



PRONÓSTICO DE GRADOS-DÍA BASADO EN IA PARA ALERTAMIENTO DE *DENDROCTONUS MEXICANUS* EN AGUASCALIENTES

AI-BASED DEGREE-DAY FORECAST FOR EARLY WARNING OF *Dendroctonus mexicanus* IN AGUASCALIENTES

Arturo Corrales-Suastegui¹; Miguel Ángel González-González¹; Guillermo Sánchez-Martínez¹.

¹Campo Experimental Pabellón, Centro de Investigación Regional Norte Centro, Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias.

*Autor por correspondencia: corrales.arturo@inifap.gob.mx

Área temática: Agrícola

Resumen

En este trabajo se presenta la evaluación de un pronóstico mensual extendido a seis meses de los grados-día de desarrollo (GDD) para *Dendroctonus mexicanus* en la Sierra Fría de Aguascalientes. El modelo se basa en una red neuronal artificial secuencial con capas densas, alimentada con el Índice Oceánico de El Niño (ONI) como predictor principal. La validación para el periodo octubre 2024-agosto 2025 mostró que la red neuronal reproduce de manera adecuada el promedio de GDD respecto a la referencia de ERA5 Land, con un sesgo global menor a 5 %. El desempeño más estable se observó en el horizonte de cuatro meses (M4), donde el sesgo fue prácticamente nulo. No obstante, la variabilidad intermensual fue pobremente representada, con sobreestimaciones en horizontes cortos y subestimaciones en los más largos. Estos resultados sugieren que el modelo puede constituir una primera aproximación operativa para sistemas de alerta temprana, permitiendo anticipar con varios meses de antelación las condiciones térmicas favorables para el desarrollo del descortezador, aunque se recomienda continuar ajustando la arquitectura y explorar predictores adicionales para mejorar la representación de la variabilidad.

Palabras clave: Red neuronal, Descortezador, ONI, Aguascalientes, ERA5 Land.

Keywords: Neural network, Barker, ONI, Aguascalientes, ERA5 Land.

Introducción

La Sierra Fría, en el noroeste de Aguascalientes, concentra bosques templados que sostienen una alta diversidad de flora y fauna. Entre las amenazas a estas masas de pino destaca el descortezador *Dendroctonus mexicanus*, cuyo ciclo bajo la corteza y la alimentación larval del floema interrumpen el transporte de nutrientes y conducen por lo general a la muerte del árbol (Vega & Hofstetter, 2015). Los brotes repercuten, además, en funciones ecosistémicas como la captura de carbono, la regulación hidrológica y la protección del suelo (Bentz et al., 2010).

En la región, el auge de *D. mexicanus* se ha vinculado con periodos más cálidos y secos, así como con prácticas de manejo inexistentes o poco adecuadas (Bentz et al., 2010; Negrón y Fettig, 2014). Anticipar su dinámica es, por tanto, clave para decidir acciones oportunas. En este trabajo se evalúa un pronóstico de seis meses con

actualizaciones mensuales de grados-día para *D. mexicanus* en la Sierra Fría, implementado mediante una red neuronal (RN) secuencial de capas densas. La evaluación abarca de octubre de 2024 a agosto de 2025, periodo en el que se inicializa, actualiza y contrasta el modelo con series de datos del reanálisis ERA5 Land. El objetivo es verificar su desempeño reciente y ofrecer una herramienta operativa para el manejo y control del descortezador en el área de estudio. Estudios recientes también muestran que las redes neuronales aplicadas a la agricultura permiten modelar relaciones complejas y anticipar dinámicas bioclimáticas con utilidad práctica (Castillo-Girones et al., 2025; Borella et al., 2022). (Bentz et al., 2010).

Materiales y métodos

Área de estudio. El análisis se realizó en la Sierra Fría, en el municipio de San José de Gracia, Aguascalientes, la zona de mayor altitud del estado (~3 000 m), como se muestra en la Figura 1. El sitio de pronóstico y validación de los GDD se ubicó dentro de la sierra (punto en rojo, Figura 1).




Figura 1. Área de estudio. Estado de Aguascalientes, división municipal, municipio de San José de Gracia (encerrado en línea negra gruesa) y topografía (m). El punto en rojo, ubicado en la Sierra Fría, indica el sitio de pronóstico y validación de los GDD para *D. mexicanus* a partir de la RN y ERA5 Land, respectivamente.

