

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMÍA**



**ESTADO ACTUAL DE LOS MODELOS DE SIMULACIÓN QUE ESTIMEN
RENDIMIENTO DE CULTIVOS Y FRUTALES EN FUNCIÓN DEL AGUA
APLICADA**

POR

MARÍA GRACIA ROMERO SANDOVAL

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN
PARA OPTAR AL TÍTULO DE
INGENIERO AGRÓNOMO.**

**CHILLÁN – CHILE
2025**

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMÍA**

**ESTADO ACTUAL DE LOS MODELOS DE SIMULACIÓN QUE ESTIMEN
RENDIMIENTO DE CULTIVOS Y FRUTALES EN FUNCIÓN DEL AGUA
APLICADA**

POR

MARÍA GRACIA ROMERO SANDOVAL

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN
PARA OPTAR AL TÍTULO DE
INGENIERO AGRÓNOMO.**

**CHILLÁN – CHILE
2025**

Aprobada por:

Profesor Asistente, Mathias Kuschel O.
Ing. Civil Agrícola, Dr.

Guía

Profesor Asistente, Abdelhalim Khaled E.
Ing Agrónomo, Dr.

Asesor

Profesor Asistente, Walter Valdivia C.
Ing Agrónomo, Dr.

Asesor

Profesor Asociado, Guillermo Wells M.
Ing. Agrónomo, Mg. Cs.

Decano

TABLA DE CONTENIDOS

	Página
Resumen	1
Summary.....	2
Introducción	2
Desarrollo y Discusión	4
Conclusiones	22
Referencias	25

INDICE DE FIGURAS Y TABLAS

		Página
Figura 1	Superficie regional de los principales cultivos anuales en Chile.....	15
Figura 2	Superficie regional de los principales frutales en Chile.....	20
Tabla 1	Mecanismo de simulación del crecimiento en modelos de simulación de rendimiento de cultivos.....	11
Tabla 2	Comparativa funcional entre modelos de simulación de rendimiento en cultivos.....	12
Tabla 3	Superficie, rendimiento y participación de la superficie total de los 5 principales cultivos anuales en Chile.....	15
Tabla 4	Comparación de estudios para los modelos de simulación en cultivos.....	16
Tabla 5	Superficie, rendimiento y participación superficie total de los 5 principales frutales en Chile.....	19
Tabla 6	Comparación de estudios para modelos de simulación en frutales.....	21

ESTADO ACTUAL DE LOS MODELOS DE SIMULACIÓN QUE ESTIMEN RENDIMIENTO DE CULTIVOS Y FRUTALES EN FUNCIÓN DEL AGUA APLICADA

CURRENT STATE OF SIMULATION MODELS FOR ESTIMATING YIELD IN CROPS AND FRUIT TREES AS FUNCTION OF APPLIED IRRIGATION WATER

Palabras índice adicionales: Toma de decisiones, Cambio climático, Producción sostenible, Eficiencia del uso del agua, Simulación agronómica.

RESUMEN

Los modelos de simulación agrícola permiten estimar el rendimiento de cultivos y frutales en función del agua aplicada, constituyéndose en herramientas fundamentales para optimizar la gestión hídrica y anticipar impactos asociados al cambio climático. Su aplicación ha sido ampliamente validada en cultivos anuales como trigo, maíz y papa mediante modelos como AquaCrop, CropSyst, APSIM y DSSAT, mostrando capacidad para representar interacciones suelo-clima-manejo y respuestas al estrés hídrico. En contraste, los frutales presentan un menor grado de modelación debido a su complejidad fisiológica, naturaleza perenne y escasez de datos fenológicos y productivos de largo plazo. Si bien se han desarrollado enfoques estructurales y sistemas híbridos con inteligencia artificial, persisten limitaciones por la baja disponibilidad de información validada y adaptada a condiciones locales. En el caso de Chile, se observa una escasa cantidad de estudios de calibración y validación para ambos tipos de cultivos, lo que restringe la implementación operativa de estos modelos. Fortalecer su desarrollo e integración en contextos productivos reales es clave para avanzar hacia una agricultura resiliente, eficiente y basada en evidencia en un escenario de creciente variabilidad climática.

SUMMARY

Crop simulation models estimate yield based on applied water, playing a crucial role in optimizing water use and anticipating climate-related risks. Their application is well

established in annual crops such as wheat, maize, and potato, using tools like AquaCrop, CropSyst, APSIM, and DSSAT, which effectively simulate soil-climate-management interactions and water stress responses. In contrast, fruit crops remain underrepresented due to their perennial nature, physiological complexity, and the lack of long-term phenological and yield data. Although structural approaches and hybrid systems combining process-based modeling and machine learning show promising results, limitations persist due to scarce locally adapted and validated information. In Chile, a significant gap remains in calibration and validation studies for both annual crops and fruit trees, limiting practical implementation. Enhancing the development and integration of these tools in real production systems is essential to support a more resilient and efficient agriculture under increasing climate variability.

INTRODUCCIÓN

El cambio climático global, impulsado principalmente por actividades humanas, ha generado impactos significativos en el medio ambiente (Roco *et al.*, 2015). Esta variabilidad climática inducida se manifiesta mediante irregularidades cada vez más frecuentes, especialmente en las zonas productivas, afectando directamente las actividades agronómicas y generando nuevos desafíos para el futuro de la agricultura (Bhadouria *et al.*, 2019; Chaudhary y Bawa, 2011). Entre los principales factores que limitan la producción se encuentran las alteraciones en la temperatura, la degradación del suelo, las fluctuaciones en la concentración de gases, la irregularidad de las precipitaciones y la creciente escasez hídrica (Bhadouria *et al.*, 2019).

Paralelamente, el crecimiento sostenido de la población mundial, proyectado en casi 10 mil millones de personas para el 2080 (United Nations, 2024) ha incrementado la demanda global de alimentos, fibras y biocombustibles, intensificando la presión sobre los recursos agrícolas. En este escenario, Chile desempeña un rol estratégico como uno de los principales exportadores mundiales de fruta, destacando por su calidad y volumen de producción (Diario Frutícola, 2024). Sin embargo, esta posición se ve amenazada por las crecientes restricciones

hídricas, lo que hace indispensable incorporar herramientas que permitan optimizar el uso del agua y mejorar la eficiencia de los sistemas productivos.

La denominada Megasequía que afecta a gran parte del territorio chileno desde el año 2010, ha reducido las precipitaciones anuales entre un 25 y el 45 % (Garreaud *et al.*, 2017; Stehr *et al.*, 2019), lo que ha intensificado la extracción de aguas subterráneas para riego. Se estima que esta extracción aumentará en un 5,5 % para el 2050 (FAO, 2011), lo cual refuerza la necesidad de utilizar el recurso hídrico de forma más racional y sustentable.

Para cubrir la creciente demanda de alimentos, fibras y biocombustibles debido al aumento poblacional, se proyecta que la producción agrícola deberá incrementarse en un 30 % hacia el año 2050 respecto a los niveles del 2012 (OMS *et al.*, 2017). Este aumento dependerá en gran medida, de la mejora de los rendimientos, los cuales han crecido en un 113 % entre 1961 y 2018 gracias a mejoras tecnológicas como el desarrollo varietal, el uso de agroquímicos, una mejor gestión del suelo y el avance en los sistemas de riego (Mekonnen y Gerbens-Leenes, 2020). Sin embargo, factores como el cambio climático, la salinización y la degradación de suelos imponen límites a este crecimiento, reforzando la necesidad de optimizar la productividad del agua (Grassini *et al.*, 2013).

Dado que las necesidades hídricas varían significativamente entre cultivos y frutales, influenciadas por factores como la ubicación geográfica, el tipo de suelo, y las prácticas de manejo, resulta clave disponer de herramientas que permitan estimar dichas demandas de manera precisa. Una de ellas es la evapotranspiración de cultivo (ETc) (Allen *et al.*, 2006), cuyo uso se ha complementado en las últimas décadas con modelos de simulación que permiten establecer relaciones entre el agua aplicada y el rendimiento obtenido, como la ecuación de Doorenbos y Kassam (1979), ampliamente difundida por FAO (2012).

En este contexto, han surgido modelos más complejos que simulan el crecimiento y desarrollo de cultivos y frutales bajo diferentes condiciones edafoclimáticas, entregando estimaciones dinámicas sobre rendimiento, consumo de agua y eficiencia del sistema. Estos modelos constituyen herramientas fundamentales para anticipar escenarios, planificar el riego, y evaluar estrategias de

manejo más sostenibles en el marco del cambio climático (ODEPA, 2023c; Steduto *et al.*, 2012).

Por tanto, el objetivo es entregar una revisión bibliográfica de los principales modelos de simulación de rendimiento en cultivos y frutales en función del agua aplicada, analizando sus fundamentos, requerimientos y aplicabilidad en los principales cultivos agrícolas de Chile, con énfasis en su utilidad para enfrentar los desafíos que impone el cambio climático en la gestión hídrica y la sostenibilidad de los sistemas productivos.

DESARROLLO Y DISCUSIÓN

Capítulo I. Modelos de simulación para estimar rendimiento en función del agua aplicada

Un modelo de simulación es una representación simplificada y cuantitativa de un sistema complejo, basada en un conjunto de ecuaciones que describe los procesos y relaciones entre las variables de un fenómeno del mundo real. Los modelos de simulación agrícola permiten representar de forma simplificada sistemas complejos, integrando variables clave como clima, suelo, características fisiológicas del cultivo y prácticas de manejo (Gavasso-Rita *et al.*, 2024; Pérez-Maqueo *et al.*, 2006). Esta integración posibilita estimar el crecimiento, la productividad y el consumo de recursos bajo distintos escenarios ambientales y de manejo, facilitando la toma de decisiones agronómicas (FAO, 2021; Hernández *et al.*, 2009). Además, estos modelos son esenciales para analizar la eficiencia en el uso del agua y los nutrientes, reducir impactos ambientales y proyectar respuestas frente a condiciones climáticas cambiantes, aspectos cruciales para la seguridad alimentaria y el diseño de estrategias agrícolas sostenibles (CGIAR, 2025).

