

ESTIMACIÓN DE GRADOS DÍA DE DESARROLLO PARA DESCORTEZADOR *D. MEXICANUS* EN EL ESTADO DE AGUASCALIENTES

Corrales S. A.; González G. M. A.; Sánchez M. G.

Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP).
Campo Experimental Pabellón. Carretera Aguascalientes-Zacatecas km 32.5, Pabellón de
Arteaga, Aguascalientes, México. C.P. 20670. Correo-e: corrales.arturo@inifap.gob.mx

RESUMEN

En este trabajo se presenta una propuesta de pronóstico de los grados día de desarrollo para el *D. mexicanus* en la Sierra Fría de Aguascalientes. Para lo anterior, se utilizó una red neuronal (RN) artificial mediante un modelo secuencial que emplea capas densas. Los resultados sugieren, que el pronóstico basado en la RN reproduce de manera adecuada el promedio de GDD (~3684) de forma cercana al promedio de GDD (~3681) obtenido a partir del reanálisis ERA5 sobre un periodo de 5 años (60 meses). No obstante, la variabilidad es pobremente representada por la RN. Para periodos de 6 a 12 meses, la RN nos puede proporcionar un pronóstico certero de GDD. Como trabajo en curso, se siguen probando diferentes configuraciones y arquitecturas de la RN. Estos resultados son de importancia para estimar con anticipación el posible comportamiento del *D. mexicanus* en la Sierra Fría de Aguascalientes.

Palabras clave. Red neuronal, capas densas, Sierra Fría

ABSTRACT

This paper presents a proposal for forecasting the growing degree days (GDD) for *Dendroctonus mexicanus* in the Sierra Fría of Aguascalientes. An artificial neural network (NN) with a sequential model utilizing dense layers was employed for this purpose. The results indicate that the NN-based forecast effectively reproduces the average GDD (~3684), closely aligning with the average GDD (~3681) derived from ERA5 reanalysis data over a 5-year period (60 months). However, the NN shows limitations in accurately representing variability. For forecasting periods ranging from 6 to 12 months, the NN can provide precise GDD predictions. Ongoing work involves testing various configurations and architectures of the NN to enhance its performance. These findings are crucial for estimating in advance the potential behavior of *D. mexicanus* in the Sierra Fría of Aguascalientes.

Key words. Neural network, dense layers, Sierra Fría

INTRODUCCION

La Sierra Fría, ubicada en el estado de Aguascalientes, es una región de gran importancia ecológica debido a su biodiversidad y a la presencia de ecosistemas forestales que albergan una variedad de especies tanto de flora como de fauna. Uno de los insectos que ha llamado la atención en esta región es el descortezador mexicano *Dendroctonus mexicanus* (*D. mexicanus*).

El *D. mexicanus* es conocido por su capacidad para atacar árboles de pino, considerándose una de las principales plagas forestales en México. Este insecto perfora la corteza de los pinos para depositar sus huevos, y las larvas que emergen se alimentan del floema, interrumpiendo

el flujo de nutrientes y causando la muerte del árbol (Salinas-Moreno et al., 2010). Los brotes de *D. mexicanus* pueden tener consecuencias devastadoras para los ecosistemas forestales, afectando no solo la biodiversidad sino también los servicios ecosistémicos que estos bosques proporcionan, como la captura de carbono, la regulación del ciclo hidrológico y la conservación del suelo (Vega and Hofstetter, 2015).

En la Sierra Fría, la incidencia de *D. mexicanus* ha generado preocupación entre los investigadores y gestores forestales debido al impacto negativo sobre las poblaciones de pino. La combinación de factores climáticos, como el aumento de la temperatura y la disminución de las precipitaciones, junto con prácticas de manejo forestal inadecuadas, han contribuido a la proliferación de este descortezador (Bentz et al., 2010; Negrón and Fettig, 2014).

El pronóstico del desarrollo de *D. mexicanus* es importante para implementar estrategias de manejo y control efectivas. En este sentido, el objetivo de este trabajo es presentar una propuesta de pronóstico de los grados día de desarrollo para el *D. mexicanus* en la Sierra Fría de Aguascalientes, utilizando una red neuronal artificial mediante un modelo secuencial que emplea capas densas. Este enfoque permitirá modelar relaciones complejas entre variables climáticas y biológicas, proporcionando una herramienta robusta para estimar el comportamiento de este descortezador.

