



CALIBRACIÓN DE MODELOS PREDICTIVOS PARA FLORACIÓN DE CEREZO (*Prunus avium* L.) EN CHIHUAHUA, MÉXICO

CALIBRATION OF PREDICTIVE MODELS FOR CHERRY (*Prunus avium* L.) BLOSSOM IN CHIHUAHUA, MEXICO

Natalia Aidé Chávez-Gutiérrez¹, Guillermo Calderón-Zavala¹, Ángel Rafael Parra-Quezada² y José Alfredo Carrillo-Salazar^{1*}

¹Colegio de Postgraduados, Campus Montecillo, Programa de Recursos Genéticos y Productividad-Fisiología Vegetal, Montecillo, Texcoco, Estado de México. ²Universidad Autónoma de Chihuahua, Facultad de Ciencias Agrotecnológicas, Campus 1, Santo Niño, Chihuahua, México.

*Autor de correspondencia (asalazar@colpos.mx)

RESUMEN

La demanda de cereza dulce (*Prunus avium* L.) y su elevado valor comercial en mercados fuera de temporada requieren de predecir con precisión la floración, lo que podría ser con el uso de modelos fenológicos, aunque sus capacidades predictivas dependen de una calibración local. El objetivo de este estudio fue calibrar y evaluar los modelos fenológicos de tiempo térmico Horas frío, Utah, y Dinámico para predecir la fecha de floración en cerezo dulce en Carichí y Cuauhtémoc, Chihuahua, México. La calibración de los parámetros se hizo con algoritmos genéticos de las librerías PyGAD y Pymoo. La función objetivo por modelo fue minimizar el error cuadrático entre la fecha observada y la fecha simulada de floración. En la calibración, se emplearon 15 registros históricos de floración de los cultivares Rainier, Skeena y Santina obtenidos localmente y de experimentos publicados. La evaluación fue con registros de floración de 2025. Los datos de temperatura se obtuvieron de la plataforma NASA Power y de estaciones meteorológicas de UNIFRUT. El modelo Utah, calibrado con Pymoo, presentó el mejor desempeño con un error absoluto medio (MAE) de 12 d en la calibración y de 6 d en la evaluación, frente a valores de 37 d y 17 d, respectivamente, en el modelo sin calibrar. El Modelo Dinámico obtuvo un MAE de 8.3 d en la calibración, aunque este aumentó a 31.7 d en la evaluación. Con el modelo Utah calibrado se obtuvo un error de 0 d en la evaluación en el cultivar Rainier y de 15 d en Santina. Los resultados demuestran que la calibración mediante algoritmos genéticos con un enfoque local y cultivar-específico mejora la estimación de la floración de cerezo en regiones con inviernos marginales.

Palabras clave: Algoritmos genéticos, calibración, procesos, requerimiento térmico, temperatura.

SUMMARY

The demand for sweet cherry (*Prunus avium* L.) and its high commercial value in off-season markets require accurate prediction of flowering, which could be achieved using phenological models, although their predictive performance depends on local calibration. The objective of this study was to calibrate and evaluate the Chill Hours, Utah and Dynamic thermal-time phenological models to predict flowering date in sweet cherry in Carichí and Cuauhtémoc, Chihuahua, Mexico. The calibration of parameters was performed with genetic algorithms from the PyGAD and Pymoo libraries. The objective function for each model was to minimize the squared error between the observed and simulated flowering dates. For calibration, 15 historical flowering records of cultivars Rainier, Skeena and Santina were used, obtained

locally and from published experiments. Evaluation was conducted with flowering records from 2025. Temperature data were obtained from the NASA Power platform and from UNIFRUT weather stations. The Utah model, calibrated with Pymoo, showed the best performance, with a mean absolute error (MAE) of 12 d in calibration and 6 d in evaluation, compared to values of 37 and 17 d, respectively, in the uncalibrated model. The Dynamic Model achieved a MAE of 8.3 d in calibration, although this increased to 31.7 days in evaluation. With the calibrated Utah Model, an error of 0 d was obtained in the evaluation in cultivar Rainier and 15 d in Santina. Results demonstrated that calibration using genetic algorithms with a local, cultivar-specific approach improves the estimation of sweet cherry flowering in regions with marginal winter conditions.

Index words: Calibration, genetic algorithms, processes, temperature, thermal-time models.

INTRODUCCIÓN

La demanda global de cereza dulce (*Prunus avium* L.) ha crecido, impulsada por el valor comercial de la producción fuera de temporada. En 2024, las importaciones de cereza fresca alcanzaron 32.2 millones de dólares estadounidenses, con destino principal a la Ciudad de México y Jalisco, cuyo origen predominante fue Estados Unidos y Chile (SE, 2012).