Los modelos de simulación se clasifican según su estructura y propósito. Los modelos estáticos describen relaciones entre variables en un momento específico, mientras que los modelos dinámicos incorporan la dimensión temporal, permitiendo analizar la evolución de los sistemas (Oteng-Darko *et al.*, 2013). Por otro lado, los modelos determinísticos generan predicciones exactas basadas en datos iniciales definidos, mientras que los modelos estocásticos incluyen elementos aleatorios

para representar la incertidumbre inherente (Candelaria *et al.*, 2011). Además, los modelos empíricos se fundamentan en datos observados para establecer relaciones matemáticas mediante regresiones, mientras que los modelos mecanicistas explican los procesos físicos y biológicos subyacentes del sistema (Hernández *et al.*, 2009).

La evolución histórica de los modelos de simulación comenzó en la década de 1950, con la creación de modelos descriptivos y matemáticos enfocados en procesos específicos. Posteriormente, en los años 60, surgieron los sistemas dinámicos, que incorporaron la dimensión temporal y permitieron representar el flujo y la interacción de los procesos en el tiempo. Ya en la década de 1970, se formalizó el concepto de dinámica de sistemas, el cual se perfeccionó en los años 80 gracias al desarrollo de técnicas computacionales que facilitaron la verificación, validación y evaluación de estos modelos (Barrett y Nearing, 2018).

En este contexto de avance metodológico, uno de los modelos clásicos más influyentes en el ámbito agrícola es el desarrollado por Doorenbos y Kassam, (1979), disponible en el reporte de la FAO 33. Este modelo establece una relación directa entre la disminución relativa del rendimiento de los cultivos y la reducción de la evapotranspiración, constituyéndose en una herramienta clave para evaluar el impacto del déficit hídrico sobre la productividad. Este modelo se basa en la ecuación 1:

$$\left(1 - \frac{Y_a}{Y_x}\right) = K_y \cdot \left(1 - \frac{ET_a}{ET_x}\right) \quad (1)$$

Donde Y_a e Y_x representan el rendimiento real y el rendimiento máximo, respectivamente, ET_a y ET_x son la evapotranspiración real y la evapotranspiración máxima, respectivamente y K_y es el factor de respuesta del rendimiento que presenta el efecto de una disminución de la evapotranspiración sobre las pérdidas de rendimiento (Steduto *et al.*, 2012). Este modelo establece una relación lineal entre el déficit hídrico relativo y la reducción del rendimiento, permitiendo evaluar el impacto de las limitaciones hídricas en la productividad agrícola.

Además de la relación lineal propuesta por Doorenbos y Kassam (1979), en el ámbito agrícola también se han utilizado modelos matemáticos empíricos para

estimar el rendimiento de cultivos y frutales en función del agua aplicada. Entre ellos, destacan los modelos polinomiales (por lo general cuadráticos), que permiten describir relaciones no lineales entre variables (Holzapfel *et al.*, 1990). Los modelos cuadráticos permiten estimar niveles óptimos de riego para maximizar rendimientos (Orozco-Romero y Pérez-Zamora, 2004). Su ecuación general es:

$$y = ax^2 + bx + c \quad (2)$$

Donde x representa la variable independiente e y la variable dependiente, a es el coeficiente cuadrático que define la curvatura, b el coeficiente lineal que indica la pendiente y c es la constante que define el punto de intersección con el eje y.

En síntesis, los modelos agrícolas se han desarrollado desde enfoques empíricos y matemáticos simples hasta herramientas más complejas capaces de simular procesos fisiológicos bajo distintos escenarios. A continuación, se describen los principales modelos de simulación utilizados.

AquaCrop. Es un modelo de simulación desarrollado por la FAO para estimar el rendimiento de cultivos herbáceos en función del agua aplicada, especialmente en contextos de escasez hídrica (Steduto *et al.*, 2009). Se basa en un enfoque mecanicista que representa el crecimiento del cultivo a partir del balance hídrico del suelo, descomponiendo la evapotranspiración en transpiración real del cultivo y evaporación del suelo, según la humedad del perfil radicular y la cobertura del dosel (Steduto *et al.*, 2009). Su objetivo principal es analizar la respuesta del cultivo al estrés hídrico y apoyar la planificación de estrategias de riego eficientes, maximizando la producción con un uso racional del agua (Cai *et al.*, 2024).

El modelo utiliza parámetros conservadores, como el WP* (productividad del agua), que convierte directamente la transpiración en biomasa (B), y calcula el rendimiento final (Y) mediante un índice de cosecha (HI) ajustado en función del estrés hídrico. Este estrés se expresa mediante funciones que modelan la inhibición del crecimiento del dosel, la reducción de la conductancia estomática, la senescencia anticipada y la disminución del HI (Steduto *et al.*, 2009).

Para su funcionamiento, requiere datos climáticos diarios (temperaturas máximas y mínimas (Tmax y Tmin), precipitación, evapotranspiración de referencia

(ET_o), concentración de CO₂), características del suelo (contenido de agua a saturación, capacidad de campo (CC), punto de marchitez permanente (PMP), conductividad hidráulica), parámetros del cultivo (fecha de siembra, densidad, cobertura del dosel, profundidad radicular, HI) y prácticas de manejo (tipo de riego, frecuencia, volumen aplicado, salinidad del agua y uso de mulch o camellones) (Raes *et al.*, 2015). Las salidas del modelo incluyen B acumulada, Y, eficiencia del uso del agua (WUE), balance hídrico y nivel de estrés hídrico. AquaCrop se destaca por su equilibrio entre simplicidad, precisión y aplicabilidad. Requiere pocos parámetros y es accesible para técnicos, agricultores e investigadores, incluso sin experiencia previa en modelación. Sin embargo, presenta algunas limitaciones: asume homogeneidad del perfil del suelo y simula únicamente flujos de agua en dirección vertical, lo cual puede restringir su precisión en suelos heterogéneos. Para una correcta calibración, se recomienda disponer de datos de biomasa, rendimiento e índice de área foliar (Raes *et al.*, 2015). Gracias a su diseño y flexibilidad, AquaCrop se presenta como una herramienta eficaz y adaptable para mejorar la gestión del agua y la productividad en sistemas agrícolas de distintas escalas y condiciones (Steduto *et al.*, 2009).

CropSyst. Es un modelo de simulación agroecosistémico de tipo mecanicista, multianual, multicultivo y de paso de tiempo diario, desarrollado para analizar el impacto del clima, el suelo y las prácticas de manejo sobre la productividad agrícola y el medio ambiente (Stöckle *et al.*, 2003). Su estructura modular permite representar procesos como la fenología, el crecimiento de biomasa, el desarrollo radicular, el balance hídrico, la dinámica del nitrógeno, la erosión hídrica y la salinidad del suelo. Esta flexibilidad lo convierte en una herramienta robusta para simular diversos escenarios de manejo, rotaciones de cultivos y condiciones agroclimáticas, tanto a escala de parcela como a nivel de cuenca (Confalonieri *et al.*, 2006).

El objetivo principal de CropSyst es evaluar el comportamiento de sistemas agrícolas en respuesta a factores edafoclimáticos y de manejo, considerando tanto la productividad como los efectos ambientales. Esto incluye el análisis de la eficiencia en el uso de agua y nutrientes, el diseño de rotaciones sostenibles, el

impacto del cambio climático y la evaluación de políticas agrarias (Mazhoud *et al.*, 2022; Stöckle *et al.*, 2003).

Para su ejecución, CropSyst requiere cinco archivos de entrada: simulación, ubicación, suelo, cultivo y manejo. Estos incluyen datos meteorológicos diarios (temperatura, radiación solar, precipitación, humedad relativa y viento), propiedades del suelo (textura, CC, pH, capacidad de intercambio catiónico (CIC), conductividad hidráulica), parámetros fisiológicos del cultivo (fenología, índice de cosecha, WUE y eficiencia en el uso de la radiación, sensibilidad a salinidad y CO₂), y prácticas de manejo (labranza, fertilización, riego y fechas de siembra o cosecha) (Raza *et al.*, 2014; Umair *et al.*, 2017).

Las salidas generadas por el modelo abarcan Y, biomasa acumulada, índice de área foliar (LAI), índice de cosecha (HI), balance hídrico (ET, escorrentía, percolación y almacenamiento), WUE, y un completo balance de nitrógeno, incluyendo absorción, lixiviación, mineralización y volatilización. Además, permite evaluar procesos como la descomposición de residuos, la erosión hídrica y la salinidad del suelo (Malek *et al.*, 2018; Stöckle *et al.*, 2003).

Entre sus principales ventajas destaca su capacidad para representar sistemas de cultivo complejos en el tiempo y el espacio, su modularidad, y su interfaz amigable. Estas características lo hacen apto para el modelado de agroecosistemas bajo condiciones reales de manejo (Confalonieri *et al.*, 2006).

No obstante, su nivel de detalle implica una mayor carga de datos de entrada, lo cual puede representar una dificultad inicial para usuarios sin experiencia. A pesar de ello, CropSyst ha sido validado y aplicado en una amplia variedad de cultivos y regiones, consolidándose como una herramienta versátil para la toma de decisiones en agricultura sustentable (Umair *et al.*, 2017). Gracias a su capacidad para integrar múltiples variables agronómicas y ambientales, CropSyst es ampliamente utilizado en la planificación y evaluación de prácticas agrícolas sostenibles bajo diversos escenarios de manejo y cambio climático (Stöckle *et al.*, 2003).