MATERIALES Y METODOS

Área de estudio

La Sierra Fría se sitúa en el municipio de San José de Gracia en el estado de Aguascalientes (Figura 1). La Sierra Fría es la zona más alta del estado, alcanzando altitudes cercanas a los 3,000 m.




Figura 1. Estado de Aguascalientes, división municipal, municipio de San José de Gracia (encerrado en línea negra gruesa) y topografía (m).

El punto verde indica el sitio de muestreo, en la Sierra Fría, de temperatura para determinar los umbrales mínimo y máximo del *D. mexicanus*. Círculo rojo relleno indica el punto cercano

en ERA5 en donde se calcularon los GDD con base en los umbrales determinados a partir del sitio de muestreo. La flecha indica el norte.

Observaciones

Se utilizaron los registros de temperaturas horarias de agosto a noviembre de 2023 obtenidas mediante un data logger que se instaló en la Sierra Fría (Figura 1, punto verde). Este monitoreo duró aproximadamente 90 días, durante los cuales se completó un ciclo generacional del insecto. A partir de esta información, se determinaron las temperaturas umbrales para el *D. mexicanus*, las cuales resultaron en una máxima de 39 °C y una mínima de 5 °C. A partir de estos umbrales de temperatura se la calcularon los GDD para el descortezador, como se describe más adelante.

Reanálisis

Dado el difícil acceso y disponibilidad de datos diarios históricos de temperatura de estaciones meteorológicas en México, se utilizaron campos horarios de temperatura para calcular la máxima y mínima diaria a partir de ERA5 Land, el cual es un producto derivado del reanálisis ERA5 (disponible desde 1950 hasta la actualidad), del Centro Europeo de Pronóstico del Tiempo a Medio Plazo (ECMWF) con resolución horizontal de 31 km (Hersbach *et al.*, 2020; CopernicusClimateChangeService[C3S], 2017, <https://cds.climate.copernicus.eu/cdsapp#!/home>), con mayor resolución espacial (~11 km). El ERA5 ha sido ampliamente utilizado en diversos trabajos de simulación (ej. Corrales-Suastegui *et al.*, 2021).

Grados día de desarrollo

Para calcular los grados día de desarrollo (GDD) se implementó el método del seno simple (Baskerville y Emin, 1969). Este método ajusta una curva seno a las temperaturas máximas y mínimas para un día. En el cálculo se utiliza un umbral inferior y otro superior de temperatura, en este caso 5 y 39 °C, respectivamente, para obtener el área bajo la curva. Este método considera seis casos diferentes para calcular los GDD de acuerdo con el comportamiento diario de las temperaturas. Para una descripción completa de este método consultar: http://ipm.ucanr.edu/WEATHER/ddss_tbl.html. La base de datos histórica de los GDD para 70 años (1951-2020), se calculó a partir de los datos diarios de temperatura máxima y mínima de ERA5 en un punto cercano (Figura 1, punto rojo) al data logger.

Modelo

En este trabajo se utilizó un modelo secuencial basado en capas densas para simular los GDD para el *D. mexicanus* a partir del índice oceánico del Niño (ONI). Las capas densas, también conocidas como capas completamente conectadas, son un tipo de capa en las redes neuronales artificiales que emplean capas densamente conectadas (Goodfellow *et al.*, 2016). Estas capas están compuestas por neuronas que reciben entradas de todas las neuronas de la capa anterior y envían sus salidas a todas las neuronas de la capa siguiente (LeCun *et al.*, 2015). La conectividad completa entre las neuronas permite que la red aprenda patrones y relaciones no lineales en los datos (Hinton *et al.*, 2012). Además, las capas densas aprenden a representar la información de entrada de manera más abstracta y compleja a medida que se propaga a través de la red (Bengio *et al.*, 2013). Las capas densas son comúnmente utilizadas en tareas de regresión y modelado de patrones en datos (Krizhevsky *et al.*, 2012). Para el entrenamiento, validación y prueba de la RN, se utilizaron datos mensuales del ONI como entrada y como salida, datos de GDD calculados a partir de ERA5 para un periodo de 70 años (1951-2020). Se entrenó durante un periodo de 49 años (1951-1999), se validó con

16 años (2000-2015) y se probó para 5 años (2016-2020). En este trabajo se presenta la estadística para el periodo de prueba.