Predecir la fecha de floración en cerezo es fundamental para evaluar la adaptación de los cultivares y planificar la producción con fines de comercialización. Este evento fenológico resulta de la interacción entre factores bióticos (genotipo y estado fisiológico), y abióticos (temperatura y fotoperiodo), cuya modelación cobra especial relevancia ante el cambio climático, la variabilidad interanual y las condiciones específicas del sitio de cultivo (Hájková *et al.*, 2023; Richardson *et al.*, 2013). En especies caducifolias de clima templado, como el cerezo, la temperatura es el principal regulador de los eventos fenológicos (Wang *et al.*, 2024). No obstante, la respuesta fenológica varía

entre cultivares y está modulada por la interacción entre la acumulación de frío invernal, necesaria para romper la latencia y la exposición a temperaturas cálidas en primavera, que promueven la reanudación del crecimiento (Castède *et al.*, 2014; Tang *et al.*, 2025).

El análisis de series fenológicas extensas permite caracterizar la respuesta de los cultivares a distintos regímenes climáticos y desarrollar modelos predictivos de floración (Semiromi *et al.*, 2024); sin embargo, en cerezo, la disponibilidad de estas series en el estado de Chihuahua, México sigue siendo insuficiente para entrenar modelos fenológicos avanzados basados en algoritmos de aprendizaje automático (Zheng *et al.*, 2022). Ante esta situación, la alternativa es usar modelos fenológicos basados en tiempo térmico, que consideran la acumulación de frío (chilling) y calor (forcing) para predecir la floración en especies caducifolias (Darbyshire *et al.*, 2020). Entre los modelos más utilizados se encuentran el de Horas frío (Weinberger, 1950), Utah (Richardson *et al.*, 1974) y Dinámico (Anderson *et al.*, 1986; Erez *et al.*, 1990); no obstante, su aplicabilidad en las condiciones climáticas de Chihuahua, México aún no ha sido evaluada.

La calibración de estos modelos consiste en ajustar parámetros con base en observaciones fenológicas locales; para ello, existe una amplia diversidad de métodos de optimización, incluyendo metaheurísticos globales como algoritmos genéticos, evolución diferencial, enjambre de partículas, recocido simulación del temple (Venter, 2010).

En modelos de cultivos, las funciones objetivo suelen ser no lineales, no convexas y multimodales, por lo que estos enfoques resultan particularmente adecuados (Trejo *et al.*, 2014). En el presente estudio se eligieron algoritmos genéticos por su capacidad para operar parámetros continuos y discretos, su exploración global del espacio de soluciones (óptimos) y su menor dependencia de supuestos analíticos; además, sus operadores (selección, recombinación y mutación) favorecen la diversidad poblacional y reducen la convergencia prematura hacia óptimos locales (Sivanandam y Deepa, 2008; Venter, 2010). Este enfoque se ha aplicado recientemente para optimizar parámetros fenológicos en olivo y vid (Didevarasl *et al.*, 2023; Grillakis *et al.*, 2022).

La disponibilidad de modelos fenológicos calibrados y precisos es fundamental para reducir la incertidumbre en la toma de decisiones. En el contexto del cultivo de cerezo en Chihuahua, donde los productores enfrentan limitaciones técnicas para predecir etapas fenológicas clave, se planteó el objetivo de calibrar parámetros de modelos fenológicos basados en tiempo térmico mediante algoritmos genéticos, para predecir con precisión la fecha de plena floración

en cultivares de cerezo dulce establecidos en Carichí y Cuauhtémoc, Chihuahua, México.

MATERIALES Y MÉTODOS

Recopilación de datos meteorológicos y fenológicos

Los datos diarios de temperatura se obtuvieron de dos fuentes: estaciones meteorológicas de UNIFRUT y registros satelitales validados del Proyecto Power de la NASA (<https://power.larc.nasa.gov/>) (Cuadro 1).

Estos registros de temperatura se obtuvieron de las coordenadas más próximas a los sitios experimentales. Los datos fueron depurados y los valores faltantes fueron completados mediante interpolación lineal.

Los datos de plena floración de cerezo, definida como el momento en que al menos el 50 % de las flores están abiertas, se obtuvieron de huertas experimentales de cerezo en dos localidades de clima seco extremo en Chihuahua, México (García, 2004): Campo Menonita 15½, Cuauhtémoc (28° 36' 59.79" N, 106° 52' 05.84" O, altitud de 1980 m) en los cultivares Rainier y Skeena; y Carichí (28° 00' 52.64" N, 107° 01' 49.31" O, altitud de 2205 m) en el cultivar Santina. También, se obtuvieron las fechas de plena floración de estos cultivares de diversas fuentes de información (Cuadro 2).