APSIM. Es un modelo de simulación agroecosistémico de tipo mecanicista, desarrollado por la Commonwealth Scientific and Industrial Research Organisation (CSIRO) en Australia. Su diseño modular permite representar con precisión una

amplia variedad de procesos biofísicos en sistemas agrícolas, incluyendo el crecimiento de cultivos, el ciclo del agua y nutrientes, la descomposición de residuos, y la dinámica del suelo bajo distintos escenarios de manejo (Holzworth *et al.*, 2014; McCown *et al.*, 1996). Cada módulo simula un proceso específico como el nitrógeno del suelo, el agua disponible o el desarrollo fenológico y todos se comunican mediante un sistema de mensajería basado en eventos, lo que permite una alta integración y flexibilidad en las simulaciones (Holzworth *et al.*, 2014).

El objetivo principal de APSIM es proporcionar una plataforma de modelación que permita analizar la respuesta de los sistemas agrícolas al clima y a distintas prácticas de manejo, facilitando la toma de decisiones en investigación, extensión agronómica y formulación de políticas (B. Keating *et al.*, 2003). Gracias a su nivel de detalle, este modelo es especialmente útil para evaluar la sostenibilidad productiva y ecológica de diferentes alternativas de manejo bajo condiciones de incertidumbre climática.

Para su funcionamiento, APSIM requiere datos meteorológicos diarios (temperatura máxima y mínima, precipitación, radiación solar), parámetros físicos del suelo (textura, pH, CC, CIC, conductividad hidráulica), información fisiológica del cultivo (curvas de crecimiento, requerimientos térmicos, sensibilidad al estrés hídrico y nutricional), y programación detallada de prácticas de manejo (fechas y dosis de riego, fertilización, cosecha, labranza, entre otros) (B. Keating *et al.*, 2003).

Entre las principales salidas del modelo se encuentran el rendimiento de los cultivos, la biomasa acumulada, la eficiencia en el uso del agua (WUE), el balance hídrico y el balance de nutrientes (particularmente N y P), además de indicadores de erosión, cambios en el pH del suelo y simulaciones de asimilación o asimilación de carbono.

Las ventajas de APSIM radican en su robustez científica, su estructura altamente modular, y su capacidad de simular escenarios complejos que integran cultivos, pasturas, árboles y ganadería. Además, permite definir reglas de manejo personalizadas mediante un lenguaje tipo script, lo que le otorga gran versatilidad (Holzworth *et al.*, 2014). No obstante, su implementación requiere una curva de

aprendizaje más elevada que otros modelos, debido a la complejidad de sus configuraciones y la necesidad de un conjunto amplio de datos de entrada.

APSIM ha sido utilizado extensamente en investigaciones sobre eficiencia del uso de agua, rotaciones, sistemas mixtos, evaluación de brechas de rendimiento, adaptación al cambio climático y diseño de políticas agrícolas. Gracias a su capacidad para integrar procesos físicos, biológicos y de manejo, APSIM se consolida como una herramienta estratégica para la simulación de agroecosistemas complejos bajo condiciones ambientales variables (B. A. Keating, 2024).

DSSAT. Decision Support System for Agrotechnology Transfer es un modelo de simulación agroecosistémico que permite representar el crecimiento, desarrollo y rendimiento de más de 40 cultivos bajo condiciones ambientales y de manejo específicas (Hoogenboom *et al.*, 2019; Jones *et al.*, 2003). Este modelo integra la información del clima, suelo, genotipo y manejo agronómico para predecir el comportamiento de los cultivos en diversos entornos (Uehara & Tsuji, 1998). DSSAT opera con paso de tiempo diario y se basa en principios mecanicistas orientados a procesos, lo que permite simular el funcionamiento del sistema de cultivo de forma detallada y dinámica (Chen *et al.*, 2019).

Para su ejecución, DSSAT requiere una base de datos climática (temperaturas máximas y mínimas diarias, precipitación y radiación solar), un perfil de suelo (contenido de agua a saturación, PMP, CC, densidad aparente, pH, textura, C orgánico), un archivo de manejo (fecha de siembra, fertilización, riego, labranza, cosecha), y un archivo de cultivar con coeficientes genéticos que representan características específicas del crecimiento fenológico y fisiológico de cada variedad (Jones *et al.*, 2003; Pokhrel *et al.*, 2022). La simulación también requiere la calibración y validación del modelo con datos experimentales locales para asegurar su aplicabilidad (Tooley *et al.*, 2021).

Las salidas generadas por DSSAT incluyen datos diarios y acumulados del desarrollo del cultivo (etapas fenológicas, índice de área foliar, biomasa, rendimiento de grano, contenido de N en hojas), y del suelo (contenido de agua, nitrógeno y carbono por capas). También entrega balances de agua y nutrientes, y reportes resumidos del ciclo del cultivo (Liu *et al.*, 2011; Mishra *et al.*, 2013). La ET

se calcula utilizando diferentes métodos (Priestley-Taylor, Penman-FAO24 o Penman-Monteith FAO56), lo que permite evaluar la eficiencia en el uso del agua (Jamieson *et al.*, 1998).

Entre sus ventajas destaca la versatilidad del modelo, su amplia validación internacional, y la capacidad de integrar efectos del genotipo, clima, suelo y manejo para simular escenarios pasados, presentes y futuros. Además, su estructura modular permite simular sistemas de cultivo complejos y rotaciones, y adaptarlo a diferentes regiones (Jones *et al.*, 2003; Msongaleli *et al.*, 2014). Como limitación, el modelo requiere una calibración cuidadosa y un número considerable de datos iniciales, lo que puede dificultar su uso en regiones con escasa información experimental (Jones *et al.*, 2003).

DSSAT ha sido utilizado globalmente para estimaciones de rendimiento, análisis de impactos del cambio climático, transferencia de tecnología y apoyo a la toma de decisiones agrícolas (Kalra *et al.*, 2007). Gracias a su precisión, flexibilidad y base científica sólida, DSSAT se ha consolidado como una herramienta clave para simular el desempeño de los cultivos en escenarios variables y orientar prácticas agrícolas sostenibles (Hoogenboom *et al.*, 2019).

La Tabla 1 presenta los mecanismos de simulación del crecimiento empleados por cada uno de los modelos previamente descritos. Por su parte, la Tabla 2 muestra una comparación funcional entre estos cuatro modelos, categorizando las variables consideradas en cada uno para facilitar el análisis de sus similitudes y diferencias.

Tabla 1. Mecanismo de simulación del crecimiento en modelos de simulación de rendimiento de cultivos

Modelo	Mecanismo de simulación del crecimiento
AquaCrop	Utiliza la cobertura del dosel (canopia) como variable central para estimar la transpiración del cultivo. La biomasa se calcula como el producto entre la transpiración acumulada y un coeficiente de productividad del agua (WP^*), siendo el rendimiento el resultado del índice de cosecha ajustado por estrés (Steduto <i>et al.</i> , 2009).

CropSyst	Se basa en la radiación fotosintéticamente activa interceptada (RFAI) o, alternativamente, en la transpiración efectiva, para estimar la acumulación diaria de biomasa. El rendimiento final se calcula mediante un índice de cosecha ajustado por condiciones ambientales (Stöckle <i>et al.</i> , 2003).
APSIM	Simula la acumulación de biomasa a partir de la captura de luz o transpiración, limitada por factores como agua, nitrógeno y temperatura. Utiliza el desarrollo del dosel y la fenología como ejes centrales, con reglas de partición de biomasa por órgano (Keating <i>et al.</i> , 2003).
DSSAT	Emplea el índice de área foliar (LAI) y coeficientes genéticos del cultivar para simular la fenología, crecimiento y partición de biomasa. La biomasa se genera por fotosíntesis o transpiración y se reparte entre órganos productivos según demanda fisiológica (Jones <i>et al.</i> , 2003).

Tabla 2. Comparativa funcional entre modelos de simulación de rendimiento en cultivos.

Variable	AquaCrop (Steduto <i>et al.</i> , 2009)	CropSyst (Stöckle <i>et al.</i> , 2003)	APSIM (B. Keating <i>et al.</i> , 2003)	DSSAT (Jones <i>et al.</i> , 2003)
Parámetros hídricos				
Humedad del suelo	X	X	X	X
Riego	C	C	C	C
Encharcamiento	X		C	C
Lixiviación de nutrientes		X	X	C
Escorrentía de nutrientes		X	X	C
Parámetros fisiológicos				
Producción de raíces	X	X	C	X
Crecimientos de órganos		X	C	X
Desarrollo fisiológico	X	X	C	X

Llenado de grano	X	X	C	X
Intercambio de gases		C		
Fotosíntesis	C	C	C	X
Producción y rendimiento				
Biomasa total	X	X	X	X
Rendimiento	X	X	X	X
Suelo y nutrientes				
Nitrógeno en planta/suelo		X	X	X
Erosión		X	X	C
Carbono orgánico del suelo		X	X	X
Salinidad	X	X		C
Factores climáticos y estrés				
Sequía	X	X	X	C
Temperatura	X	X	X	X
Ráfagas de viento			C	
Lluvias intensas	C	C	C	C
Helada	C		C	
Calor	X	X	X	X
Cambio climático	C	C	C	C
Esterilidad	C		C	C

X: Output automatizado por el modelo, C: Proceso condicionado, inferido o dependiente de entradas externas, (En blanco): No representado en el modelo.

Capítulo II. Aplicación de los modelos de simulación en cultivos anuales

En Chile, los cinco cultivos anuales con mayor superficie sembrada son el trigo harinero, la avena, el maíz de consumo, la papa y el raps, los cuales representan el 72,67 % de la superficie total destinada a cultivos anuales (ODEPA, 2023c).

El trigo harinero ocupa un lugar destacado en la agricultura nacional, con una superficie sembrada de 179.443 hectáreas durante la temporada 2023/2024, equivalente al 35,47 % del total. En esta misma temporada, la producción alcanzó 1.063.227 toneladas, con un rendimiento promedio de 59,25 quintales por hectárea.

