*. doi:10.1016/j.inpa.2019.01.005
- Ritchie, J.T., Godwin, D.C., Otter-Nacke, S., 1985. CERES-wheat: A User-oriented Wheat Yield Model. Preliminary Documentation. AGRISTARS Publication No. YM-U3-04442-JSC-18892. Michigan State University, Michigan. <https://cir.nii.ac.jp/crid/1573387449661175552>
- Saltelli, A., Ratto, M., Andres, T., Campolongo, F., Cariboni, J., Gatelli, D., Tarantola, S., 2008. Global sensitivity analysis: the primer. John Wiley & Sons. DOI: 10.1002/9780470725184
- Saltelli, A., Tarantola, S., Campolongo, F., Ratto, M., 2004 Sensitivity Analysis in Practice. A Guide to Assessing Scientific Models; John Wiley & Sons, Ltd.: Hoboken, NJ, USA, 219p. https://doi.org/10.1111/j.1467-985X.2005.358_13.x
- Saltelli, A.; Ratto, M.; Tarantola, S.; Campolongo, F. Sensitivity analysis practices: Strategies for model-based inference. *Reliab. Eng. Syst. Saf.* 2006, 91, 1109–1125. <https://doi.org/10.1016/j.ress.2005.11.014>
- SAS Institute Inc. SAS 9.3 System Options: Reference. 2nd ed. Cary, NC: SAS Institute Inc; 2011.
- Schwartz, H.F., Brick, M.A., 2015. Dry Bean Pest Management and Production, 3rd ed.; Cooperative Extension Resource Center, Colorado State University: Fort Collins, CO, USA
- Seidel, S. J., Palosuo, T., Thorburn, P., Wallach, D., 2018. Towards improved calibration of crop models – Where are we now and where should we go? *European Journal of Agronomy*, 94, 25-35. doi: <https://doi.org/10.1016/j.eja.2018.01.006>
- Serna, P. A.; Zegbe, J. A. y Mena, C. J., 2011. Rendimiento y calidad de chile seco Mirasol cultivado bajo riego parcial de la raíz. *Rev. Chapingo Ser. Hortic.* 17(1):19-24. <http://www.scielo.org.mx/pdf/rcsh/v17nspe1/v17nspe1a4.pdf>
- Servín Palestina, M., Tijerina Chávez, L., Medina García, G., Palacios Velez, O., Flores Magdaleno, H., 2017. Sistema para programar y calendarizar el riego de los cultivos en tiempo real.

