

Integración de Modelos Ecológicos y Herramientas Bioinformáticas para la Estimación del Riesgo de *Spodoptera frugiperda* en Zonas Agrícolas Ecuatorianas Integration of Ecological Models and Bioinformatics Tools for Risk Estimation of *Spodoptera frugiperda* in Ecuadorian Agricultural Zones

Fernando Abasolo-Pacheco¹ , Maricruz Carranza-Valencia¹ ,
Yarelys Ferrer-Sánchez¹  y Alexis Herminio Plasencia-Vázquez^{2†} 

¹ Universidad Técnica Estatal de Quevedo. Av. Quito, km 1.5 vía a Santo Domingo de los Tsáchilas. 120501 Quevedo, Los Ríos, Ecuador; (F.A.P.), (M.C.V.), (Y.F.S.).
² Universidad Autónoma de Campeche, Centro de Investigaciones Históricas y Sociales. A. Agustín Melgar s/n, col Buenavista. 24039 Campeche, México; (A.H.P.V.).
[†] Autor para correspondencia: ahplasen@uacam.mx

RESUMEN

El gusano cogollero (*Spodoptera frugiperda*) es una plaga polífaga que afecta a diversos cultivos de importancia económica a nivel mundial, es el maíz (*Zea mays*) su principal hospedero. En este estudio se evaluó la eficacia de seis métodos estadísticos de complejidad variable para modelar la distribución potencial de *S. podoptera frugiperda* y determinar zonas agrícolas de alto riesgo en Ecuador continental. Se emplearon herramientas SIG, diversos paquetes estadísticos, variables bioclimáticas y registros de presencia para modelar el nicho ecológico de la especie en su espacio ambiental. Los mapas de probabilidad de presencia de la plaga obtenidos en RStudio fueron reclasificados en ArcGIS utilizando el umbral de prevalencia de los modelos para generar mapas de distribución potencial de la especie. El rendimiento de los modelos se evaluó mediante un conjunto de métricas, entre las cuales destacan: AUC, estadística de habilidad verdadera, pendiente de calibración de Miller y validación cruzada. Las zonas agrícolas de alto riesgo en Ecuador continental se delimitaron mediante análisis espaciales de la cobertura de suelo y los mapas de distribución potencial de la especie. El estudio confirma el valor de GLM/GAM/GBM como bases robustas (individuales o en ensamble) para mapear riesgo de *S. frugiperda* en Ecuador, delimitar zonas agrícolas prioritarias en Costa y valles de Sierra y reafirma la hipótesis de que las altas temperaturas son cruciales para su desarrollo y propagación, mientras que las precipitaciones excesivas actúan como factor limitante. Actualmente, la distribución potencial de *S. frugiperda* se concentra principalmente en la región Costa del país. Los datos obtenidos permiten comprender el potencial de invasión de *S. frugiperda* y proporcionan una línea base para futuros estudios sobre plagas en cultivos de interés. Esto contribuye al desarrollo de estrategias preventivas de manejo integrado de plagas, reduciendo el riesgo para la seguridad alimentaria y minimizando impactos negativos en el ecosistema.

Palabras clave: agricultura de precisión, análisis espacial, métricas de rendimiento, plaga agrícola, predicción de distribución.

SUMMARY

The fall armyworm (*Spodoptera frugiperda*) is a polyphagous pest that affects several economically important crops worldwide, with maize (*Zea mays* L.) as its principal host. This study evaluated the effectiveness of six statistical methods of varying complexity to model the potential distribution of *S. frugiperda* and identify high-risk agricultural areas in continental Ecuador. Geographic information system (GIS) tools, statistical packages, bioclimatic variables, and occurrence records were used to model the ecological niche of the species within its environmental space.



check for
updates

Cita recomendada:

Abasolo-Pacheco, F., Carranza-Valencia, M., Ferrer-Sánchez, Y., & Plasencia-Vázquez, A. H. (2026). Integración de Modelos Ecológicos y Herramientas Bioinformáticas para la Estimación del Riesgo de *Spodoptera frugiperda* en Zonas Agrícolas Ecuatorianas. *Terra Latinoamericana*, 44, 1-19. e2440. <https://doi.org/10.28940/terralatinoamericana.v44i.2440>

Recibido: 22 octubre de 2025.
Aceptado: 25 de febrero de 2026.
Artículo. Volumen 44.
Mayo de 2026.