Este cultivo tiene un rol fundamental tanto económico como social, ya que es producido principalmente por pequeños agricultores, y su destino principal es la elaboración de pan y otros alimentos esenciales para la dieta chilena (ODEPA, 2023a)

La avena constituye el segundo cultivo más relevante en términos de superficie, abarcando el 16,85 % del total de los cultivos anuales. Durante la temporada 2023/2024 se sembraron 85.215 hectáreas, alcanzando una producción total de 457.567 toneladas y un rendimiento promedio de 53,7 quintales por hectárea (ODEPA, 2023c). Este cultivo se utiliza principalmente como insumo para la alimentación animal, aunque también se destina, en menor medida, a la producción de alimentos para consumo humano (Valenzuela, 2019).

El maíz de consumo ocupa el tercer lugar en importancia con superficie sembrada de 38.427 hectáreas, equivalente al 7,6 % del total. En la temporada 2023/2024, la producción alcanzó aproximadamente 500.829 toneladas, con un rendimiento promedio de 130,33 quintales por hectárea (ODEPA, 2023c). Este cultivo se destina principalmente a la alimentación animal, siendo utilizado en concentrados y forraje, aunque también tiene aplicaciones en la industria alimentaria y el consumo humano (González, 2020).

La papa es el cuarto cultivo anual en superficie sembrada, con 36.074 hectáreas, lo que representa un 7,13 % del total en la temporada 2023/2024. La producción alcanzó 1.246.278 toneladas, con un rendimiento promedio de 345,48 quintales por hectárea (ODEPA, 2023c). Este cultivo tiene una alta relevancia alimentaria en Chile, siendo el segundo alimento más consumido por la población, tanto en cantidad como en aporte calórico (Ministerio de Desarrollo Social y Familia, 2023).

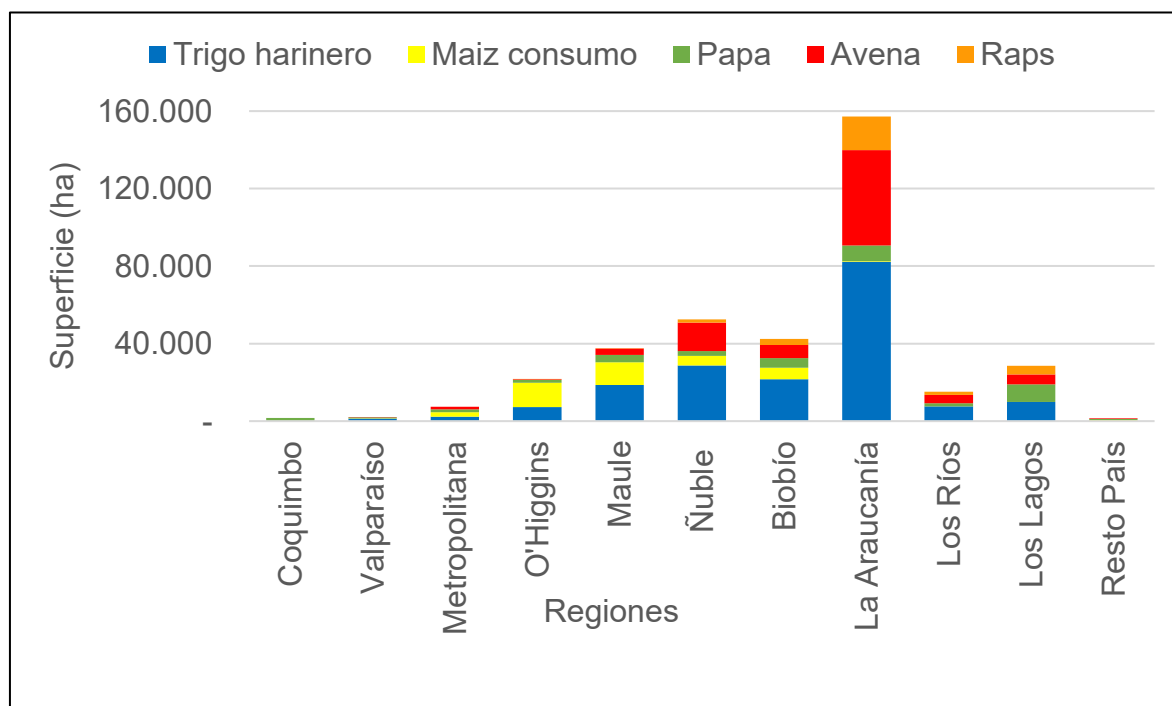
Finalmente, el raps se posiciona como el quinto cultivo en superficie sembrada, con 28.440 hectáreas, lo que equivale al 5,62 % del total en la temporada 2023/2024. Su producción total fue de aproximadamente 123.068 toneladas, con un rendimiento promedio de 43,27 quintales por hectárea (ODEPA, 2023b). Este cultivo es altamente versátil, ya que se utiliza para la producción de aceite comestible, alimentación animal y biocombustibles (ODEPA, 2023b)

La Figura 1 muestra la superficie sembrada por región para los cinco principales cultivos del país. Se observa que la Región de La Araucanía concentra la mayor superficie cultivada en la sumatoria total de estos cultivos, seguida por las regiones de Ñuble y Biobío. Complementariamente, la Tabla 3 detalla la superficie sembrada, el rendimiento y la participación porcentual de cada cultivo respecto a la superficie total nacional, permitiendo una comparación más precisa entre ellos.

Tabla 3. Superficie, rendimiento y participación de la superficie total de los 5 principales cultivos anuales en Chile (ODEPA, 2023c).

Cultivo	Superficie (ha)	Rendimiento (qqm ha ⁻¹)	Participación superficie total (%)
Trigo Harinero	179.443	59,25	35,47
Avena	85.215	53,70	16,85
Maíz consumo	38.427	130,33	7,60
Papa	36.074	345,48	7,13
Raps	28.440	43,27	5,62

Figura 1. Superficie regional de los principales cultivos anuales en Chile (ODEPA, 2023c).



Los modelos de simulación agrícola AquaCrop, CropSyst, APSIM y DSSAT han sido ampliamente aplicados en cultivos como trigo harinero, maíz, avena, papa y raps, permitiendo analizar su rendimiento bajo distintas condiciones edafoclimáticas y de manejo. AquaCrop ha mostrado utilidad en la simulación de la respuesta al estrés hídrico en trigo y maíz (da Conceição *et al.*, 2022; Peña, 2013), mientras que DSSAT ha sido validado para maíz en contextos de rotación (Umair *et al.*, 2017). APSIM ha demostrado alta precisión en la simulación de avena, papa y raps, incorporando interacciones suelo-clima-manejo (George y Kaffka, 2017; Luo *et al.*, 2024; Ma *et al.*, 2022). Por su parte, CropSyst ha sido utilizado eficazmente en papa y raps para evaluar eficiencia hídrica y estrategias de manejo sostenible (Honar *et al.*, 2011; Montoya *et al.*, 2018). En conjunto, estos modelos constituyen herramientas clave para optimizar decisiones agronómicas, estimar rendimientos y adaptar la agricultura al cambio climático. La Tabla 4 recopila diversos estudios que han aplicado modelos de simulación en los cinco principales cultivos en Chile. En ella se presentan los resultados estadísticos obtenidos, los cuales reflejan la correspondencia entre los rendimientos observados y los simulados, permitiendo evaluar el grado de ajuste y precisión de los modelos utilizados.

Tabla 4. Comparación de estudios para los modelos de simulación en cultivos.

Cultivo	Descripción del estudio
AquaCrop	
Trigo	Calibrado en Chillán, Chile. Valores de la prueba T correspondientes al rendimiento, $p > 0,05$ (Peña, 2013).
Maíz	Validado en Chile y Brasil. NRMSE entre 0,21 y 6,71% (da Conceição <i>et al.</i> , 2022).
Papa	Validado en Córdoba, Argentina. Valores de R^2 correspondientes al rendimiento entre 0,899 y 0,90 (De la Casa <i>et al.</i> , 2013).
Raps	Validado en Irán. Valores de NRMSE, R^2 e índice d correspondientes al rendimiento 7,05%, 0,86 y 0,96 respectivamente (Khorsand <i>et al.</i> , 2024).
CropSyst	

Trigo	Validado en Egipto. Valores de NRMSE correspondientes al rendimiento entre 0,03 y 0,192% (Morsy <i>et al.</i> , 2018).
Maíz	Validado en China. Valor de NRMSE correspondiente al rendimiento 3,79% (Umair <i>et al.</i> , 2017).
Papa	Validado en España. Valores de Índice d y R ² correspondientes al rendimiento 0,95 y 0,89, respectivamente (Montoya <i>et al.</i> , 2018).
Raps	Validado en Irán. Valores de R ² e índice d correspondientes al rendimiento 0,96 y 0,85, respectivamente (Honar <i>et al.</i> , 2011).
APSIM	
Trigo	Validado en Marruecos. Valores de R ² e índice d correspondientes al rendimiento 0,95 y 0,98, respectivamente (Briak y Kebede, 2021).
Avena	Validado en China. Valores de NRMSE e índice d correspondientes al rendimiento entre 10,6 y 22,6% y 0,978 y 0,995, respectivamente (Ma <i>et al.</i> , 2022).
Maíz	Validado en Irán. Valores de NRMSE, R ² e índice d correspondientes al rendimiento 9,86%, 0,94 y 0,7 respectivamente (Jahangirlou <i>et al.</i> , 2023).
Papa	Validado en China. Valores de NRMSE, R ² e índice d correspondientes al rendimiento 11,88%, 0,89 y 0,89 respectivamente (Luo <i>et al.</i> , 2024).
Raps	Validado en California, EE.UU. Valores de R ² correspondientes al rendimiento entre 0,88 y 0,92 (George y Kaffka, 2017).
DSSAT	
Trigo	Validado en Chile. Valores de R ² correspondientes al rendimiento entre 0,72 y 0,81 (Maldonado-Ibarra <i>et al.</i> , 2015).
Maíz	Validado en España. Valores de RRMSE, R ² e índice d correspondientes al rendimiento 9,5%, 0,7 y 0,82 respectivamente (Yakoub <i>et al.</i> , 2017).
Papa	Validado en Maine, EE.UU. Valores de NRMSE, R ² e índice d correspondientes al rendimiento entre 12,3 y 13,3%, 0,985 y 0,986, 0,90 y 0,94 respectivamente (Tooley <i>et al.</i> , 2021).