- Revista mexicana de ciencias agrícolas, 8(2), 423-430. <https://doi.org/10.29312/remexca.v8i2.61>
- Sheng, M., Liu, J., Zhu, A. X., Rossiter, D. G., Liu, H., Liu, Z., Zhu, L., 2019. Comparison of GLUE and DREAM for the estimation of cultivar parameters in the APSIM-maize model. *Agricultural and Forest Meteorology*, 278. doi: 10.1016/j.agrformet.2019.107659
- SIAP., 2015. Servicio de Información y Estadística Agroalimentaria y Pesquera Información Agrícola. Avances mensuales por estado. <http://www.siap.sagarpa.gob.mx> (Retrieved May 15, 2022)
- Silva V. M. P., M. J. B. Andrade, A. R. Moraes, N. M. B. Vieira and J. Alves Jr., 2005. Dry matter accumulation by common bean cv. BRS MG Talismã. *Bean Improvement Cooperative* 48:154-155.
- Sinclair, T.R., Tanner, C.B., Bennet, J.M., 1984. Water use efficiency in crop production. *BioScience* 34 (1), 36–40. <https://doi.org/10.2307/1309424>
- Soltani, A., Alimagham, S. M., Nehbandani, A., Torabi, B., Zeinali, E., Dadrasi, A., . . . Sinclair, T. R., 2020. SSM-iCrop2: A simple model for diverse crop species over large areas. *Agricultural Systems*, 182, 102855. doi: <https://doi.org/10.1016/j.agsy.2020.102855>
- Soltani, A., Sinclair, T.R., 2012. *Modeling Physiology of Crop Development. Growth and Yield*, CABI, Wallingford, UK.
- 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. *Agron. J.* 101 (3), 426–437 <https://doi.org/10.2134/agronj2008.0139s>
- Stöckle, C. O., Donatelli, M., Nelson, R., 2003. CropSyst, a cropping systems simulation model. *European journal of agronomy*, 18(3-4), 289-307. [https://doi.org/10.1016/S1161-0301\(02\)00109-0](https://doi.org/10.1016/S1161-0301(02)00109-0)
- Teweldebrhan, A. T., Burkhart, J. F., Schuler, T. V., 2018. Parameter uncertainty analysis for an operational hydrological model using residual-based and limits of acceptability approaches. *Hydrology and Earth System Sciences*, 22(9), 5021-5039. <https://doi.org/10.5194/hess-22-5021-2018>
- Trejo-Zúñiga, E. C., López-Cruz, I. L., Ruíz-García, A., 2013. Parameter estimation for crop growth model using evolutionary and bio-inspired algorithms. *Agrociencia*, 47(7), 671-682. <http://www.scielo.org.mx/pdf/agro/v47n7/v47n7a4.pdf>
- Van Ittersum, M.K., Howden, S.M., Asseng, S., 2003. Sensitivity of productivity and deep drainage of wheat cropping systems in a Mediterranean environment to changes in CO₂, temperature and precipitation. *Agric. Ecosyst. Environ.* 97 (1), 255–273. [https://doi.org/10.1016/S0167-8809\(03\)00114-2](https://doi.org/10.1016/S0167-8809(03)00114-2)
- Van Loon, M. P., Deng, N., Grassini, P., Rattalino Edreira, J. I., Wolde-meskel, E., Bajjukya, F., ..., van Ittersum, M. K., 2018. Prospect for increasing grain legume crop production in East Africa. *European Journal of Agronomy*, 101, 140–148. <https://doi.org/10.1016/j.eja.2018.09.004>
- van Straten, G., 2008. What can systems and control theory do for agricultural science?. *Automatika: Journal for Control, Measurement, Electronics, Computing & Communications*, 49. <http://hrcak.srce.hr/file/46123>
- Voinov, A. A., 2010. *Systems science and modeling for ecological economics*. Academic Press. <https://ezproxy2.utwente.nl/login?url=http://www.dawsonera.com/depp/reader/protected/external/AbstractView/S9780080886176>
- Voinov, A., Gaddis, E. J. B., 2008. Lessons for successful participatory watershed modeling: a perspective from modeling practitioners. *Ecological modelling*, 216(2), 197-207. <https://doi.org/10.1016/j.ecolmodel.2008.03.010>
- Wallach, D., 2011. Crop model calibration: A statistical perspective. *Agronomy Journal*, 103(4), 1144-1151. <https://doi.org/10.2134/agronj2010.0432>
- Wallach, D., Buis, S., Lecharpentier, P., Bourges, J., Clastre, P., Launay, M., . . . Justes, E., 2011. A package of parameter estimation methods and implementation for the STICS crop-soil model. *Environmental Modelling and Software*, 26(4), 386-394. doi: 10.1016/j.envsoft.2010.09.004
- Wallach, D., Makowski, D., Jones, J.W., Brun, F., 2019. *Working with Dynamic Crop Models: Methods, Tools and Examples for Agriculture and Environment*, Third. ed. Academic Press, London, U.K