Descripción de los modelos fenológicos

El modelo de Utah (Richardson *et al.*, 1974) asigna unidades de frío ponderadas en función de distintos umbrales de temperatura (Ec. 1 y Ec. 2). Define una unidad de frío como una hora de exposición a un intervalo de temperaturas considerado óptimo para la acumulación de frío. Las temperaturas fuera de este intervalo, ya sea por encima o por debajo, contribuyen en menor medida, y aquellas superiores de 15 °C tienen un efecto negativo; es decir, reducen la acumulación de unidades de frío. Con temperaturas inferiores de 1.4 °C, la acumulación de unidades frío es nula.

$$UF = \sum_{h=1}^N f(T_h) \tag{Ec. 1}$$

Donde T_h es la temperatura horaria (°C), $f(T_h)$ es la función de contribución de frío y N es el número total de horas evaluadas. La asignación de unidades frío acumuladas fue en función de la T_h en intervalos de temperatura ajustados para garantizar cobertura continua.

$$f(T_h) = 0.0 \mathbb{1}_{(-\infty, 1.4)} + 0.5 \mathbb{1}_{(1.4, 2.4)} + 1.0 \mathbb{1}_{(2.4, 9.1)} + 0.5 \mathbb{1}_{(9.1, 12.4)} + 0.0 \mathbb{1}_{(12.4, 15.9)} - 0.5 \mathbb{1}_{(15.9, 18.0)} - 1.0 \mathbb{1}_{(18.0, \infty)} \tag{Ec. 2}$$

Donde T_A es la función indicadora del intervalo A. Los parámetros se enlistan en el Cuadro 3.

El modelo dinámico (Erez *et al.*, 1990) describe la acumulación de frío como un proceso dependiente de la temperatura y parcialmente reversible; primero, un precursor se forma y se destruye según la cinética de Arrhenius, donde la destrucción es más sensible al aumento térmico y puede revertir la acumulación; después, cuando el precursor alcanza un umbral, se activa una etapa irreversible que lo convierte en unidades de ruptura del

letargo. El código del modelo se encuentra disponible en: https://rdr.io/cran/ChillModels/src/R/dynamic_model.R, y la lista de parámetros calibrados en el Cuadro 3.

El modelo de Horas frío (Weinberger, 1950) contabiliza una hora frío por cada hora en que la temperatura horaria del aire (T_h) se mantiene entre 0 (T_{minh}) y 7 °C (T_{maxh}) (Ec. 3). Fuera de este intervalo, no se acumulan unidades de frío.

$$HF_{acum}(N) = \sum_{h=1}^N 1(0 \leq T_h \leq 7) \quad \text{Ec. 3}$$

Cuadro 1. Ubicación y procedencia de los datos de temperatura diaria máxima promedio (T_{máx}, °C) y temperatura mínima promedio (T_{mín}, °C).

Sitio	Años	Coordenadas geográficas	T _{máx}	T _{mín}	Cultivar	Fuente
Buena Vista, Carichí, Chihuahua, México	2020-2021, 2021-2022, 2022-2023, 2023-2024	28° 03' 54.67" N 106° 57' 11.82" O	32.1	-13.5	Rainier, Skeena	UNIFRUT
Michigan, USA	2006-2007	42° 52' 15.36" N 85° 15' 33.86" O	24.8	-18.0	Rainier, Skeena	NASA
Pontificia Universidad Católica de Chile	2020	33° 40' S 70° 36' O	35.5	-6.5	Rainier, Santina	NASA
Maule, Chile	2019, 2020	35° 01' S, 71° 26' O	38.7	-0.6	Santina	NASA
Campo Menonita 15½, Cuauhtémoc, Chihuahua, México.	2023-2024	28° 36' 59.79" N 106° 52' 05.84" O			Santina	NASA

Cuadro 2. Fechas de plena floración de cerezo (50 % de flores abiertas).

Cultivar	Fecha	Fuente
Rainier	18/marzo/2021, 28/marzo/2022, 21/marzo/2023, 04/marzo/2024, 07/abril/2025	Productores del sitio experimental.
	22/abril/2007	Demirsoy <i>et al.</i> (2022)
	25/septiembre/2020	Bastías (Com. Pers.) ¹
Skeena	18/marzo/2021, 28/marzo/2022, 21/marzo/2023, 04/marzo/2024, 07/abril/2025	Propios investigadores
	23/abril/2007	Demirsoy <i>et al.</i> (2022)
Santina	30/octubre/2020	Palma <i>et al.</i> (2023)
	01/octubre/2019	Palma <i>et al.</i> (2023)
	15/marzo/2024, 11/abril/2025 30/septiembre/2020	Propios investigadores Bastías (Com. Pers.) ¹

¹Bastías I. A. (2020) Caracterización fenológica, reproductiva y de calidad de fruta de distintas variedades de cerezo (*Prunus avium* L.) en la zona central de Chile. Tesis de Maestría. Pontificia Universidad Católica de Chile. Santiago, Chile. 104 p, <https://doi.org/10.7764/tesisuc/agr/48228>

Cuadro 3. Intervalos de calibración de parámetros de modelos de acumulación de frío mediante algoritmos genéticos.