Raps	Validado en Pakistán. Valores de R^2 e índice d correspondientes al rendimiento entre 0,97 y 0,99, y 0,99, respectivamente (Hamza <i>et al.</i> , 2023).
------	--

Capítulo III. Aplicación de los modelos de simulación en frutales

En Chile, los cinco frutales con mayor superficie plantada son la vid vinífera, el cerezo, el avellano europeo, el nogal y la vid de mesa, los cuales en conjunto representan el 62,87 % de la superficie total destinada a frutales en el país (ODEPA, 2023c).

La vid vinífera se posiciona como la principal especie frutal, con una superficie de 124.436 hectáreas plantadas, lo que corresponde al 23,9% del total nacional (ODEPA, 2023c). Chile ocupa aproximadamente el quinto lugar entre los mayores exportadores de vino a nivel global, destacando por su contribución significativa al mercado internacional mediante un enfoque centrado en la calidad del producto y en la diversidad de variedades cultivadas (Thom y Leal-Paiva, 2023).

El cerezo ocupa el segundo lugar en superficie plantada, con 76.447 hectáreas que representan el 14,68 % del total (ODEPA, 2023c). Chile lidera las exportaciones mundiales de cereza dulce, destinando más del 50 % de su producción al comercio exterior, siendo China su principal mercado de destino (Yuri *et al.*, 2024).

En tercer lugar, se encuentra el avellano europeo, con una superficie de 49.264 hectáreas, equivalente al 9,46% de la superficie frutal del país (ODEPA, 2023c). Chile se ha consolidado como un proveedor relevante para el hemisferio norte, gracias a su capacidad de producir en contra estación (Meriño-Gergichevich *et al.*, 2021). Esta ventaja se sustenta en condiciones edafoclimáticas favorables y una alta calidad de la fruta exportada (Gutiérrez-Gamboa *et al.*, 2025).

El nogal, con 43.990 hectáreas plantadas que representan el 8,45% del total, ocupa el cuarto lugar (ODEPA, 2023c). Chile ha experimentado un crecimiento sostenido en este sector, participando activamente en el mercado internacional con nueces frescas y procesadas. Se han implementado estrategias orientadas a la mejora continua de las técnicas de producción y al cumplimiento de altos estándares

de calidad, lo que ha fortalecido su presencia global (Manterola-Barroso *et al.*, 2024).

Finalmente, la vid de mesa se posiciona en el quinto lugar, con 33.155 hectáreas que corresponden al 6,37 % del total (ODEPA, 2023c). Chile también se encuentra entre los principales exportadores de uvas de mesa a nivel mundial, ubicándose con frecuencia entre los cuatro mayores proveedores globales. Su éxito se debe en gran medida a las condiciones climáticas del país, que permiten una temporada de cultivo extendida y una oferta constante de fruta fresca, especialmente hacia los mercados de América del Norte y Europa (Salinas, 2021).

La Figura 2 muestra que la Región del Maule concentra la mayor superficie cultivada al considerar la sumatoria de los cinco principales frutales del país, seguida por las regiones de O'Higgins y Metropolitana. Por su parte, la Tabla 5 presenta la superficie cultivada y el porcentaje de participación que representa cada uno de estos frutales respecto a la superficie total nacional, permitiendo dimensionar su relevancia dentro del sector frutícola chileno.

Tabla 5. Superficie, rendimiento y participación superficie total de los 5 principales frutales en Chile (ODEPA, 2023c).

Frutal	Superficie (ha)	Participación superficie total (%)
Vid vinífera	124.436	23,9
Cerezo	76.447	14,68
Avellano	49.264	9,46
Nogal	43.990	8,45
Vid de mesa	33.155	6,37

A diferencia de los cultivos anuales, la aplicación de modelos de simulación en frutales caducifolios ha sido escasa y fragmentada, con enfoques mayoritariamente experimentales y localizados. AquaCrop, ampliamente usado en especies herbáceas, ha tenido intentos de adaptación para frutales como la vid, aunque con limitaciones estructurales en la simulación de procesos fenológicos como la brotación y la cobertura de dosel, particularmente en etapas iniciales del ciclo

vegetativo (Er-Raki *et al.*, 2021). Para especies como el avellano, se ha desarrollado un modelo estructural que representa la arquitectura del árbol, aunque sin integración funcional de procesos como la partición de carbono, y con necesidad de observaciones multianuales para mejorar su aplicabilidad (Grisafi *et al.*, 2022). Más recientemente, el modelo HADES ha combinado simulación basada en procesos y aprendizaje automático para estimar el rendimiento de avellanos en Turquía, incorporando datos meteorológicos y oficiales de producción, pero aún limitado por la escasa disponibilidad de datos fenológicos por variedad (Bregaglio *et al.*, 2021). En conjunto, la simulación del rendimiento en frutales sigue siendo una brecha crítica frente a los desafíos productivos y climáticos. En la Tabla 6 se resumen algunos ejemplos relevantes.

Figura 2. Superficie regional de los principales frutales en Chile.

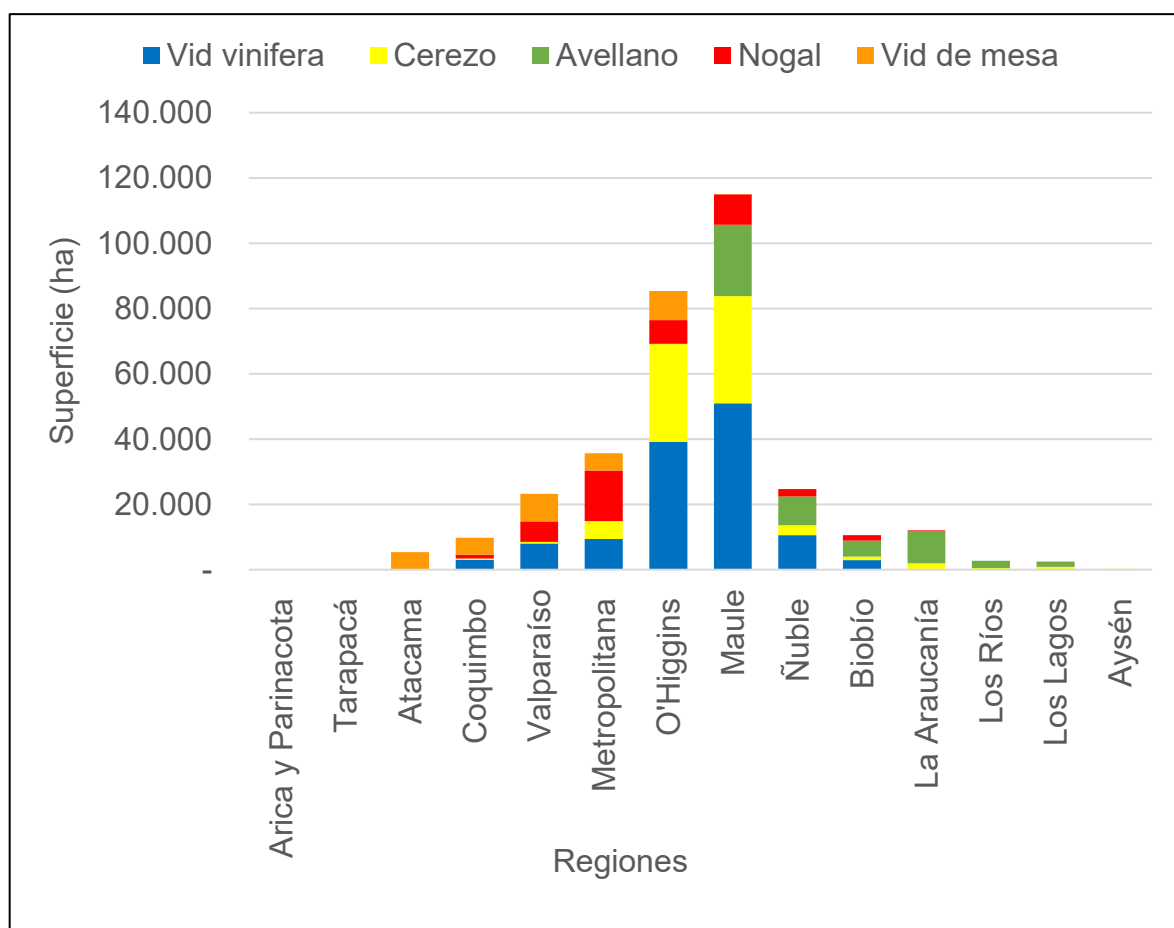


Tabla 6. Comparación de estudios para modelos de simulación en frutales.

Modelo	Descripción del estudio
Vid Vinífera	
CropSyst	Validado en Irán. Valores de NRMSE, R ² e índice d correspondientes al rendimiento entre 5 y 15%, 0,97 y 0,98 y 0,96 y 0,99, respectivamente. (Khozaei <i>et al.</i> , 2020).
Vitisim	Validado en España. Valor de RRMSE correspondiente a la masa seca de la fruta 0,93 (Mirás-Avalos <i>et al.</i> , 2018)
STICS	Validado en Chile y Francia. Valor de NRMSE correspondientes al rendimiento 10,60%. (Valdés-Gómez <i>et al.</i> , 2009).
UNIFI. GrapeML	Validado en Italia. Valores de R ² correspondiente a la biomasa de la fruta 0,47 (Leolini <i>et al.</i> , 2023).
(Yang <i>et al.</i> , 2021).	Calibrado en Portugal. Uso de un método de mínimos cuadrados estándar para calibrar un modelo complejo de vid que simule fenología (floración y fecha de cosecha) y rendimiento. Valores de NRMSE correspondientes al rendimiento entre 11 y 16 %.
Cerezo	
(Cittadini & Balkhoven, 2002).	Validado en países Bajos. Modelo de simulación diseñado para evaluar la producción potencial de cerezo dulce (<i>Prunus avium</i>) en función de diferentes densidades de plantación. Valor de NRMSE correspondientes al rendimiento 21,6%.
Avellano Europeo	
(Bregaglio <i>et al.</i> , 2016)	Validado en Italia. Se presentan dos modelos para simular crecimiento del avellano, diferenciados por su enfoque en la simulación de fotosíntesis: tipo Farquhar y eficiencia radiativa. Valor de rRMSE correspondientes al rendimiento 25,03 y 30,4%.