- Wallach, D., Palosuo, T., Thorburn, P., Hochman, Z., Gourdain, E., Andrianasolo, F., ..., Seidel, S. J., 2021. The chaos in calibrating crop models: Lessons learned from a multi-model calibration exercise. *Environmental Modelling & Software*, 145, 105206. <https://doi.org/10.1016/j.envsoft.2021.105206>.
- Wang, J., Li, X., Lu, L., Fang, F., 2013. Parameter sensitivity analysis of crop growth models based on the extended Fourier Amplitude Sensitivity Test method. *Environ. Model. Softw.* 48, 171–182. <https://doi.org/10.1016/j.envsoft.2013.06.007>
- White, J. W., Izquierdo, J., 1991. Physiology of yield potential and stress tolerance. In: *Common Beans. Research for Crop Improvement*. A. van Schoonhoven and O. Voysest (eds.). CAB International. Wallingford, U. K. pp:287-382.
- Woli, P., Jones, J., Ingram, K., Fraisse, C., 2012. Agricultural reference index for drought (ARID). *Agron. J.* 104 (2), 287–300. <https://doi.org/10.2134/agronj2011.0286>
- Zhao Chuang, B. L., Liujun Xiao, Gerrit Hoogenboom, Kenneth J. Boote, Belay T. Kassie, Willingthon Pavan, . . . Yan Zhu, S. A., 2019. A SIMPLE crop model. *European Journal of Agronomy*, 104(1161-0301), 97-106. <https://doi.org/10.1016/j.eja.2019.01.009>
- Zhou, Q., Zhang, Y., & Wu, F. (2021). Evaluation of the most proper management scale on water use efficiency and water productivity: A case study of the Heihe River Basin, China. *Agricultural Water Management*, 246, 106671. doi:10.1016/j.agwat.2020.106671

VI. CONCLUSIONES GENERALES

El código abierto y la disponibilidad de las ecuaciones de los procesos fisiológicos involucrados de los modelos del cultivo permite a los investigadores adaptarlos en acuerdo a sus necesidades de simulación, esta ventaja permite resolver los problemas encontrado en la mayoría de modelos usados para simular el crecimiento y desarrollo del frijol, sobre todo fechas de cambio de las etapas fenológicas.

Las incertidumbres de las variables de salida están relacionadas con la precipitación que influyo en gran medida en la simulación del modelo SIMPLE, seguida de la temperatura y radiación solar. Además, es recomendable realizar un análisis de incertidumbre de las variables de entrada para hacer mejor inferencia sobre las fuentes de incertidumbre y el desempeño del modelo. También, para mejorar la robustez y la calidad de le predicción tanto para el frijol de riego como para el de seco, es necesario dar especial atención en el parámetro Tsum.

De acuerdo con el análisis de sensibilidad global, el modelo para cultivos SIMPLE con datos climáticos de Zacatecas de primavera (riego) sugiere cinco parámetros influyentes. La Tsum es el índice que más afecta el sistema para simulación de tiempo térmico, biomasa y rendimiento, Swater es más importante en riego, seguido I50A, posteriormente, Tb y Topt. Para invierno (secano) es importe considerar RUE, dando un total de seis parámetros más influyes para representar las condiciones climáticas de las cuatro regiones productoras de frijol de Zacatecas.

Con el método GLUE se identificó la importancia de aplicar distribución normal a los parámetros más influyentes (Tsum y Swater) para identificar los parámetros más sensibles en el análisis de incertidumbre con el modelo SIMPLE sin calibrar, garantizan la expresión de los parámetros que se enmascaran al aplicar demasiada incertidumbre.

El análisis de incertidumbre con el método GLUE utilizando el modelo SIMPLE calibrado indican que la incertidumbre aplicada a los parámetros en cada uno de los escenarios no tiene influencia en los intervalos de confianza, sin embargo, al utilizar

el modelo SIMPLE sin calibrar se recomienda utilizar distribución normal en Tsum y Swater.

El modelo SIMPLE simula en forma correcta la dinámica de la biomasa en el cultivo de frijol ya que al calibrar los parámetros I50A, T_{opt}, Swater, T_b, I50maxW y Tsum se obtuvo un buen ajuste entre las predicciones y mediciones. A pesar de ser un modelo con pocos parámetros, el modelo SIMPLE mostró potencial para simular la biomasa de frijol sometido a diferentes condiciones de humedad y sirve como una herramienta de planificación de actividades productivas para el cultivo de frijol. Sin embargo, cuando los cambios de humedad son muy pequeños, el modelo no tiene la capacidad para expresar estas variaciones en la simulación de la biomasa.

La biomasa acumulada de frijol con respecto a la lámina aplicada respondió a un modelo lineal; mientras que la curva de acumulación de biomasa mostró un comportamiento sigmoideo, pero el rendimiento de grano tuvo un comportamiento incierto. No obstante, con el modelo de regresión lineal múltiple propuesto, es posible obtener una buena estimación de rendimiento de frijol.