Editor de Sección:
Dr. Fernando Abasolo Pacheco



Copyright: © 2026 by the authors.
Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY NC ND) License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

Probability-of-presence maps generated in RStudio were reclassified in ArcGIS using the prevalence threshold of each model to produce potential distribution maps of the species. Model performance was evaluated using a set of metrics, including the Area Under the Curve (AUC), True Skill Statistic (TSS), Miller Calibration Slope, and cross-validation. High-risk agricultural areas in mainland Ecuador were delineated through spatial analyses of land cover and maps of the species' potential distribution. The results confirmed the value of GLM, GAM, and GBM models, used individually or in combination, as robust tools for mapping *S. frugiperda* risk in Ecuador. Priority agricultural areas were identified along the Coastal region and inter-Andean valleys of the Sierra. The results also support the hypothesis that high temperatures are crucial for the development and spread of the pest, whereas excessive rainfall acts as a limiting factor. Currently, the potential distribution of *S. frugiperda* is concentrated mainly in the Coastal region of the country. The information generated provides insight into the invasion potential of the species and establishes a baseline for future studies on pest dynamics in economically important crops. This contributes to the development of preventive integrated pest management strategies aimed at reducing risks to food security and minimizing negative impacts on agroecosystems.

Index words: precision agriculture, spatial analysis, performance metrics, agricultural pest, distribution prediction.

INTRODUCCIÓN

Los agroecosistemas enfrentan desafíos crecientes debido a la proliferación de insectos plaga que generan pérdidas económicas significativas a nivel mundial (Alphey y Bonsall, 2018). Entre estas plagas, *Spodoptera frugiperda* (J.E. Smith, 1797) (Lepidoptera: Noctuidae), conocido comúnmente como el gusano cogollero, destaca como un insecto polífago de alto impacto económico. Originario de América tropical y subtropical, su rápida expansión hacia África y Asia responde a su capacidad migratoria y adaptación a diversas condiciones ambientales (He *et al.*, 2021; Zhang *et al.*, 2021).

En América Latina, *S. frugiperda* representa una de las amenazas más importantes para el cultivo del maíz (*Zea mays*), con pérdidas de rendimiento que oscilan entre el 40% en Honduras y el 72% en Argentina (Early, González, Murphy y Day, 2018). Este insecto ataca diversas partes de la planta en su fase larval, incluyendo hojas, espigas y mazorcas, lo que ocasiona defoliación severa y afecta significativamente el potencial de crecimiento (Zhang *et al.*, 2021). Cuando la infestación de esta plaga alcanza el 20%, los cultivos pueden experimentar una reducción promedio de productividad del 60% (Gaibor, Rodríguez, Guevara, Reyes y Plaza, 2023). Además del maíz, *S. frugiperda* compromete otros cultivos de gran importancia agrícola a nivel mundial, como arroz, caña de azúcar, sorgo, tomate, papa, algodón y pastos, lo que subraya su impacto global en la seguridad alimentaria (Early *et al.*, 2018; He *et al.*, 2021). Sin embargo, a pesar de su importancia económica, el conocimiento sobre la distribución potencial de *S. frugiperda* en América del Sur sigue siendo limitado (Nagoshi *et al.*, 2019), lo que limita el alcance y la eficiencia de las estrategias de control, así como la efectividad de la agricultura de precisión.

En Ecuador, el maíz duro seco es un cultivo fundamental para la seguridad alimentaria y la economía agrícola, especialmente en la región Costa, donde representa el principal cultivo transitorio con una superficie sembrada de aproximadamente 300 000 ha (Zambrano *et al.*, 2019; Vélez, Betancourt y Mendoza, 2021). Sin embargo, la infestación por *S. frugiperda* ha alcanzado niveles alarmantes, provocando pérdidas de hasta el 88% en la producción de maíz durante brotes intensivos (INIAP, 2019). Esta situación se ve agravada por la escasez de herramientas eficaces para el control de plagas, lo que ocasiona pérdidas económicas significativas y afecta directamente a las familias de los productores (Vélez *et al.*, 2021). Las estrategias de manejo se han centrado principalmente en el uso de plaguicidas químicos, lo que no solo incrementa los costos de producción, sino que también conlleva riesgos para la salud humana y el medio ambiente (Vélez *et al.*, 2021; Gaibor *et al.*, 2023).