RESULTADOS Y DISCUSION

En la Figura 2 se muestra la variabilidad interanual de los GDD a partir de ERA5 y simulados por la RN. Se observa que para los primeros tres años del periodo de prueba la RN sobrestima los datos en ~100 GDD, a partir del cuarto año de prueba subestima los GDD en ~150 GDD. El promedio sobre todo el periodo, así como la desviación estándar se muestran en la Tabla 1.

La Figura 3 muestra la variabilidad intraanual de los GDD calculados a partir de ERA5 y simulados por la RN para el periodo de prueba. Se encontró que durante los primeros 10 meses, los valores de GDD simulados por la RN son muy cercanos a los “observados”, no obstante, a partir de ahí, la amplitud en la variabilidad en los datos de RN empieza a disminuir, aun cuando sigue un patrón similar a ERA5, de lo cual se obtuvo una correlación estadísticamente significativa al 95% de 0.41, lo cual es una correlación positiva media. La desviación estándar a partir de las series de datos mensuales se presenta en la Tabla 1. Aun cuando el promedio sobre todo el periodo es cercano a ERA5, la variabilidad (desviación estándar) no es bien reproducida. La variabilidad es una de las medidas más complicadas de reproducir por un modelo.




Figura 2. Variabilidad interanual de los GDD a partir de ERA5 (línea negra continua) y la RN (línea negra discontinua).




Figura 3. Variabilidad intraranual de los GDD a partir de ERA5 (línea negra continua) y la RN (línea negra discontinua).

Se realizó un ajuste lineal para las series de tiempo anuales y mensuales de ERA5 y la RN (Figura 4). En la Figura 4a se muestra la dispersión y ajuste lineal a partir de los datos anuales y para el cual se obtuvo un coeficiente de determinación $R^2 = 0.44$, lo cual es un valor bajo. Similarmente, en la Figura 4b, se presenta el ajuste lineal y la dispersión de los datos mensuales, para el cual el coeficiente de determinación es $R^2 = 0.52$, lo cual indica, que el modelo explica el 52% de la varianza en las “observaciones”. Un valor de R^2 mayor o igual a 0.5 puede considerarse aceptable (Rodríguez and Benítez-Parejo, 2011; Nguyen *et al.*, 2022).




Figura 4. (a) Ajuste lineal para datos anuales de GDD a partir de ERA5 y la RN, $R^2 = 0.44$. (b) Ajuste lineal para datos mensuales de GDD a partir de ERA5 y la RN, $R^2 = 0.52$.

Tabla 1. Estadística de las series de tiempo anuales y mensuales de los GDD de acuerdo a ERA5 y la RN para el periodo de prueba de cinco años (60 meses). Los resultados están relacionados a las series de tiempo de las Figuras 2 y 3.

	media	desviación estándar anual	desviación estándar mensual
ERA5	3681.28	141.38	56.78
RN	3684.38	108.45	15.49

CONCLUSIONES

A partir del análisis estadístico del modelo de pronóstico de GDD basado en una RN, se concluye que, para periodos de 6 a 12 meses el modelo nos puede proporcionar un pronóstico certero de GDD, como una primera aproximación. No obstante, se continúa trabajando con diferentes configuraciones y arquitecturas de la RN, con el propósito de reducir el error en el periodo de prueba. Estos resultados son de suma importancia para estimar con anticipación (6 a 12 meses) el posible comportamiento del *D. mexicanus* en la Sierra Fría de Aguascalientes.