VII. LITERATURA CITADA

- Asseng, S., Guarin, J. R., Raman, M., Monje, O., Kiss, G., Despommier, D. D., ... Gauthier, P. P. G. (2020). Wheat yield potential in controlled-environment vertical farms. *Proceedings of the National Academy of Sciences*, 202002655. doi:10.1073/pnas.2002655117
- Asseng, S., Foster, I., Turner, N.C., 2011. The impact of temperature variability on wheat yields. *Glob. Change Biol.* 17 (2), 997–1012.
- Bala, B.K., Arshad, F.M., Noh, K.M., 2017. *System Dynamics. Modelling and Simulation*. Springer. Singapore. 278 pp. https://doi.org/10.1007/978-981-10-2045-2_9
- Boogaard, H.L., Diepen, C.A.v., Rutter, R.P., Cabrera, J., Laar, H.H.v., 1998. User's guide for the WOFOST 7.1 crop growth simulation model and WOFOST ControlCenter 1.5.
- Brisson, N., Gary, C., Justes, E., Roche, R., Mary, B., Ripoche, D., Zimmer, D., Sierra, J., Bertuzzi, P., Burger, P., Bussière, F., Cabidoche, Y.-M., Cellier, P., Debaeke, P., Gaudillière, J.-P., Hénault, C., Maraux, F., Seguin, B., Sinoquet, H., 2003. An overview of the crop model STICS. *Eur. J. Agron.* 18, 309–332.
- Cavero, J., Farre, I., Debaeke, P., & Faci, J. M. (2000). Simulation of maize yield under water stress with the EPICphase and CROPWAT models. *Agronomy Journal*, 92(4), 679-690.
- Farré, I., Faci, J.M., 2006. Comparative response of maize (*Zea mays* L.) and sorghum (*Sorghum bicolor* L. Moench) to deficit irrigation in a Mediterranean environment. *Agric. Water Manage.* 83, 135–143.
- García, E. 2004. *Modificaciones al sistema de clasificación climática de Köppen* (Quinta ed.). México, DF: Instituto de Geografía-Universidad Nacional Autónoma de México (UNAM). <http://www.publicaciones.igg.unam.mx/index.php/ig/catalog/view/83/82/251-1>
- Goudriaan, J., & Van Laar, H. H. (2012). *Modelling potential crop growth processes: textbook with exercises* (Vol. 2). Springer Science & Business Media.
- Haefner, J. W. (2005). *Modeling biological systems: principles and applications*. Springer Science & Business Media.
- Heng, L. K., Hsiao, T., Evett, S., Howell, T., & Steduto, P. (2009). Validating the FAO AquaCrop model for irrigated and water deficient field maize. *Agronomy journal*, 101(3), 488-498. <https://doi.org/10.2134/agronj2008.0029xs>
- Hoogenboom, G., et al., 2010. *Decision Support System for Agrotechnology Transfer (DSSAT) Version 4.5 [CD-ROM]*. University of Hawaii, Honolulu, Hawaii.
- Hoogenboom, G., Jones, J. W., Traore, P., & Boote, K. J. (2012). Experiments and data for model evaluation and application. In *Improving soil fertility recommendations in Africa using the Decision Support System for Agrotechnology Transfer (DSSAT)* (pp. 9-18). Springer, Dordrecht.
- INEGI (Instituto Nacional De Estadística y Geografía). (2012). *Censo Agropecuario 2007*. Septiembre, 25, 2016, de INEGI Sitio web: <http://www3.inegi.org.mx>
- Jones, J.W., et al., 2003. The DSSAT cropping system model. *Eur. J. Agron.* 18 (3-4), 235–265.
- Keating, B. A., & Thorburn, P. J. (2018). Modelling crops and cropping systems—Evolving purpose, practice and prospects. *European journal of agronomy*, 100, 163-176.
- Ko, J., Piccinni, G., & Steglich, E. (2009). Using EPIC model to manage irrigated cotton and maize. *Agricultural Water Management*, 96(9), 1323-1331.
- Lépiz-Ildefonso, R., Chavarín-Espinoza, I. E., López-Alcocer, J. D. J., Rodríguez-Guzmán, E., 2018. Dry matter accumulation during developmental stages of common bean cultivars. *Revista fitotecnia mexicana*, 41(3), 275-282. <https://doi.org/10.35196/rfm.2018.3.275-283>.
- Ljung, L., & Glad, T. (1994). *Modeling of Dynamic Systems*. Englewood Cliffs, NJ: Prentice-Hall.
- Li, Y., Hoogenboom, G., Asseng, S., Niu, J.-Y., Wu, L., & Kang, L.-H. (2022). Adaptation of the SIMPLE Model to Oilseed Flax (*Linum usitatissimum* L.) for Arid and Semi-Arid Environments. *Agronomy*, 12(6). doi: 10.3390/agronomy12061267
- Wheat yield potential in controlled-environment vertical farms