Esta difícil situación se puede mitigar gracias a la creciente disponibilidad de datos y al perfeccionamiento de técnicas estadísticas que han ampliado la capacidad para analizar patrones espaciales de presencia y ausencia de especies (Baloch, Fan, Haseeb y Zhang, 2020; Huang *et al.*, 2020; Junttila *et al.*, 2022; Munro, Montes, Gandhi y Poisson, 2022). Entre estas herramientas destacan los Modelos de Distribución de Especies (MDE), que han

evolucionado notablemente en las últimas décadas, dando lugar a una diversidad de enfoques, desde modelos deterministas tradicionales, como los Modelos Lineales Generalizados (GLM), hasta algoritmos avanzados basados en Inteligencia Artificial, como Random Forest y Máxima Entropía (Carlson, 2020). Actualmente, los MDE se han consolidado como herramientas clave en la biogeografía de la conservación, con aplicaciones que incluyen el estudio de especies en peligro, invasoras, hasta patógenos y plagas (Li y Wang, 2013). Al correlacionar datos de presencia con variables ambientales, los MDE permiten identificar zonas de alto riesgo y diseñar estrategias de manejo más eficientes. Además, contribuyen significativamente a mejorar la agricultura de precisión al identificar las zonas más aptas para el cultivo de determinadas especies agrícolas según las condiciones ambientales locales. Ayudan a predecir la distribución potencial de plagas agrícolas, lo que permite tomar decisiones preventivas y focalizadas; al conocer las condiciones óptimas para cada cultivo, se evita el uso excesivo de agua, fertilizantes o pesticidas en zonas no aptas. Se pueden simular escenarios futuros para ver cómo cambiaría la distribución de cultivos o plagas, ayudando a planificar estrategias de adaptación y apoya la planificación territorial agrícola, definiendo qué zonas son más aptas para qué tipo de producción.

Sin embargo, la diversidad de enfoques disponibles para la modelación estadística plantea el desafío de identificar el modelo más preciso y confiable para cada caso. Esto hace necesaria una comparación sistemática de modelos con distintos niveles de complejidad y enfoques metodológicos, con el fin de optimizar las predicciones y orientar acciones de manejo más eficientes (Bradie y Leung, 2017; Carlson, 2020; Li y Wang, 2013).

Dado este panorama, a través de este trabajo de investigación se evaluó la eficacia de diferentes métodos estadísticos en la modelación de la distribución potencial de *S. frugiperda*, para identificar las variables o características del nicho de la especie. Con base en esta modelación, se confrontaron los sitios aptos para la especie según estas características y el riesgo para las zonas agrícolas en Ecuador continental. Se prevé que la distribución de *S. frugiperda* se limite principalmente a regiones cálidas y húmedas, especialmente en aquellas zonas propicias para el cultivo de maíz y otros cereales, que constituyen sus principales hospederos. Los modelos de distribución generados proporcionarán una base científica que permitirá a las entidades competentes comprender el potencial de invasión de *S. frugiperda* y planificar medidas preventivas y eficaces para el manejo de plagas. Estos modelos predictivos contribuirán a proteger cultivos estratégicos para la economía nacional, garantizar la seguridad alimentaria y reducir los impactos negativos en el ecosistema, fomentando un desarrollo sostenible. Además, este estudio representa uno de los pocos realizados en Ecuador que comparan diferentes enfoques estadísticos para predecir la distribución de una plaga polífaga, lo que refuerza los estudios biogeográficos y establece una línea base para futuros proyectos de investigación sobre plagas en cultivos de interés.

MATERIALES Y MÉTODOS

Ecuador continental se localiza al noroeste de América del Sur, entre los 01° 28' N y 05° 01' S; y desde los 75° 11' en la planicie Amazónica hasta los 81° 01' O (Figura 1). Limita al norte con Colombia, al sur y este con Perú, y al oeste con el océano Pacífico. El territorio continental abarca una superficie de aproximadamente 248 356 km². La cordillera de los Andes atraviesa el país, dividiéndolo en tres regiones geográficas principales, cada una con características distintivas de topografía, clima, vegetación y población: la Costa o llanuras costeras, la Sierra o montañas andinas y el Oriente o selva amazónica (Portilla, 2018).

Recopilación y Limpieza de Registros de Presencia de la Especie

Se recopilaron 11 411 registros de presencia georreferenciados de *S. frugiperda* mediante diversas bases de datos. A nivel mundial, se obtuvieron 7809 registros a través de las plataformas Global Biodiversity Information Facility (GBIF, 2025) y Centre for Agriculture and Bioscience International (CABI, 2025). Para Ecuador se recopilaron 3602 registros de a partir de diversas fuentes nacionales e internacionales. Del total nacional, el 96.06% (3460 registros) proviene de la Agencia de Regulación y Control Fito y Zoonosanitario (AGROCALIDAD), mientras que el 3.94% (142 registros) corresponde a bases como (GBIF), (CABI), iNaturalist Ecuador y a informes de proyectos de investigación realizados entre 2016 y 2021 publicados en repositorios de universidades en Ecuador. El conjunto de registros de presencia del gusano cogollero se importaron al software ArcGIS 10.8 (ESRI, 2020) para la respectiva validación dentro del mapa base (Figura 1).