(Bregaglio <i>et al.</i> , 2020).	Validado en Chile, Georgia y Italia. Modelo mecanístico basado en eficiencia del uso de la radiación (RUE), con módulos para fenología, biomasa, LAI y balance hídrico. Valor de rRMSE correspondientes al rendimiento entre 8,6 y 22,89 %.
HADES.	Validado en Turquía. HAZelnut yield forEcaSt, un sistema de predicción del rendimiento de avellanas que combina técnicas de modelado basado en procesos y aprendizaje automático. Valores de rRMSE y R ² correspondientes al rendimiento entre 16,71 y 23,4 % y 0,5 y 0,75, respectivamente (Bregaglio <i>et al.</i> , 2021).
(Giulietti <i>et al.</i> , 2025).	Validado en Italia. Modelo de visión computacional que detecta y cuenta flores femeninas de avellano mediante YOLOv1x, estimando rendimiento potencial sin simular procesos fisiológicos del cultivo. Valor de R ² correspondiente a simulación de estimación temprana de rendimiento 0,989.
Vid de Mesa	
AquaCrop	Validado en México. Valor de NRMSE correspondiente a la biomasa y rendimiento 8,8 % (Er-Raki <i>et al.</i> , 2021).
STICS	Validado en Pakistán. Valores de rRMSE y R ² correspondientes al rendimiento 10,1 % y 0,94, respectivamente (Rafique <i>et al.</i> , 2024).

En primer lugar, herramientas consolidadas como AquaCrop (Steduto *et al.*, 2009), CropSyst (Stöckle *et al.*, 2003), APSIM (B. Keating *et al.*, 2003) y DSSAT (Jones *et al.*, 2003) han demostrado alta efectividad para simular rendimientos de cultivos anuales bajo distintas condiciones edafoclimáticas y de manejo, integrando variables como el estrés hídrico, la eficiencia de uso del agua y las respuestas fenológicas. Sin embargo, su adaptación a especies frutales sigue siendo incipiente y poco sistematizada.

En el caso de los frutales, especialmente aquellos de hoja caduca como el nogal, el cerezo, el avellano y la vid, la información disponible proviene de estudios

aislados, muchas veces restringidos a condiciones experimentales específicas y sin procesos robustos de validación (Bregaglio et al., 2020; Whitney et al., 2021).

Asimismo, el rendimiento en frutales está condicionado no solo por la acumulación de frío y el inicio de la brotación, sino también por la interacción entre manejo agronómico, variabilidad climática intra e interanual, y características genéticas particulares (Bregaglio et al., 2021). La ausencia de datos fenológicos y productivos de largo plazo, así como la baja sistematización de información local, ha dificultado la calibración de modelos que permitan capturar adecuadamente estos procesos. En consecuencia, casos como el modelo estructural de avellano propuesto por Grisafi et al. (2022) muestran avances relevantes en la representación visual del crecimiento arbóreo, pero también evidencian la necesidad de integrar componentes funcionales y de realizar seguimientos multianuales en árboles de distintas edades para mejorar su aplicabilidad agronómica.

Del mismo modo, el enfoque híbrido del modelo HADES desarrollado por Bregaglio et al. (2021), que combina el modelo basado en procesos con algoritmos de aprendizaje automático, constituye un ejemplo de cómo se puede mejorar la capacidad predictiva en frutales. Este modelo incorpora datos agrometeorológicos y registros estadísticos oficiales, logrando simular incluso la alternancia productiva. No obstante, enfrenta restricciones por falta de información fenológica específica por variedad, escasa representación espacial de los genotipos y baja disponibilidad de datos multianuales.

Por otro lado, se han intentado adaptaciones de modelos originalmente desarrollados para cultivos anuales a especies perennes. Un caso representativo es AquaCrop, ampliamente validado para trigo y maíz (Hsiao et al., 2009), cuya estructura presenta dificultades para simular adecuadamente el comportamiento fenológico de frutales caducifolios. (Er-Raki et al., 2021), reportaron ajustes para aplicar AquaCrop en uva de mesa, reemplazando la fecha de siembra por la de brotación y la emergencia por la brotación completa. Sin embargo, estas modificaciones evidenciaron limitaciones estructurales del modelo, especialmente

en etapas tempranas del ciclo vegetativo, donde el crecimiento lento tras la latencia invernal compromete la precisión de la simulación.

En conjunto, el panorama actual evidencia una profunda brecha entre los modelos desarrollados para cultivos anuales y la escasa disponibilidad de herramientas robustas, calibradas y adaptables para frutales. La fisiología compleja de estas especies, su dependencia de condiciones ambientales variables y la falta de datos impiden la generación de modelos universalmente aplicables. A pesar de ciertos avances prometedores (Bregaglio et al., 2021; Grisafi et al., 2022), se requiere una inversión sustancial en la recopilación sistemática de datos, la validación cruzada de modelos existentes y el desarrollo de herramientas adaptadas a condiciones locales, especialmente en zonas de alta variabilidad como Chile.

Finalmente, superar estas limitaciones permitirá no solo mejorar la eficiencia productiva y la planificación agronómica, sino también anticipar y mitigar los efectos del cambio climático sobre los sistemas agrícolas. Como advierte Whitney et al. (2021), la falta de información y de modelos predictivos adecuados restringe la capacidad de agricultores y tomadores de decisiones para anticiparse a pérdidas de rendimiento en contextos de creciente incertidumbre climática. En este escenario, contar con modelos adaptados al contexto chileno y validados con datos locales constituye un paso clave para avanzar hacia una agricultura más resiliente, eficiente y sostenible.

CONCLUSIONES

El análisis del estado actual de los modelos de simulación agrícola evidencia una disparidad nítida entre la mayor madurez alcanzada en cultivos anuales y su limitada aplicabilidad en especies frutales. En estas últimas persisten restricciones estructurales que dificultan la representación precisa de procesos clave, en particular, la alternancia productiva y las respuestas a eventos extremos de temperatura y a déficits hídricos, lo que incrementa la incertidumbre y reduce la robustez predictiva de las estimaciones. En Chile, además, la escasez de estudios de calibración y validación limita su implementación efectiva en contextos agronómicos locales. Superar estas brechas permitiría anticipar con mayor

precisión los impactos del cambio climático, optimizar el uso del agua y contribuir a una fruticultura más resiliente y eficiente. Asimismo, la simulación de escenarios climáticos, al proyectar los efectos de variaciones en temperatura y precipitación, facilita la adaptación del sector mediante ajustes en rotaciones o selección de cultivos según región y entrega una base técnica sólida para orientar políticas públicas, definir zonas prioritarias y gestionar el recurso hídrico de forma más eficiente a escala territorial.

REFERENCIAS

1. Allen, R., L. Pereira, D. Raes and M. Smith. 2006. Parte C. Evapotranspiración del cultivo en condiciones no estándar ETc bajo condiciones de estrés hídrico. Evapotranspiración del cultivo: Guías para la determinación de los requerimientos de agua de los cultivos. Estudio FAO Riego y Drenaje N° 56, p. 48.
2. Barrett, J. and M. Nearing. 2018. Humanization of decision support using information from simulations. *Agricultural Systems Modeling and Simulation*, 1–17.
3. Bhadouria, R., R. Singh, V. Singh, A. Borthakur, A. Ahamad, G. Kumar and P. Singh. 2019. Agriculture in the era of climate change: Consequences and effects. En: *Climate Change and Agricultural Ecosystems: Current Challenges and Adaptation*, 1–23.
4. Bregaglio, S., K. Fischer, F. Ginaldi, T. Valeriano and L. Giustarini. 2021. The HADES yield prediction system: A case study on the Turkish hazelnut sector. *Frontiers in Plant Science*, 12: 665471.
5. Bregaglio, S., L. Giustarini, E. Suarez, G. Mongiano and T. De Gregorio. 2020. Analysing the behaviour of a hazelnut simulation model across growing environments via sensitivity analysis and automatic calibration. *Agricultural Systems*, 181: 102794.
6. Bregaglio, S., F. Orlando, E. Forni, T. De Gregorio, S. Falzoi, C. Boni, M. Pisetta and R. Confalonieri. 2016. Development and evaluation of new modelling solutions to simulate hazelnut (*Corylus avellana* L.) growth and development. *Ecological Modelling*, 329: 86–99.
7. Briak, H. and F. Kebede. 2021. Wheat (*Triticum aestivum*) adaptability evaluation in a semi-arid region of Central Morocco using APSIM model. *Scientific Reports*, 11(1): 1–20.