Modelo	Descripción de los parámetros	Valor inicial del parámetro	Rango de optimización	
			Mínimo	Máximo
Utah	Temperaturas límite de los rangos de acumulación de frío	1.4	0	2
		2.4	0	3
		9.1	6	11
		12.4	10	15
		15.9	10	20
		18	10	20
	Asignación de unidades frío por intervalo térmico	0	0	0.5
		0.5	0	1
		1	0	2
		0.5	0	1
		0	-1	0
		-0.5	-1	0
		-1	-2	1
Horas frío	Requerimiento de unidades frío (Rainier)	950	600	1800
	Requerimiento de unidades frío (Skeena)	1050 [†]	600	1800
	Requerimiento de unidades frío (Santina)	1150	600	1800
	Temperatura mínima de acumulación de frío (T_{minh} , °C)	0	-3.5	3.5
	Temperatura máxima de acumulación de frío (T_{maxh} , °C)	7	3.5	10.5
	Requerimiento de horas frío (Rainier)	1067	600	1800
	Requerimiento de horas frío (Skeena)	1556	600	1800
Dinámico	Requerimiento de horas frío (Santina)	917	600	1800
	Energía de activación para la formación del precursor (e_0)	4153.5	2500	5000
	Energía de activación para la degradación del precursor (e_1)	12888.8	10000	14000
	Velocidad de formación del precursor (a_0)	1395000	1200000	1500000
	Velocidad de degradación del precursor (a_1)	2.57×10^{18}	1.00×10^{18}	3.00×10^{18}
	Pendiente de la curva (slp)	1.6	0.5	4
	Temperatura óptima (Θ_m , K)	277	100	400
	Requerimiento de unidades frío (Rainier)	57	30	100
	Requerimiento de unidades frío (Skeena)	59 [†]	30	100
Requerimiento de unidades frío (Santina)	61	30	100	

[†]Se registró el promedio de requerimiento de los otros cultivares reportados por la literatura (Fadón *et al.*, 2018; 2021).

Donde 1(•) vale 1 si la condición se cumple y 0 si no.

Calibración

La calibración de los parámetros de los modelos de acumulación de frío (Cuadro 3) se realizó mediante algoritmos genéticos (AG). Los AG son métodos heurísticos adaptativos, basados en poblaciones e inspirados en la evolución natural, que exploran iterativamente un espacio de búsqueda mediante operadores de selección, cruzamiento y mutación, con el objetivo de encontrar soluciones eficientes a problemas de optimización no lineales y multimodales (Katoch *et al.*, 2021). La implementación se realizó en Python (v3.10.12), utilizando las librerías PyGAD (v3.4.0) y Pymoo (v0.6.1.3), dentro de un entorno Jupyter Notebook (v7.5.0), ejecutado en una estación de trabajo Apple M2 Ultra con 128 GB de memoria RAM. PyGAD permite implementar algoritmos genéticos de forma sencilla mediante la definición directa de una función de aptitud, mientras que Pymoo proporciona un marco más general y extensible, basado en la formulación explícita del problema de optimización y el uso de algoritmos evolutivos especializados.

La acumulación de frío inició el 1 de octubre para los sitios ubicados en el hemisferio norte y el 26 de abril para los del hemisferio sur. Para la calibración se emplearon 15 fechas observadas de floración, correspondientes a los tres cultivares (Rainier, Skeena y Santina) y a distintos sitios experimentales y años (Cuadro 2).

Para cada combinación cultivar-sitio, se identificó el hemisferio correspondiente con el fin de definir la fecha de inicio de la acumulación de frío. Con los datos de temperatura máxima y mínima diarias, se calcularon las temperaturas horarias mediante un modelo sinusoidal utilizado en estudios agroclimáticos (Catalán *et al.*, 2005; Plaza, 2011). Con estas temperaturas horarias, se calcularon las unidades frío según el modelo de acumulación evaluado. La acumulación de frío se detuvo cuando el modelo alcanzó el requerimiento específico de frío para cada cultivar, momento en el cual se registró el día del año (DOY) estimado de floración. Este valor fue comparado con la fecha observada para evaluar el error del modelo.

La calibración de parámetros se planteó como un problema de minimización del error entre las fechas de floración observadas y las simuladas por el modelo. La función objetivo $J(\theta)$, usada en ambas librerías, se definió como (Ec. 4):

$$J(\theta) = \sum_{i=1}^G \sum_{j=1}^S (y_{ij}^{obs} - \hat{y}_{ij}(\theta))^2 \rightarrow \min_{\theta} \# \quad \text{Ec. 4}$$

Donde y_{ij}^{obs} es el valor observado del día del año de floración para el cultivar i en el sitio j ; $\hat{y}_{ij}(\theta)$ es el valor estimado por el modelo, dependiente de θ , para el cultivar i en el sitio j ; $\theta = (\theta_1, \theta_2, \dots, \theta_p)$ es el vector de parámetros a calibrar, G es el cultivar y S es el sitio, combinado con el año evaluado.