- López-Cruz, I. L., Ramírez-Arias, A., & Rojano-Aguilar, A. (2005). Modelos matemáticos de hortalizas en invernadero: trascendiendo la contemplación de la dinámica de cultivos. *Revista Chapingo Serie Horticultura*, 11(2), 257-267.
- Raes, D., Steduto, P., Hsiao, T. C., Fereres, E., Izzi, G., & Heng, L. K. (2010). AquaCrop (versión 3.1) reference manual. FAO, Rome.
- Ritchie, J.T., Godwin, D.C., Otter-Nacke, S., 1985. CERES-wheat: A User-oriented Wheat Yield Model. Preliminary Documentation. AGRISTARS Publication No. YM-U3-04442-JSC-18892. Michigan State University, Michigan.
- SAGARPA. (2015). Propuesta de estructuras tipo para la organización de conglomerados productivos y comerciales, integrados por pequeños productores de frijol con empresas integradoras. En línea: https://www.gob.mx/cms/uploads/attachment/file/346972/Frijol_Detallado.pdf
- Sandhu, R., & Irmak, S. (2019). Performance of AquaCrop model in simulating maize growth, yield, and evapotranspiration under rainfed, limited and full irrigation. *Agricultural Water Management*, 223, 105687.
- SIAP., 2020. Servicio de Información y Estadística Agroalimentaria y Pesquera Información Agrícola. Avances mensuales por estado. <http://www.siap.sagarpa.gob.mx> (Retrieved May 15, 2022)
- Sinclair, T.R., Tanner, C.B., Bennet, J.M., 1984. Water use efficiency in crop production. *BioScience* 34 (1), 36–40.
- Stöckle, C. O., Donatelli, M., & Nelson, R. (2003). CropSyst, a cropping systems simulation model. *European Journal of Agronomy*, 18(3-4), 289–307. doi:10.1016/s1161-0301(02)00109-0
- 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. *Agron. J.* 101 (3), 426–437
- Van Ittersum, M.K., Howden, S.M., Asseng, S., 2003. Sensitivity of productivity and deep drainage of wheat cropping systems in a Mediterranean environment to changes in CO₂, temperature and precipitation. *Agric. Ecosyst. Environ.* 97 (1), 255–273.
- Van Laar, H. H., Goudriaan, J., & Van Keulen, H. (1992). Simulation of crop growth for potential and water-limited production situations: as applied to spring wheat (No. 27). CABO-DLO.
- Voinov, A., Gaddis, E. J. B., 2008. Lessons for successful participatory watershed modeling: a perspective from modeling practitioners. *Ecological modelling*, 216(2), 197-207. <https://doi.org/10.1016/j.ecolmodel.2008.03.010>
- Woli, P., Jones, J., Ingram, K., Fraisse, C., 2012. Agricultural reference index for drought (ARID). *Agron. J.* 104 (2), 287–300.
- Xinyou, Y., and H. Van Laar, 2005: Crop systems dynamics: an ecophysiological simulation model for genotype-by-environment interactions, Wageningen Academic Publishers
- Yang C-C, Chang L-C, Chen C-S, Yeh M-S (2009) Multi-objective planning for conjunctive use of surface and subsurface water using genetic algorithm and dynamics programming. *Water Resour Manag* 23(3):417–437
- Zhao Chuang, B. L., Liujun Xiao, Gerrit Hoogenboom, Kenneth J. Boote, Belay T. Kassie, Willingthon Pavan, . . . Yan Zhu, S. A., 2019. A SIMPLE crop model. *European Journal of Agronomy*, 104(1161-0301), 97-106. <https://doi.org/10.1016/j.eja.2019.01.009>