8. Cai, C., L. Lv, S. Wei, L. Zhang and W. Cao. 2024. How does climate change affect potential yields of four staple grain crops worldwide by 2030? *PLOS ONE*, 19(5): e0303857.
9. Candelaria, B., O. Ruizo, F. Gallardo López, P. Pérez, M. Becerra and L. Vargas Villamil. 2011. Application of simulation models in agricultural research and planning: A review. *Tropical and Subtropical Agroecosystems*, 14: 999–1010.
10. CGIAR. 2025. CGIAR Platform for Big Data in Agriculture. Crop Modeling Community of Practice [en línea]. <<https://bigdata.cgiar.org/communities-of-practice/crop-modeling/>>. [Consulta: 2 enero, 2025].
11. Chaudhary, P. and K. S. Bawa. 2011. Local perceptions of climate change validated by scientific evidence in the Himalayas. *Biology Letters*, 7(5): 767–770.
12. Chen, D., Y. Kikuchi, K. Fujiyama, S. Akimoto, S. Oominato and T. Hasegawa. 2019. Improving the soil water module of the Decision Support System for Agrotechnology Transfer cropping system model for subsurface irrigation. arXiv preprint, arXiv:1908.10523.
13. Cittadini, E. and J. Balkhoven. 2002. Development of a simulation model for potential production of sweet cherry: its usefulness to analyse planting density. Plant Production Systems Group, Department of Plant Sciences, Wageningen University.
14. Confalonieri, R., D. Gusberty, S. Bocchi and M. Acutis. 2006. The CropSyst model to simulate the N balance of rice for alternative management. *Agronomy for Sustainable Development*, 26(4): 241–249.
15. da Conceição, C., A. D. Robaina, M. Peiter, L. Ben, L. D. Ferreira and A. Parizi. 2022. Performance of the AquaCrop model for corn hybrids under different irrigation strategies. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 26(6): 441–450.
16. De la Casa, A., G. Ovando, L. Bressanini and J. Martínez. 2013. Aquacrop model calibration in potato and its use to estimate yield variability under field conditions. *Atmospheric and Climate Sciences*, 2013(3): 397–407.
17. Diario Frutícola. 2024. Chile es el quinto dentro de los exportadores mundiales de frutas [en línea]. *Diario Frutícola*. <<https://www.diariofruticola.cl/noticia/noticias-fruticolas/2024/03/chile-es-el-quinto-dentro-de-los-exportadores-mundiales-de-frutas>>. [Consulta: 9 junio, 2025].
18. Doorenbos, J. and A. H. Kassam. 1979. Yield response to water. *FAO Irrigation and Drainage Paper N° 33*. FAO, Roma, Italia.

19. Er-Raki, S., E. Bouras, J. Rodriguez, C. Watts, C. Lizarraga-Celaya and A. Chehbouni. 2021. Parameterization of the AquaCrop model for simulating table grapes growth and water productivity in an arid region of Mexico. *Agricultural Water Management*, 245: 106585.
20. FAO. 2011. Base de datos FAOSTAT [en línea]. <<http://faostat.fao.org/>> [Consulta: 14 julio, 2024].
21. FAO. 2021. El estado mundial de la agricultura y la alimentación 2021. FAO, Roma. 240 p.
22. Garreaud, R., C. Álvarez-Garreton, J. Barichivich, J. P. Boisier, D. Christie, M. Galleguillos, C. LeQuesne, J. McPhee and M. Zambrano-Bigiarini. 2017. The 2010–2015 megadrought in central Chile: Impacts on regional hydroclimate and vegetation. *Hydrology and Earth System Sciences*, 21(12): 6307–6327.
23. Gavasso-Rita, Y., S. Papalexiou, Y. Li, A. Elshorbagy, Z. Li and C. Schuster-Wallace. 2024. Crop models and their use in assessing crop production and food security: A review. *Food and Energy Security*, 13(1).
24. George, N. and S. Kaffka. 2017. Canola as a new crop for California: A simulation study. *Agronomy Journal*, 109(2): 496–509.
25. Giulietti, N., S. Tombesi, M. Bedodi, C. Sergenti, M. Carnevale and H. Giberti. 2025. Hazelnut yield estimation: A vision-based approach for automated counting of hazelnut female flowers. *Sensors*, 25(10): 3212.
26. González U., J. 2020. Agricultura de la nueva región de Ñuble: una caracterización sectorial. Colección Libros INIA, N° 39. Instituto de Investigaciones Agropecuarias (INIA), Chillán, Chile. 378 p.
27. Grassini, P., K. Eskridge and K. Cassman. 2013. Distinguishing between yield advances and yield plateaus in historical crop production trends. *Nature Communications*, 4.
28. Grisafi, F., T. Dejong and S. Tombesi. 2022. Fruit tree crop models: An update. *Tree Physiology*, 42(3): 441–457.
29. Gutiérrez-Gamboa, G., M. Araya-Alman, M. Zúñiga-Sánchez, M. González, M. Lisperguer and S. Romero-Bravo. 2025. The impacts of light interception on yield and kernel parameters in hazelnut production. *Horticulturae*, 11(2): 156.
30. Hamza, A., F. Fayyaz-UI-Hassan, M. Ahmed, E. Yaqub, M. Hussain and G. Shabbir. 2023. Modeling photoperiod response of canola under changing climate conditions. En: *Global Agricultural Production: Resilience to Climate Change*, 469–515.

31. Hernández, N., F. Soto and A. Caballero. 2009. Modelos de simulación de cultivos: Características y usos. *Cultivos Tropicales*, 30(1): 00–00.
32. Holzzapfel, E., A. Marino, M. A. Miguel and A. Valenzuela. 1990. Drip irrigation nonlinear optimization model. *Journal of Irrigation and Drainage Engineering*, 116(4): 479–496.
33. Holzworth, D., N. Huth, P. deVoil, E. Zurcher, N. Herrmann, G. McLean, K. Chenu, E. van Oosterom, V. Snow, C. Murphy, A. Moore, H. Brown, J. Whish, S. Verrall, J. Fainges, L. Bell, A. Peake, P. Poulton, Z. Hochman and B. Keating. 2014. APSIM – Evolution towards a new generation of agricultural systems simulation. *Environmental Modelling & Software*, 62: 327–350.
34. Honar, T., A. Sabet, A. Kamgar and Sh. Shams. 2011. Calibration of crop system model for growth simulation and yield estimation of canola. *Water and Soil*, 25(3).
35. Hoogenboom, G., C. Porter, J. Kenneth, V. Vakhtang, P. Wilkens, U. Sinhg, J. White, S. Asseng, J. Lizaso, P. Moreno, W. Pavan, R. Ogoshi, A. Hunt, G. Tsuji and J. Jones. 2019. The DSSAT crop modeling ecosystem. En: *Decision Support Systems for Agrotechnology Transfer*, 173–216.
36. Hsiao, T., L. Heng, P. Steduto, B. Rojas-Lara, D. Raes and E. Fereres. 2009. AquaCrop—The FAO crop model to simulate yield response to water: III. Parameterization and testing for maize. *Agronomy Journal*, 101(3): 448–459.
37. Jahangirlou, M., J. Morel, G. Akbari, I. Alahdadi, S. Soufizadeh and D. Parsons. 2023. Combined use of APSIM and logistic regression models to predict the quality characteristics of maize grain. *European Journal of Agronomy*, 142: 126629.
38. Jamieson, P., J. Porter, J. Goudriaan, J. Ritchie, H. Van Keulen and W. Stol. 1998. A comparison of the models AFRCWHEAT2, CERES-Wheat, Sirius, SUCROS2 and SWHEAT with measurements from wheat grown under drought. *Field Crops Research*, 55(1–2): 23–44.
39. Jones, J., G. Hoogenboom, C. Porter, K. Boote, W. Batchelor, L. Hunt, P. Wilkens, U. Singh, A. Gijssman and J. Ritchie. 2003. The DSSAT cropping system model. *European Journal of Agronomy*, 18(3–4): 235–265.
40. Kalra, N., S. Chander, H. Pathak, P. Aggarwal, N. Gupta, M. Sehgal and D. Chakraborty. 2007. Impacts of climate change on agriculture. *Outlook on Agriculture*, 36(2): 109–118.
41. Keating, B. A. 2024. APSIM's origins and the forces shaping its first 30 years of evolution: A review and reflections. *Agronomy for Sustainable Development*, 44(3): 1–15.

42. Keating, B., P. Carberry, G. Hammer, M. Probert, M. Robertson, D. Holzworth, N. Huth, J. Hargreaves, H. Meinke, Z. Hochman, G. McLean, K. Verburg, V. Snow, J. Dimes, M. Silburn, E. Wang, S. Brown, K. Bristow, S. Asseng and C. Smith. 2003. An overview of APSIM, a model designed for farming systems simulation. *European Journal of Agronomy*, 18(3–4): 267–288.
43. Khorsand, A., H. Dehghanisani, A. Heris, H. Asgarzadeh and V. Rezaverdinejad. 2024. Calibration and evaluation of the FAO AquaCrop model for canola (*Brassica napus*) under full and deficit irrigation in a semi-arid region. *Applied Water Science*, 14(3): 1–18.
44. Khozaei, M., A. A. Kamgar-Haghighi, A. Sepaskhah, S. Zand-Parsa, F. Razzaghi and M. Karami. 2020. Supplemental irrigation management of rainfed grapevines under drought conditions using the CropSyst model. *Spanish Journal of Agricultural Research*, 18(2): e1203.
45. Leolini, L., S. Bregaglio, F. Ginaldi, S. Costafreda-Aumedes, S. Di Gennaro, A. Matese, F. Maselli, G. Caruso, G. Palai, S. Bajocco, M. Bindi and M. Moriondo. 2023. Use of remote sensing-derived fPAR data in a grapevine simulation model for estimating vine biomass accumulation and yield variability at sub-field level. *Precision Agriculture*, 24(2): 705–726.
46. Liu, H., J. Yang, C. Drury, W. Reynolds, C. Tan, Y. Bai, P. He, J. Jin and G. Hoogenboom. 2011. Using the DSSAT-CERES-Maize model to simulate crop yield and nitrogen cycling in fields under long-term continuous maize production. *Nutrient Cycling in Agroecosystems*, 89(3): 313–328.
47. Luo, X., Y. Sun, L. Liu, L. Wang and X. Gao. 2024. Response of potato growth and yield to drought scenarios based on APSIM-Potato in the single-cropping region in Northern China. *Potato Research*, 67(4): 1775–1796.
48. Ma, Q., X. Zhang, Y. Wu, H. Yang and Z. Wang. 2022. Optimizing water and nitrogen strategies to improve forage oat yield and quality on the Tibetan Plateau using APSIM. *Agronomy*, 12(4): 933.
49. Maldonado-Ibarra, I., G. R. Rodríguez and D. Castillo-Rosales. 2015. Determination of genetic coefficients of three spring wheat varieties under a Mediterranean environment applying the DSSAT model. *Chilean Journal of Agricultural Research*, 75(4): 418–424.
50. Malek, K., J. Adam, C. Stöckle and R. Peters. 2018. Climate change reduces water availability for agriculture by decreasing non-evaporative irrigation losses. *Journal of Hydrology*, 561: 444–460.
51. Manterola-Barroso, C., D. Padilla Contreras, G. Ondrasek, J. Horvatinec, G. Gavilán CuiCui and C. Meriño-Gergichevich. 2024. Hazelnut and walnut nutshell features as emerging added-value byproducts of the nut industry: A review. *Plants*, 13(7): 1034.