Los parámetros de cada modelo se optimizaron dentro de un espacio de búsqueda definido por los límites inferiores (θ_k^{min}) y superiores (θ_k^{max}) (Cuadro 3). Se realizaron más de 30 ejecuciones independientes de optimización, con el fin de evaluar la estabilidad de la solución, el número de parámetros calibrados por el modelo y el desempeño comparativo de las librerías utilizadas.

El proceso de optimización se ejecutó de manera iterativa a lo largo del número de generaciones definido para cada algoritmo genético, evaluando la función objetivo por individuo, y en cada generación, hasta alcanzar el criterio de término del proceso.

Los hiperparámetros utilizados en los algoritmos genéticos fueron los siguientes:

Con PyGAD se usó una población de 100 individuos, durante 70 generaciones, con 70 % de cruzamiento y mutación de 10 %; en cada generación se seleccionaron 20 padres mediante torneo binario, priorizando el menor error. Con Pymoo se empleó una población inicial de 150 individuos y 85 generaciones, con cruzamiento SBX del 80 % y mutación del 15 % en un problema mono-objetivo ($n_{obj}=1$); en cada generación, se eliminaron duplicados y la selección de padres fue mediante torneo binario.

Evaluación

En este estudio, el término evaluación se utiliza en un sentido operativo para referirse a la prueba del desempeño del modelo utilizando conjuntos de datos independientes a los empleados en la calibración, manteniendo fijos los parámetros estimados. Los modelos se evaluaron con datos de plena floración registrados en abril de 2025 en ambos sitios experimentales: el 07 de abril para Rainier y Skeena, con los datos meteorológicos de Buena Vista, Carichí, Chihuahua; y el 11 de abril para Santina con datos del Campo Menonita 15½, Cuauhtémoc, Chihuahua.

Métricas evaluadas

La precisión de los modelos en el cálculo del día del año de la floración, tanto en la calibración como en la evaluación, se evaluó mediante el coeficiente de determinación (R^2) utilizado como una medida de la proporción de la variabilidad observada que es explicada por el modelo, el

error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE).

RESULTADOS Y DISCUSIÓN

Para cada modelo se reportó únicamente el escenario con la mayor capacidad predictiva (Cuadro 4). Conviene interpretar con cautela el coeficiente de determinación (R^2) en la fase de evaluación, debido al número limitado de observaciones; por esto, en el cuadro se reporta como no disponible (ND) cuando su estimación resulta fuera de intervalo. La calibración mediante algoritmos genéticos redujo considerablemente los errores (≥ 85 % en MAE y RMSE) y elevó el R^2 de calibración a valores ≥ 0.96 en los tres modelos. El modelo Utah calibrado con Pymoo presentó el mejor desempeño en evaluación, con el menor MAE (6 d) y RMSE (8.8 d) y un R^2 de 0.98.

El modelo Dinámico calibrado registró un MAE bajo (8.3 días), comparable al del modelo Utah optimizado (12 días); sin embargo, en la evaluación el MAE aumentó a 31.7 d, lo que evidencia una capacidad predictiva limitada y una escasa generalización a datos no utilizados durante la calibración.

En la evaluación, se dispuso únicamente de un registro de fecha de floración para cada uno de los cultivares en Carichí (Rainer y Skeena), y un registro para Santina en Cuauhtémoc, Chihuahua (Cuadro 5).

El modelo Utah optimizado con Pymoo presentó la mayor precisión en la fase de evaluación, con errores absolutos entre -3 y 15 d, según el cultivar; en contraste, el modelo de Horas frío mostró errores absolutos de mayor magnitud (15 a 19 d), mientras que el modelo Dinámico presentó los errores más altos (178 a 183 d), lo que sugiere inestabilidad en su desempeño y una capacidad predictiva comparable a la del modelo sin calibrar. En el caso particular del cultivar Santina, la fecha de plena floración se estimó con mayor precisión mediante el modelo Utah sin calibrar; además, este cultivar fue mejor estimado por el modelo de Horas frío en comparación con los otros cultivares.

La calibración del modelo Utah aumentó el umbral inferior del intervalo de acumulación de frío de 1.4 a 1.97 °C, lo que redujo la acumulación de unidades frío a temperaturas cercanas a 0 °C. Después del ajuste, solo el intervalo 1.97 a 2.19 °C aporta una unidad completa de frío por hora, mientras que el intervalo 6.12 a 14.0 °C contribuye con 0.5 unidades por hora. Este cambio, por encima de 14.0 °C y por debajo de 1.97 °C, representa una pérdida de frío acumulado o, en su caso, una acumulación parcial mínima, lo que equivale a una penalización suavizada en los extremos térmicos (Figura 1).