Reanálisis climático. Dada la limitada disponibilidad de series históricas diarias de estaciones locales, se utilizaron campos horarios de temperatura de ERA5 Land (Muñoz-Sabater et al., 2021) para derivar Tmax y Tmin diarias. El reanálisis ERA5 Land es una base de datos global que cubre de 1950–presente y cuya resolución espacial es de ~11 km.

Cálculo de grados-día de desarrollo (GDD). Los GDD se calcularon con el método del seno simple de Baskerville y Emin (1969), que ajusta una curva seno a las temperaturas máximas y mínimas diarias e integra el área acotada por los umbrales inferior y superior de 5 °C y 39 °C, respectivamente. Los umbrales 5 °C y 39 °C se obtuvieron a partir de mediciones en campo, como se describe en Corrales-Suastegui et al. (2024).



Modelo operativo de pronóstico. Se empleó una RN artificial secuencial con capas densas para el pronóstico de GDD mensuales para *D. mexicanus* a partir del Índice Oceánico de El Niño (ONI). La RN se describe en Corrales-Suastegui et al. (2024).

Configuración del pronóstico operativo y periodo de evaluación. Para el presente estudio, el sistema se ejecuta en modo pronóstico extendido a 6 meses con actualizaciones mensuales (horizonte deslizante) y se evalúa/valida contra GDD derivados de ERA5 Land entre octubre de 2024 y agosto de 2025. Este periodo de evaluación corresponde a la fase reciente operativa del proyecto. El pronóstico mensual se encuentra disponible al público en: https://www.myqnapcloud.com/smartshare/783ig432np2m26759885y132_c9h2higk179722260055731c884bff9f

Métricas de desempeño. La verificación del pronóstico se basó en el sesgo (RN – ERA5 Land), expresado en valores absolutos (°D) y relativos (%), junto con la comparación de medias y desviación estándar. Esto permitió evaluar tanto la magnitud promedio de los GDD como su variabilidad intermensual. Se analizaron seis horizontes de pronóstico (M1-M6), identificando mayor estabilidad en M4 (sesgo cercano a cero) y mayor dispersión en M3 y M5. Estas métricas son estándar en validaciones climáticas y han mostrado su utilidad en estudios recientes (Zanchi et al., 2023; Gong et al., 2022; Lin et al., 2024).

Resultados

El análisis (Cuadros 1 a 3) mostró que ERA5 Land presenta un aumento progresivo de GDD hacia horizontes largos, con alta variabilidad en M3. La RN reproduce la tendencia, aunque con mayor dispersión, destacando concordancia en M4. El sesgo indica sobreestimaciones en M2–M3 y subestimaciones en M5–M6, pero en promedio global fue <5 %, lo que refleja una buena aproximación al nivel medio (Zanchi et al., 2023; Gong et al., 2022). En conjunto, el sistema ofrece un desempeño útil para anticipar condiciones térmicas que favorecen a *D. mexicanus* en la Sierra Fría, especialmente en horizontes de 4 meses.

Discusión

El hecho de que el sesgo global porcentual sea menor a 5 % indica que, pese a la variabilidad no capturada, la red neuronal reproduce con gran exactitud el nivel medio de los GDD. En términos operativos, este nivel de precisión es altamente valioso para un sistema de alerta temprana, ya que permite anticipar condiciones favorables para el desarrollo de *D. mexicanus* con suficiente confiabilidad.

La principal limitante identificada está en la representación de la variabilidad intraestacional, lo que sugiere la necesidad de incorporar predictores adicionales (p. ej. humedad del suelo, índices de sequía o circulación atmosférica regional) o explorar arquitecturas de RN más sofisticadas (LSTM, GRU o híbridas) que permitan capturar la memoria del sistema climático.

En resumen, aunque el modelo actual no logra describir con detalle la variabilidad intraanual, su capacidad de aproximarse al promedio mensual de GDD lo convierte en una herramienta útil para la planeación preventiva del manejo forestal en la Sierra Fría de Aguascalientes en complemento con pronósticos climáticos dinámicos y observaciones locales. Este resultado concuerda con trabajos que han demostrado la capacidad de modelos de aprendizaje profundo para reproducir condiciones climáticas promedio aun con limitaciones en la variabilidad intraestacional (Zanchi et al., 2023; Gong et al., 2022). En este sentido, enfoques recientes que combinan arquitecturas recurrentes y modelos de crecimiento han mostrado mejoras en la predicción basada en GDD (Lin et al., 2024), y otros trabajos destacan su aplicación en pronósticos de eventos térmicos extremos como heladas (Talsma et al., 2023).