REFERENCIAS

- Bengio, Y., Courville, A., and Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828.
- Bentz, B. J., Régnière, J., Fettig, C. J., Hansen, E. M., Hayes, J. L., Hicke, J. A., ... and 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.
- Corrales-Suastegui, A., Ruiz-Alvarez, O., Torres-Alavez, J.A., Pavia, E.G. (2021). Analysis of Cooling and Heating Degree Days over Mexico in Present and Future Climate. *Atmosphere*, 12, 1131. <https://doi.org/10.3390/atmos12091131>
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). Deep learning. MIT Press. <http://www.deeplearningbook.org>
- Hersbach H, Bell B, Berrisford P, et al. (2020). The ERA5 global reanalysis. *Q J R Meteorol Soc.* 146: 1999-2049. <https://doi.org/10.1002/qj.3803>
- Geoffrey E. Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. <https://doi.org/10.48550/arXiv.1207.0580>
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1106-1114.
- LeCun, Y., Bengio, Y., and Hinton, G. E. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Negrón, J. F., and Fettig, C. J. (2014). Mountain pine beetle, a major disturbance agent in US western coniferous forests: a synthesis of the state of knowledge. *Forest Science*, 60(3), 409-413.
- Nguyen, T.Chi, Do, A.Ngoc, Pham, V.Van and Alexandr, G. (2022). Multiple linear regression analysis model and artificial neural network model to calculate and estimate the blast induced area of the tunnel face. A case study Deo Ca tunnel. *Journal of Mining and Earth Sciences*, 63(3), 43-52. [https://doi.org/10.46326/JMES.2022.63\(3\).06](https://doi.org/10.46326/JMES.2022.63(3).06).
- Rodríguez, dÁ.N.M., and Benítez-Parejo, N. (2011). Simple linear and multivariate regression models. *Allergologia et Immunopathologia*, 39(3), 159-173.
- Salinas-Moreno, Y., Mendoza, M. G., Barrios, M. A., Cisneros, R., & Macías-Sámano, J. (2010). Phenology of bark beetles (Coleoptera: Curculionidae: Scolytinae) in the Sierra Madre Oriental, Nuevo León, Mexico. *Annals of the Entomological Society of America*, 103(5), 723-731.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- Vega, F. E., and Hofstetter, R. W. (Eds.). (2015). Bark beetles: biology and ecology of native and invasive species. Academic Press.

Agradecimientos

Se agradece al INIFAP–Campo Experimental Pabellón por el financiamiento otorgado para realizar este trabajo a través del proyecto de investigación Núm. SIGI: 1281435966 “Determinación de temperaturas umbrales y grados día implicados en el desarrollo de *Dendroctonus adjunctus* y *Dendroctonus mexicanus*, y modelaje de los ciclos y límite de distribución de estas especies bajo tres escenarios climáticos”.

ESTIMACIÓN DE GRADOS DÍA DE DESARROLLO PARA DESCORTEZADOR *D. MEXICANUS* EN EL ESTADO DE AGUASCALIENTES

INTRODUCCION

En este trabajo se presenta una propuesta de pronóstico de los grados día de desarrollo para el *D. mexicanus* en la Sierra Fría de Aguascalientes. Para lo anterior, se utilizó una red neuronal (RN) artificial mediante un modelo secuencial que emplea capas densas. Los resultados sugieren, que el pronóstico basado en la RN reproduce de manera adecuada el promedio de GDD (~3684) de forma cercana al promedio de GDD (~3681) obtenido a partir del reanálisis ERA5 sobre un periodo de 5 años (60 meses). No obstante, la variabilidad es pobremente representada por la RN. Para periodos de 6 a 12 meses, la RN nos puede proporcionar un pronóstico certero de GDD. Como trabajo en curso, se siguen probando diferentes configuraciones y arquitecturas de la RN. Estos resultados son de importancia para estimar con anticipación el posible comportamiento del *D. mexicanus* en la Sierra Fría de Aguascalientes.

MATERIALES Y METODOS

Área de estudio

La Sierra Fría se sitúa en el municipio de San José de Gracia en el estado de Aguascalientes (Figura 1). La Sierra Fría es la zona más alta del estado, alcanzando altitudes cercanas a los 3,000 m.




Figura 1. Estado de Aguascalientes, división municipal, municipio de San José de Gracia (encerrado en línea negra gruesa) y topografía (m). El punto verde indica el sitio de muestreo, en la Sierra Fría, de temperatura para determinar los umbrales mínimo y máximo del *D. mexicanus*. Círculo rojo relleno indica el punto cercano en ERA5 en donde se calcularon los GDD con base en los umbrales determinados a partir del sitio de muestreo. La flecha indica el norte.

Observaciones

Se utilizaron los registros de temperaturas horarias de agosto a noviembre de 2023 obtenidas mediante un data logger que se instaló en la Sierra Fría (Figura 1, punto en verde). A partir de esta información, se determinaron las temperaturas umbrales para el *D. mexicanus*, las cuales resultaron en una máxima de 39 °C y una mínima de 5 °C. Adicionalmente, se utilizaron datos del reanálisis ERA5 Land para obtener las temperaturas máxima y mínima diarias. (Figura 1, punto en rojo) y calcular los GDD históricos para un periodo histórico de 1951 a 2020.