VIII. APÉNDICES

8.1. Descripción de modelo de cultivo SIMPLE

El modelo dinámico SIMPLE y en tiempo discreto, propuesto por Zhao et. Al., (2019) simula el crecimiento limitado por agua, el desarrollo y el rendimiento de los cultivos utilizando un paso de tiempo diario, con funciones o ecuaciones que explican el efecto de la temperatura diaria, el estrés por calor, la disponibilidad de agua en el suelo y la concentración atmosférica de CO₂. El tiempo térmico (TTi, °C d⁻¹) y producción de biomasa seca (Biomasa, t ha⁻¹) son las variables de estado y el rendimiento de grano (Y, t ha⁻¹) es una variable de salida. El modelo SIMPLE tiene 13 parámetros, nueve relacionados con el tipo de cultivo y cuatro que especifican diferencias entre variedades. El modelo SIMPLE se basa en la intercesión de radiación y considera las temperaturas cardinales (Figura 8.1).




Figura 8.1. Diagrama conceptual del modelo simple

El modelo SIMPLE utiliza la temperatura acumulada para determinar el desarrollo fenológico (Ritchie et al., 1985) de la siguiente manera:

$$TT_{i+1} = TT_i + \Delta TT \quad 1)$$

$$\Delta TT = \begin{cases} T - T_b; & T > T_b \\ 0 & ; T \leq T_b \end{cases} \quad 2)$$

donde TT_i (°C d) es el tiempo térmico para el i-ésimo día, ΔTT (°C) es el incremento diario en temperatura, T (°C) es la temperatura media diaria y T_b (°C) es la temperatura base para el desarrollo fenológico de los cultivos.

El crecimiento de biomasa se basa en la eficiencia en el uso de la radiación (Monteith, 1965), es decir, una fracción de la radiación fotosintéticamente activa diaria es interceptada por la planta y se transforma en biomasa de cultivos.

$$Bio_{i+1} = Bio_i + \Delta Bio \quad 3)$$

$$\Delta Bio = R_s \cdot f_{Solar} \cdot RUE \cdot f(CO_2) \cdot f(Temp) \cdot \min[f(Heat), f(Water)] \quad 4)$$

donde: Bio_{i+1} (t ha⁻¹) es la biomasa acumulada diaria hasta madurez fisiológica, ΔBio (t ha⁻¹ día⁻¹) es la tasa de crecimiento diario de la biomasa y f_{Solar} es la fracción de la radiación solar interceptada por un dosel de cultivo, RUE (g MJ⁻¹ m⁻²) es la eficiencia del uso de la radiación y $f(calor)$, $f(CO_2)$, $f(Temp)$ y $f(Agua)$ son factores de corrección por estrés a altas temperaturas, impacto del CO_2 , impacto a temperaturas cardinales y a sequía respectivamente, factores que pueden o no favorecer la acumulación de biomasa.

El rendimiento del grano se calcula como el producto de la biomasa total acumulada ($Bio - cum_{maturity}$) y el índice de cosecha (HI) (Amir and Sinclair, 1991).

$$Y = Bio - cum_{maturity} \times HI \quad 5)$$

El modelo SIMPLE realiza un balance de agua en el suelo basándose en la metodología de la curva número y escorrentía. Para este balance se utilizan cuatro parámetros para caracterizar el suelo de la parcela experimental: 1) humedad disponible ($AWC=0.123 \text{ m}^3 \text{ m}^{-3}$), 2) coeficiente de drenaje profundo ($DDC=0.5$), 3) curva número de escorrentía ($RCN=0.81$) y 4) profundidad radicular ($RDZ=600 \text{ mm}$),

además, el modelo utiliza el índice estandarizado de sequía ARID (Woli et al., 2012) para relacionar el efecto de agua en el suelo con la acumulación de biomasa. Muchas de las funciones de SIMPLE han sido usadas en otros modelos de cultivos, descritas en Tabla 8.1.