52. Mazhoud, H., F. Chemak, H. Belhouchette and R. Chenoune. 2022. A bio-economic model for improving irrigated durum wheat performance and regional profits under Mediterranean conditions. *Agriculture*, 12(5).
53. McCown, R., G. Hammer, J. Hargreaves, D. Holzworth and D. Freebairn. 1996. APSIM: A novel software system for model development, model testing and simulation in agricultural systems research. *Agricultural Systems*, 50(3): 255–271.
54. Mekonnen, M. and W. Gerbens-Leenes. 2020. The water footprint of global food production. *Water*, Switzerland, 12(10).
55. Meriño-Gergichevich, C., A. Luengo-Escobar, D. Alarcón, M. Reyes-Díaz, G. Ondrasek, F. Morina and K. Ogass. 2021. Combined spraying of boron and zinc during fruit set and premature stage improves yield and fruit quality of European hazelnut cv. Tonda di Giffoni. *Frontiers in Plant Science*, 12: 661542.
56. Ministerio de Desarrollo Social y Familia. 2023. Actualización del valor de la línea de pobreza y línea de pobreza extrema: Diciembre 2023 [en línea]. Gobierno de Chile. <<https://observatorio.ministeriodesarrollosocial.gob.cl/nueva-serie-cba-2024>> [Consulta: 25 enero, 2025].
57. Mirás-Avalos, J., D. Uriarte, A. Lakso and D. Intrigliolo. 2018. Modeling grapevine performance with 'VitiSim', a weather-based carbon balance model: Water status and climate change scenarios. *Scientia Horticulturae*, 240: 561–571.
58. Mishra, V., J. F. Cruise, J. Mecikalski, C. Hain and M. Anderson. 2013. A remote-sensing driven tool for estimating crop stress and yields. *Remote Sensing*, 5(7): 3331–3356.
59. Montoya, F., D. Camargo, A. Domínguez, J. Ortega and J. Córcoles. 2018. Parametrization of CropSyst model for the simulation of a potato crop in a Mediterranean environment. *Agricultural Water Management*, 203: 297–310.
60. Morsy, M., G. El Afandi and E. Naif. 2018. CropSyst simulation and response of some wheat cultivars to late season drought. *Italian Journal of Agrometeorology*, 2018(1): 15–24.
61. Msongaleli, B., F. Rwehumbiza, S. Tumbo and N. Kihupi. 2014. Sorghum yield response to changing climatic conditions in semi-arid Central Tanzania: Evaluating crop simulation model applicability. *Agricultural Sciences*, 5(10): 822–833.
62. ODEPA. 2023a. Estudio: Agricultura de contratos para el trigo harinero en Chile [en línea]. Oficina de Estudios y Políticas Agrarias. <<https://www.odepa.gob.cl/publicaciones/consultorias-y-asesorias/estudio->

- agricultura-de-contratos-para-el-trigo-harinero-en-chile>. [Consulta: 25 enero, 2025].
63. ODEPA. 2023b. Mercado del raps: Temporada 2022/23 [en línea]. Oficina de Estudios y Políticas Agrarias. <<https://www.odepa.gob.cl/publicaciones/articulos/mercado-del-raps-temporada-2022-23>>. [Consulta: 25 enero, 2025].
 64. ODEPA. 2023c. Estadísticas productivas [en línea]. Oficina de Estudios y Políticas Agrarias. <<https://www.odepa.gob.cl/estadisticas-del-sector/estadisticas-productivas>>. [Consulta: 25 enero, 2025].
 65. OMS, PMA, & UNICEF. 2017. El estado de la seguridad alimentaria y la nutrición en el mundo. FAO, 52.
 66. Orozco-Romero, J. and O. Pérez-Zamora. 2004. Tensión de humedad del suelo y fertilización nitrogenada en plátano (*Musa AAA Simmonds*) cv. Gran Enano. *Agrociencia*, 40: 149–162.
 67. Oteng-Darko, P., S. Yeboah, S. Addy, S. Amponsah and E. Danquah. 2013. Crop modeling: A tool for agricultural research. A review. *E3 Journal of Agricultural Research and Development*, 2(1): 1–6.
 68. Peña, A. 2013. Validación del modelo AquaCrop en cinco genotipos de trigo (*Triticum aestivum L.*) cultivados en condiciones de disponibilidad de agua contrastantes. Memoria de título. Universidad de Concepción, Facultad de Agronomía, Chillán, Chile.
 69. Pérez-Maqueo, O., C. A. Delfín-Alfonso, A. Fregoso, H. C. Avalos and M. E. Zamora. 2006. Modelos de simulación para la elaboración y evaluación de los programas de servicios ambientales hídricos. *Gaceta Ecológica*, (78): 47–66.
 70. Pokhrel, P., N. Rajan, J. Jifon, W. Rooney, R. Jessup, J. da Silva, J. Enciso and A. Attia. 2022. Evaluation of the DSSAT-CANEGRO model for simulating the growth of energy cane (*Saccharum spp.*), a biofuel feedstock crop. *Crop Science*, 62(1): 466–478.
 71. Raes, D., P. Steduto, T. C. Hsiao and E. Fereres. 2015. AquaCrop Reference Manual. FAO, Roma. 157 p.
 72. Rafique, R., T. Ahmad, M. Ahmed and M. Khan. 2024. Adapting the process-based STICS model to simulate phenology and yield of table grapes – a high-value fruit crop in a new emerging viticulture zone of South Asia. *Scientia Horticulturae*, 336: 113419.

73. Raza, A., A. Moghaddam, G. Gollner and J. Friedel. 2014. Evaluation of CropSyst for studying the effect of mulching with lucerne (*Medicago sativa* L.) in Austria. *Journal of Plant Interactions*, 9(1): 592–598.
74. Roco, L., A. Engler, B. Bravo-Ureta and R. Jara-Rojas. 2015. Farmers' perception of climate change in Mediterranean Chile. *Regional Environmental Change*, 15(5): 867–879.
75. Salinas, G. 2021. Chile: A role model of export diversification policies? *IMF Working Papers*, 2021(148): 1. Fondo Monetario Internacional. Disponible en: <https://doi.org/10.5089/9781513573373.001>.
76. Steduto, P., T. Hsiao, D. Raes and E. Fereres. 2009. AquaCrop – The FAO crop model to simulate yield response to water: I. Concepts and underlying principles. *Agronomy Journal*, 101(3): 426–437.
77. Steduto, P., T. Hsiao, E. Fereres and D. Raes. 2012. Respuesta del rendimiento de los cultivos al agua. Land and Water Division. FAO, Roma. 212 p.
78. Stehr, A., S. Vicuña, X. Vargas, T. Gómez, J. Cepeda, P. Mendoza, N. Vásquez, V. Delgado, J. Arumí, C. Vásquez, C. Álvarez, P. Álvarez, C. Berroeta, Y. Castillo, G. Chiang, S. Crespo, G. Donoso, A. Dussillant, F. Ferrando, ... R. Ponce. 2019. Recursos hídricos en Chile: impactos y adaptación al cambio climático. Ministerio de Ciencia, Tecnología, Conocimiento e Innovación, Santiago, Chile. 16 p.
79. Stöckle, C., M. Donatelli, and R. Nelson. 2003. CropSyst, a cropping systems simulation model. *European Journal of Agronomy*, 18(3–4), 289–307.
80. Thom, K. and V. Leal-Paiva. 2023. Wine international market structure and competitiveness. Department of Agribusiness, University of Brasilia.
81. Tooley, B., E. Mallory, G. Porter, and G. Hoogenboom. 2021. Predicting the response of a potato-grain production system to climate change for a humid continental climate using DSSAT. *Agricultural and Forest Meteorology*, 307, 108452.
82. Uehara, G. and G. Tsuji. 1998. Overview of IBSNAT. 1–7.
83. Umair, M., Y. Shen, Y. Qi, Y. Zhang, A. Ahmad, H. Pei, and M. Liu. 2017. Evaluation of the CropSyst model during wheat-maize rotations on the North China plain for identifying soil evaporation losses. *Frontiers in Plant Science*, 8, 272136.
84. United Nations. 2024. World population prospects 2024: Data sources. Department of Economic and Social Affairs, Population Division.

85. Valdés-Gómez, H., F. Celette, I. García de Cortázar-Atauri, F. Jara-Rojas, S. Ortega-Farías, and C. Gary. 2009. Modelling soil water content and grapevine growth and development with the stics crop-soil model under two different water management strategies. *OENO One*, 43(1), 13–28.
86. Valenzuela, M. 2019. Estudio de las metodologías para el análisis comercial de la avena para consumo humano. Ministerio de Agricultura. Oficina de Estudios y Políticas Agrarias.
87. Whitney, C., E. Fernandez, K. Schiffers, I. Cuneo, and E. Luedeling. 2021. Forecasting yield in temperate fruit trees from winter chill accumulation. *Acta Horticulturae*, 1327, 397–404.
88. Yakoub, A., J. Lloveras, A. Biau, J. Lindquist, and J. Lizaso. 2017. Testing and improving the maize models in DSSAT: Development, growth, yield, and N uptake. *Field Crops Research*, 212, 95–106.
89. Yang, C., C. Menz, H. Fraga, S. Reis, N. Machado, A. Malheiro, and J. Santos. 2021. Simultaneous calibration of grapevine phenology and yield with a soil–plant–atmosphere system model using the frequentist method. *Agronomy*, 11(8), 1659.