Cuadro 1. GDD mensuales (°D) de referencia derivados de ERA5 Land para seis horizontes (M1–M6; del primer al sexto mes del horizonte) y seis periodos deslizantes: octubre 2024–marzo 2025, noviembre 2024–abril 2025, diciembre 2024–mayo 2025, enero 2025–junio 2025, febrero 2025–julio 2025 y marzo 2025–agosto 2025. Se reportan promedio y desviación estándar (Std) por horizonte y por periodo.

Periodo	Octubre 2024	Noviembre 2024	Diciembre 2024	Enero 2025	Febrero 2025	Marzo 2025		
	-	-	-	-	-	-		
	Marzo 2025	Abril 2025	Mayo 2025	Junio 2025	Julio 2025	Agosto 2025		
Horizonte	GDD (°D)	GDD (°D)	GDD (°D)	GDD (°D)	GDD (°D)	GDD (°D)	Promedio (°D)	Std (°D)
M1	303.7	314.4	237.3	215.5	264.0	320.4	275.9	43.6
M2	314.4	237.3	215.5	264.0	320.4	364.3	286.0	56.5
M3	237.3	215.5	264.0	320.4	364.3	447.2	308.1	87.4
M4	215.5	264.0	320.4	364.3	447.2	377.8	331.5	83.4
M5	264.0	320.4	364.3	447.2	377.8	342.1	352.6	61.2
M6	320.4	364.3	447.2	377.8	342.1	353.9	367.6	43.6
Promedio (°D)	275.9	286.0	308.1	331.5	352.6	367.6		
Std (°D)	43.6	56.5	87.4	83.4	61.2	43.6		

Cuadro 2. Pronóstico de GDD mensuales (°D) con la red neuronal (RN) para los mismos seis horizontes (M1–M6) y periodos deslizantes indicados en el Cuadro 1. Se incluyen promedio y desviación estándar (Std) por horizonte y por periodo.

Periodo	Octubre 2024	Noviembre 2024	Diciembre 2024	Enero 2025	Febrero 2025	Marzo 2025		
	-	-	-	-	-	-		
	Marzo 2025	Abril 2025	Mayo 2025	Junio 2025	Julio 2025	Agosto 2025		
Horizonte	GDD (°D)	GDD (°D)	GDD (°D)	GDD (°D)	GDD (°D)	GDD (°D)	Promedio (°D)	Std (°D)
M1	315.8	247.0	161.9	233.2	275.2	376.4	268.3	73.5
M2	207.0	297.2	286.7	275.2	376.4	413.3	309.3	74.3
M3	297.2	348.6	186.8	376.4	413.3	344.3	327.8	79.0
M4	271.2	343.8	361.8	413.3	344.3	255.0	331.6	59.0
M5	343.8	355.5	402.0	344.3	255.0	251.9	325.4	59.7
M6	355.5	297.0	413.4	255.0	251.9	264.5	306.2	65.3
Promedio (°D)	298.4	314.9	302.1	316.2	319.4	317.6		
Std (°D)	54.3	42.1	108.8	72.3	68.3	69.8		

Cuadro 3. Sesgo del pronóstico de la RN respecto a la referencia ERA5 Land, expresado en °D y %, para cada periodo y horizonte (M1–M6). Convención: sesgo = RN - ERA5 Land (positivo = sobreestimación). Se presentan también los promedios por periodo y por horizonte.



Periodo	Octubre 2024	Noviembre 2024	Diciembre 2024	Enero 2025	Febrero 2025	Marzo 2025	Promedio
	-	-	-	-	-	-	
	Marzo 2025	Abril 2025	Mayo 2025	Junio 2025	Julio 2025	Agosto 2025	
Sesgo (°D)	22.5	28.9	-6.0	-15.3	-33.3	-50.1	-0.6
Sesgo (%)	8.2	10.1	-2.0	-4.6	-9.4	-13.6	-1.9
Horizonte	M1	M2	M3	M4	M5	M6	Promedio
Sesgo (°D)	-7.6	23.3	19.7	0	-27.2	-61.4	1.6
Sesgo (%)	-2.8	8.2	6.4	0	-7.7	-16.7	-2.1

Conclusión

A partir del análisis del modelo de pronóstico de GDD basado en una red neuronal, concluimos que, para un horizonte de seis meses, el sistema ofrece estimaciones útiles del nivel medio de GDD, con un sesgo global menor a 5 % y un desempeño particularmente sólido en M4 (sesgo prácticamente nulo). Aunque la red reproduce bien el promedio, aún presenta limitaciones para capturar la variabilidad intermensual, con sobreestimaciones en horizontes cortos y subestimaciones en los más largos.