Este patrón muestra que los algoritmos genéticos pueden explorar espacios de búsqueda discretos y no lineales, como en el modelo Utah, que asigna ponderaciones escalonadas por intervalos de temperatura. Al optimizar la función objetivo, el algoritmo ajusta los límites de cada tramo y genera combinaciones de parámetros que, aunque poco intuitivas, minimizan el error total del modelo. Así, se evita la sobreacumulación de frío en condiciones subóptimas y se mejora la precisión de la estimación horaria de unidades frío.

En cuanto a los requerimientos de frío, no se encontró en la literatura información específica para el cultivar Skeena (Cuadro 6). Con base en los modelos evaluados, se propone un intervalo razonable del requerimiento de frío. En contraste, los modelos sin calibración tienden a subestimar el requerimiento de frío en los sitios estudiados, caracterizados por inviernos marginales en Chihuahua, México.

El desarrollo de modelos fenológicos precisos depende de la disponibilidad de datos de calidad y de una calibración rigurosa, ajustada a los cultivares y a las condiciones locales. Diversos estudios han reportado un desempeño alto en modelos basados en la acumulación de frío y calor, con errores absolutos medios de 3 a 6 días en especies de clima templado (Darbyshire *et al.*, 2020), así como valores de RMSE de hasta 1.5 días cuando se incorporan técnicas de inteligencia artificial (Masago y Lian, 2022).

Los resultados de este estudio evidencian la limitada precisión de los modelos evaluados sin calibración específica (testigos). En particular, el modelo Dinámico fue el más inexacto, con errores superiores a 170 días en todos los cultivares y un MAE de evaluación de 180 días (Cuadro 6).

Finalmente, al proyectar modelos fenológicos calibrados localmente a escalas mayores, es indispensable evaluar su incertidumbre. Wang *et al.* (2024) señalaron que los modelos desarrollados ajustados solo con datos experimentales pueden incurrir en errores importantes al extrapolarse, especialmente bajo cambio climático o cuando derivan de ambientes controlados; por ello, se recomienda evaluar en múltiples ambientes y cultivares e incorporar la heterogeneidad ambiental. En este estudio se usaron métricas de error; como trabajo futuro se propone un análisis explícito de incertidumbre para fortalecer la confiabilidad de las predicciones.

CONCLUSIONES

La aplicación de algoritmos genéticos permite calibrar con precisión los modelos de acumulación de frío para

Cuadro 4. Análisis comparativo de métricas de los modelos.

Modelo	Algoritmo de optimización	Número de parámetros ajustados	Datos usados en la calibración (n = 15)			Datos usados en la evaluación (n = 3)		
			MAE	R ²	RMSE	MAE	R ²	RMSE
Utah	Testigo	16	37.3	0.89	38.0	17.6	ND	17.7
Utah	Pymoo	16	12.0	0.97	17.9	6.0	0.98	8.8
Dinámico	Testigo	9	187.0	0	188.0	180.0	0.25	180.1
Dinámico	Pymoo	9	8.3	0.99	10.3	31.7	ND	33.5
Horas frío	Testigo	5	134.0	0	175.0	182.0	0.26	201.0
Horas frío	Pymoo	5	14.2	0.96	14.2	17.7	ND	17.8

R²: coeficiente de determinación, MAE: error absoluto medio, RMSE: raíz del error cuadrático medio, ND: valor no disponible.

Cuadro 5. Evaluación de los modelos Utah, Dinámico y Horas frío en la estimación de la fecha de floración plena por cultivar durante la fase de evaluación.

Modelo	Cultivar	Fecha de floración modelada [†]	Fecha de floración observada [†]	Error (± días del año)	Unidades frío (uf)
Utah testigo	Rainier	116	97	19	479
	Skeena	116	97	19	479
	Santina	116	101	5	566
Utah	Rainier	97	97	0	988
	Skeena	94	97	-3	974
	Santina	116	101	15	1033
Dinámico testigo	Rainier	278	97	181	60.61
	Skeena	278	97	181	60.61
	Santina	279	101	178	72.91
Dinámico	Rainier	279	97	182	76.35
	Skeena	280	97	183	91.92
	Santina	279	101	178	72.91
Horas frío testigo	Rainier	340	97	243	950.44
	Skeena	37	97	-60	1563.55
	Santina	345	101	244	923.66
Horas frío	Rainier	116	97	17.6	1295
	Skeena	116	97	19	1295
	Santina	116	101	15	1424

[†]Día del año.