Modelo

En este trabajo se utilizó un modelo secuencial basado en capas densas para simular los GDD para el *D. mexicanus* a partir del índice oceánico del Niño (ONI). Para el entrenamiento, validación y prueba de la RN, se utilizaron datos mensuales del ONI como entrada y como salida, datos de GDD calculados a partir de ERA5 para un periodo de 70 años (1951-2020). Se entrenó durante un periodo de 49 años (1951-1999), se validó con 16 años (2000-2015) y se probó para 5 años (2016-2020). En este trabajo se presenta la estadística para el periodo de prueba.

RESULTADOS Y DISCUSION

La Figura 2 muestra la variabilidad intraanual de los GDD calculados a partir de ERA5 y simulados por la RN para el periodo de prueba. Se encontró que durante los primeros 10 meses, los valores de GDD simulados por la RN son muy cercanos a los “observados”, no obstante, a partir de ahí, la amplitud en la variabilidad en los datos de RN empieza a disminuir, aun cuando sigue un patrón similar a ERA5, de lo cual se

Corrales S. A.; González G. M. A.; Sánchez M. G.

Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP). Campo Experimental Pabellón. Carretera Aguascalientes-Zacatecas km 32.5, Pabellón de Arteaga, Aguascalientes, México. C.P. 20670.
Correo-e: corrales.arturo@inifap.gob.mx

obtuvo una correlación estadísticamente significativa al 95% de 0.41, lo cual es una correlación positiva media. La media y desviación estándar a partir de las series de datos mensuales de ERA5 fue 306.77 ± 76.75 GDD; y a partir de la RN se obtuvo 307.03 ± 56.78 GDD. Aun cuando el promedio sobre todo el periodo es cercano a ERA5, la variabilidad (desviación estándar) no es bien reproducida por la RN. La variabilidad es una de las medidas más complicadas de reproducir por un modelo.




Figura 2. Variabilidad intranual de los GDD a partir de ERA5 (línea negra continua) y la RN (línea negra discontinua).

Se realizó un ajuste lineal para las series de tiempo anuales y mensuales de ERA5 y la RN (Figura 3). En la Figura 3a se muestra la dispersión y ajuste lineal a partir de los datos anuales y para el cual se obtuvo un coeficiente de determinación $R^2 = 0.44$, lo cual es un valor bajo. Similarmente, en la Figura 3b, se presenta el ajuste lineal y la dispersión de los datos mensuales, para el cual el coeficiente de determinación es $R^2 = 0.52$, lo cual indica, que el modelo explica el 52% de la varianza en las “observaciones”. Un valor de R^2 mayor o igual a 0.5 puede considerarse aceptable (Rodríguez and Benítez-Parejo, 2011; Nguyen et al., 2022).




Figura 3. (a) Ajuste lineal para datos anuales de GDD a partir de ERA5 y la RN, $R^2 = 0.44$. (b) Ajuste lineal para datos mensuales de GDD a partir de ERA5 y la RN, $R^2 = 0.52$

CONCLUSIONES

A partir del análisis estadístico del modelo de pronóstico de GDD basado en una RN, se concluye que, para periodos de 6 a 12 meses el modelo nos puede proporcionar un pronóstico certero de GDD, como una primera aproximación. No obstante, se continúa trabajando con diferentes configuraciones y arquitecturas de la RN, con el propósito de reducir el error en el periodo de prueba. Estos resultados son de suma importancia para estimar con anticipación (6 a 12 meses) el posible comportamiento del *D. mexicanus* en la Sierra Fría de Aguascalientes.

BIBLIOGRAFIA

Nguyen, T.Chi, Do, A.Ngoc, Pham, V.Van and Alexandr, G. (2022). Multiple linear regression analysis model and artificial neural network model to calculate and estimate the blast induced area of the tunnel face. A case study Deo Ca tunnel. Journal of Mining and Earth Sciences, 63(3), 43-52. [https://doi.org/10.46326/JMES.2022.63\(3\).06](https://doi.org/10.46326/JMES.2022.63(3).06).
Rodríguez, dÁ.N.M., and Benítez-Parejo, N. (2011). Simple linear and multivariate regression models. Allergologia et Immunopathologia, 39(3), 159-173.