En consecuencia, continuaremos ajustando la arquitectura y la calibración del modelo e incorporando predictores adicionales (p. ej., humedad del suelo, índices de sequía o circulación regional) para reducir la dispersión y mejorar la estabilidad en todos los horizontes. Pese a estas limitaciones, los resultados son valiosos para la planeación y el alertamiento temprano del *D. mexicanus* en la Sierra Fría de Aguascalientes.

Referencias

- Baskerville, G. L., & Emin, P. (1969). Rapid estimation of heat accumulation from maximum and minimum temperatures. *Ecology*, 50(3), 514–517. <https://doi.org/10.2307/1933912>
- Bentz, B. J., Régnière, J., Fettig, C. J., Hansen, E. M., Hayes, J. L., Hicke, J. A., Kelsey, R. G., Negrón, J. F., & Seybold, S. J. (2010). Climate change and bark beetles of the western United States and Canada: Direct and indirect effects. *BioScience*, 60(8), 602–613. <https://doi.org/10.1525/bio.2010.60.8.6>
- Produção, Gestão & Borella, Lucas & Borella, Margareth & Corso, Leandro. (2022). Climate analysis using neural networks as supporting to the agriculture. *Gestão & Produção*. 29. <https://doi.org/10.1590/1806-9649-2022v29e06>
- Castillo-Girones, S., Munera, S., Martínez-Sober, M., Blasco, J., Cubero, S., & Gómez-Sanchis, J. (2025). Artificial neural networks in agriculture: The core of decision support systems. *Computers and Electronics in Agriculture*, 221, 108808. <https://doi.org/10.1016/j.compag.2025.109938>
- Corrales-Suastegui, A., González-González, M. A., & Sánchez-Martínez, G. (2024). Estimación de grados-día de desarrollo para el descortezador *D. mexicanus* en el estado de Aguascalientes. *Memoria de la XXXVI Semana Internacional de Agronomía* (pp. 254–260).
- Gong, B., Langguth, M., Ji, Y., Mozaffari, A., Stadtler, S., Mache, K., & Schultz, M. G. (2022). Temperature forecasting by deep learning methods. *Geoscientific Model Development*, 15, 8931–8956. <https://doi.org/10.5194/gmd-15-8931-2022>



- Lin, Y.-S., Fang, S.-L., Kang, L., Chen, C.-C., Yao, M.-H., & Kuo, B.-J. (2024). Combining Recurrent Neural Network and Sigmoid Growth Models for Short-Term Temperature Forecasting and Tomato Growth Prediction in a Plastic Greenhouse. *Horticulturae*, 10(3), 230. <https://doi.org/10.3390/horticulturae10030230>
- Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G., Balsamo, G., Boussetta, S., Choulga, M., Harrigan, S., Hersbach, H., Martens, B., Miralles, D. G., Piles, M., Rodríguez-Fernández, N. J., Zsoter, E., Buontempo, C., & Thépaut, J.-N. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, 13(9), 4349–4383. <https://doi.org/10.5194/essd-13-4349-2021>
- Negrón, J. F., & Fettig, C. J. (2014). Mountain pine beetle, a major disturbance agent in U.S. western coniferous forests: A synthesis of the state of knowledge. *Forest Science*, 60(3), 409–413. <https://doi.org/10.5849/forsci.13-169>
- Talsma, C. J., [y coautores]. (2023). Frost prediction using machine learning and deep neural methods. *Frontiers in Artificial Intelligence*, 5, 963781. <https://doi.org/10.3389/frai.2022.963781>
- Vega, F. E., & Hofstetter, R. W. (2015). *Bark beetles: Biology and ecology of native and invasive species*. Academic Press. ISBN 978-0-12-417156-5
- Zanchi, M., Zapperi, S., & La Porta, C. A. M. (2023). Harnessing deep learning to forecast local microclimate using global climate data. *Scientific Reports*, 13, 21012. <https://doi.org/10.1038/s41598-023-48028-1>