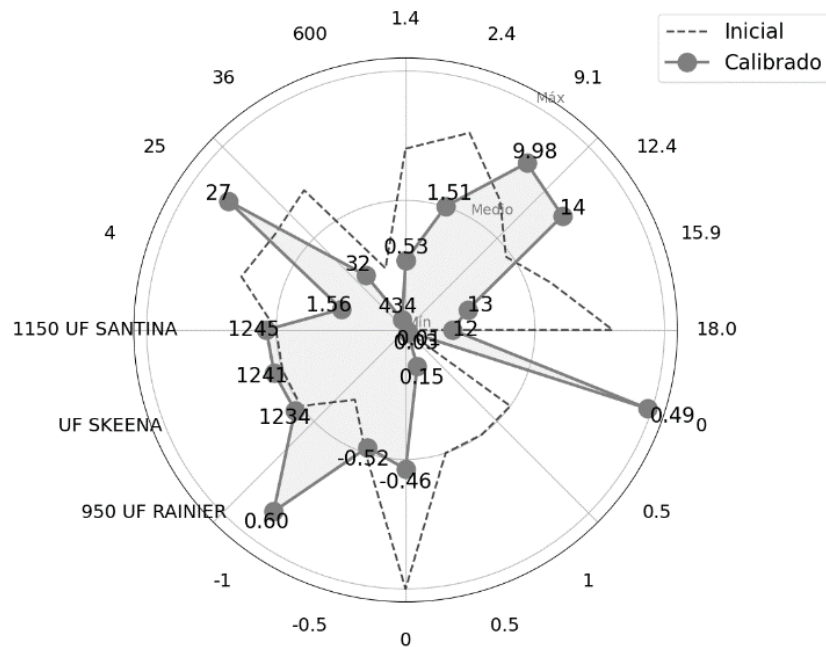


Figura 1. Valores de los parámetros del modelo Utah antes y después de la calibración con algoritmos genéticos.

Cuadro 6. Requerimientos de frío en cultivares de cerezo: datos bibliográficos y estimaciones de los modelos antes y después de la calibración con datos de evaluación.

Cultivar	Literatura			Modelos sin calibrar			Modelos calibrados		
	Utah	Dinámico	Horas frío	Utah	Dinámico	Horas frío	Utah	Dinámico	Horas frío
Rainier	950	61	1067	469	60	950	987	76	1442
Skeena	†	†	1556	469	60	1563	966	90	1444
Santina	1150	57	917	576	72	923	1795	62	1419

Fadón *et al.* 2018; 2021, †No reportados en la literatura.

cerezos cultivados en Chihuahua. En particular, el modelo Utah optimizado con Pymoo alcanzó un MAE de 12 d en la fase de calibración y 6 d en la evaluación, mejorando sustancialmente el desempeño de la versión sin calibrar. El mayor grado de precisión se obtuvo en el cultivar Rainier, lo que demuestra la influencia del cultivar en la respuesta fenológica. Los resultados confirman que los modelos deben calibrarse con datos locales para minimizar errores predictivos. La extrapolación de parámetros desarrollados en otras regiones o condiciones controladas puede conducir a estimaciones inexactas.

AGRADECIMIENTOS

La primera autora agradece al SECIHTI por la beca otorgada para realizar estudios de Maestría en Ciencias.

BIBLIOGRAFÍA

Anderson J. L., E. A. Richardson and C. D. Kesner (1986) Validation of chill unit and flower bud phenology models for 'Montmorency' sour cherry. *Acta Horticulturae* 184:71-78, <https://doi.org/10.17660/actahortic.1986.184.7>

Castède S., J. A. Campoy, J. Quero G., L. Le Dantec, M. Lafargue, T. Barreneche, ... and E. Dirlwanger (2014) Genetic determinism of phenological traits highly affected by climate change in *Prunus avium*: flowering date dissected into chilling and heat requirements. *New Phytologist* 202:703-715, <https://doi.org/10.1111/nph.12658>

Catalán V. E. A., M. A. Inzunza I. y S. F. Mendoza M. (2005) Evaluación de la metodología curva seno modificada para estimar grados-día en tres localidades del norte de México. *Agrofaz* 5:851-856.

Darbyshire R., J. Navas L., X. Song, B. Wenden and D. Close (2020) Modelling cherry full bloom using 'space-for-time' across climatically diverse growing environments. *Agricultural and Forest Meteorology* 284:107901, <https://doi.org/10.1016/j.agrformet.2020.107901>

Demirsoy H., L. Demirsoy and G. A. Lang (2022) Research on spring frost damage in cherries. *Horticultural Science* 49:89-94, <https://doi.org/10.17221/91/2021-hortsci>