Tabla 8.1. Ecuaciones auxiliares del modelo SIMPLE

Descripción	Ecuación	Fuente
fSolar para el crecimiento de las hojas y el período de senescencia se basa en la ley de Beer-Lambert, fsolar_max =0.95	$fSolar = \begin{cases} \frac{fsolar_max}{1 + e^{-0.01(TT-I_{50A})}}, & leaf\ growth\ period \\ \frac{fsolar_max}{1 + e^{-0.01(TT-(Tsum-I_{50B}))}}, & leaf\ senescence\ period \end{cases}$	(Steduto et al., 2009).
El impacto de la temperatura en la tasa de crecimiento de la biomasa	$f(Temp) = \begin{cases} 0 & T < T_{base} \\ \frac{T - T_{base}}{T_{opt} - T_{base}} & T_{base} \leq T < T_{opt} \\ 1 & T \geq T_{opt} \end{cases}$	(Ritchie et al., 1985)
El impacto del estrés por calor en la tasa de crecimiento de la biomasa	$f(heat) = \begin{cases} 1 & T_{max} \leq T_{heat} \\ 1 - \frac{T_{max} - T_{heat}}{T_{ext} - T_{heat}} & T_{heat} < T_{max} \leq T_{extreme} \\ 0 & T_{max} > T_{extreme} \end{cases}$	(Asseng et al., 2011).
La temperatura acumulada requerida para alcanzar el 50% de la interceptación de la radiación durante la senescencia del dosel (I50B) se ve incrementada por el estrés por calor	$I_{50B_{i+1}} = I_{50B_i} + I_{max, heat} (1 - f(heat))$	(Zhao et al., 2019)
El impacto del CO ₂ en la RUE	$f(CO_2) = \begin{cases} 1 + S_{CO_2} (CO_2 - 350) & 350 ppm \leq CO_2 < 700 ppm \\ 1 + S_{CO_2} (350) & CO_2 > 700 ppm \end{cases}$	(Van Ittersum et al., 2003)
Estrés por sequía basado en retención de agua.	$f(water) = 1 + S_{water} (ARID)$	(Zhao et al., 2019)
Índice estandarizado de estrés por sequía	$ARID = 1 - \frac{\min(ET_o, 0.096 * PAW)}{ET_o}$	(Woli et al. (2012),
El estrés por sequía reduce la RUE	$I_{50B_{i+1}} = I_{50B_i} + I_{max, water} (1 - f(water))$	(Sinclair et al., 1984)
La interceptación de la radiación afectado por estrés por sequía	$fSolar_water = \begin{cases} 0.9 + f(water) & f(water) < 0.1 \\ 1 & f(water) \geq 0.1 \end{cases}$	(Steduto et al., 2009).

Tsum: Requerimiento de temperatura de siembra hasta madurez (°C d).

HI: Índice potencial de cosecha

I50A: Requerimiento de temperatura acumulada para el desarrollo de área foliar para interceptar el 50% de la radiación (°C d).

I50B: Requerimiento de temperatura acumulada hasta la madurez para alcanzar el 50% de la radiación debido a la senescencia foliar (°C d).

Tbase: Temperatura base para el crecimiento y desarrollo de la fenología (°C).

Topt: Temperatura óptima para el crecimiento de biomasa (°C).

RUE: Eficiencia en el uso de la radiación (solo sobre el suelo y sin respiración) (g MJ⁻¹m⁻²).

I50maxH: La reducción diaria máxima en I50B debido al estrés por calor (°C d).

I50maxW: La reducción diaria máxima en I50B debido al estrés por sequía (°C d).

Tmax: Umbral de temperatura para comenzar a acelerar la senescencia por estrés por calor (°C).

Text: El umbral de temperatura extrema cuando RUE se convierte en 0 debido al estrés por calor (°C).

SCO₂: Aumento relativo de la RUE por ppm de CO₂ elevado por encima de 350 ppm.

Swater: Sensibilidad de la RUE (o índice de cosecha) al estrés por sequía (índice ARID).