- Didevarasl, A., J. M. Costa S., D. Spano, P. Deiana, R. L. Snyder, M. Mulas, ... and A. Trabucco (2023) Modeling phenological phases across olive cultivars in the Mediterranean. *Plants* 12:3181, <https://doi.org/10.3390/plants12183181>
- Erez A., S. Fishman, G. Linsley-Noakes and P. Allan (1990) The dynamic model for rest completion in peach buds. *Acta Horticulturae* 276:165-174, <https://doi.org/10.17660/actahortic.1990.276.18>
- Fadón E., J. Rodrigo and M. Herrero (2018) Is there a specific stage to rest? Morphological changes in flower primordia in relation to endodormancy in sweet cherry (*Prunus avium* L.). *Trees* 32:1583-1594, <https://doi.org/10.1007/s00468-018-1735-7>
- Fadón E., J. Rodrigo and E. Luedeling (2021) Cultivar-specific responses of sweet cherry flowering to rising temperatures during dormancy. *Agricultural and Forest Meteorology* 307:108486, <https://doi.org/10.1016/j.agrformet.2021.108486>
- García E. (2004) Modificaciones al Sistema de Clasificación Climática de Köppen. Instituto de Geografía, Universidad Nacional Autónoma de México. México, D. F. 90 p.
- Grillakis M. G., G. Doupis, E. Kapetanakis and E. Goumenaki (2022) Future shifts in the phenology of table grapes on Crete under a warming climate. *Agricultural and Forest Meteorology* 318:108915, <https://doi.org/10.1016/j.agrformet.2022.108915>
- Hájková L., M. Možný, V. Oušková, L. Bartošová, P. Dížková and Z. Žalud (2023) Increasing risk of Spring frost occurrence during the cherry tree flowering in times of climate change. *Water* 15:497, <https://doi.org/10.3390/w15030497>
- Katoch S., S. S. Chauhan and V. Kumar (2021) A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications* 80:8091-8126, <https://doi.org/10.1007/s11042-020-10139-6>
- Masago Y. and M. Lian (2022) Estimating the first flowering and full blossom dates of Yoshino cherry (*Cerasus × yedoensis* 'Somei-yoshino') in Japan using machine learning algorithms. *Ecological Informatics* 71:101835, <https://doi.org/10.1016/j.ecoinf.2022.101835>
- Palma M., Á. Sepúlveda and J. A. Yuri (2023) Effect of plastic roof and high tunnel on microclimate, physiology, vegetative growth and fruit characteristics of 'Santina' sweet cherry. *Scientia Horticulturae* 317:112037, <https://doi.org/10.1016/j.scienta.2023.112037>
- Plaza G. L. F. (2011) Modelamiento matemático de fenómenos cíclicos. *Scientia et Technica* 16:145-150.
- Richardson A. D., T. F. Keenan, M. Migliavacca, Y. Ryu, O. Sonnentag and M. Toomey (2013) Climate change, phenology, and phenological control of vegetation feedbacks to the climate system. *Agricultural And Forest Meteorology* 169:156-173, <https://doi.org/10.1016/j.agrformet.2012.09.012>
- Richardson E. A., S. D. Seeley and D. R. Walker (1974) A Model for estimating the completion of rest for 'Redhaven' and 'Elberta' peach trees. *HortScience* 9:331-332, <https://doi.org/10.21273/hortsci.9.4.331>
- SE, Secretaría de Economía (2012) Cerezas frescas (excepto las cerezas ácidas): intercambio comercial, compras y ventas internacionales, mercado y especialización. Data México. Secretaría de Economía. Ciudad de México. <https://www.economia.gob.mx/datamexico/es/profile/product/fresh-cherries-except-sour-cherries> (Julio 2025).
- Semiromi J. T., S. Amirzadeh and H. Meighani (2024) New simple approach to the site-specific prediction of grapevine (*Vitis vinifera*) phenological phases (The case of Kerman, Iran). *Agricultural and Forest Meteorology* 353:110057, <https://doi.org/10.1016/j.agrformet.2024.110057>
- Sivanandam S. N. and S. N. Deepa (2008) Introduction to Genetic Algorithms. Springer. Berlin, Germany. 461 p, <https://doi.org/10.1007/978-3-540-73190-0>
- Tang D., B. K. Quinn, Y. Yang, L. Guo, D. A. Ratkowsky and P. Shi (2025) Fall and Winter temperatures, together with Spring temperatures, determine the first flowering date of *Prunus armeniaca* L. *Plants* 14:1503, <https://doi.org/10.3390/plants14101503>
- Trejo Z. E. C., I. L. López C. and A. Ruiz G. (2014) Parameter estimation for crop growth model using evolutionary and bio-inspired algorithms. *Applied Soft Computing* 23:474-482, <https://doi.org/10.1016/j.asoc.2014.06.023>
- Venter G. (2010) Review of optimization techniques. In: Encyclopedia of Aerospace Engineering. R. Blockley and W. Shyy (eds). John Wiley & Sons. Hoboken, New Jersey, USA. pp:1-12, <https://doi.org/10.1002/9780470686652.eae495>
- Wang H., S. Lin, J. Dai and Q. Ge (2024) Controlled experiments fail to capture plant phenological response to chilling temperature. *Global Ecology and Biogeography* 33:e13888, <https://doi.org/10.1111/geb.13888>
- Weinberger J. H. (1950) Chilling requirements of peach varieties. *Proceedings of the American Society for Horticultural Science* 56:122-128.
- Zheng H., Y. Chen and Z. Zhang (2022) Predicting blossom date of cherry tree with support vector machine and recurrent neural network. *arXiv:2210.04*, <https://doi.org/10.48550/arXiv.2210.04406>