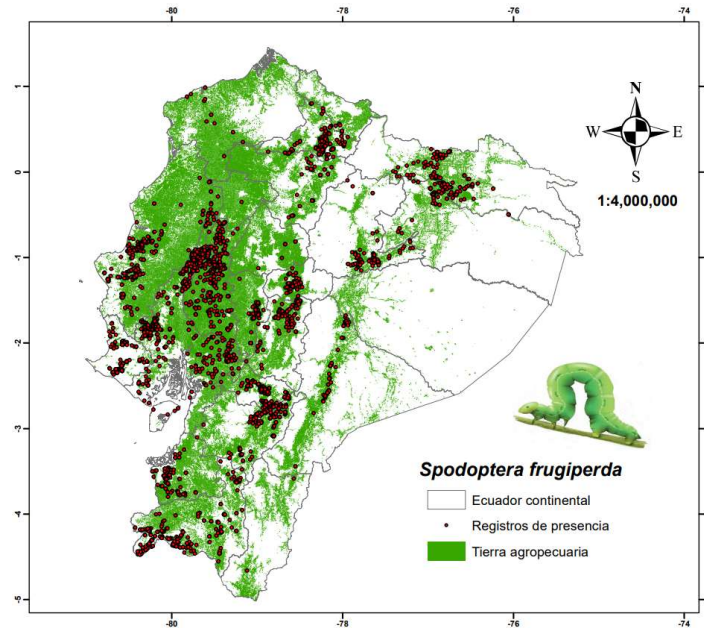


Figura 1. Registros de presencia de *Spodoptera frugiperda* en Ecuador continental para modelar la distribución geográfica potencial a partir de varios enfoques estadísticos.

Figure 1. Records of *Spodoptera frugiperda* occurrence in continental Ecuador to model potential geographic distribution using various statistical approaches

Los registros sin información geográfica, o con errores obvios como coordenadas incompletas, ubicaciones en el océano y desajustes entre metadatos y coordenadas se excluyeron del análisis mediante limpieza directa en ArcGIS (ESRI, 2020). Posteriormente, se llevó a cabo una segunda limpieza de los registros duplicados a 0.008333° (aproximadamente 1 km) utilizando el paquete Niche Toolbox en RStudio (Osorio-Olvera *et al.*, 2020). Este proceso tuvo como objetivo reducir los sesgos espaciales a gran escala, facilitando una estimación más precisa de las características del nicho (Fourcade, Besnard y Secondi, 2018). Finalmente, quedaron 7764 registros mundiales y 3370 registros de presencia a nivel nacional para construir los modelos predictivos (Figura 1). Además, se generaron 3300 puntos aleatorios como pseudoausencias en áreas donde no se ha registrado presencia de la especie, ni cultivos hospederos en Ecuador, con una distancia mínima de 1 km entre estos, tratando de establecer una proporción 1:1 con los registros de presencia (Barbet-Massin, Jiguet, Albert y Thuiller, 2012). Estos puntos fueron creados para ajustar los Modelos de Distribución de Especies, con excepción de MaxEnt que usó 20 000 puntos de fondo en el área de accesibilidad de la especie definida para Ecuador continental (Phillips y Dudík, 2008).

Variables Climáticas y Topográficas

Se obtuvieron como predictores ambientales 19 variables bioclimáticas (Bio1-Bio19) y la variable elevación de la base WorldClim 2.1 (Fick y Hijmans, 2017). Estas variables, con una resolución espacial de 30 segundos de arco (~ 1 km) y un período de referencia de ~ 1970-2000, capturan factores climáticos extremos o limitantes en función de la variación en la precipitación y la temperatura. Son predictores cruciales para comprender los requerimientos ecológicos de las especies.

La información bioclimática se obtuvo para cada registro de presencia y para los puntos aleatorios utilizando la herramienta Extract MultiValues to Points de la caja de herramientas Spatial Analyst en ArcGIS 10.8 (ESRI, 2020). Posteriormente, se resumieron los datos con estadística descriptiva y un intervalo de confianza del 95% mediante el software XLSTAT (Lumivero, 2024). Los datos ambientales en los sitios de presencia y puntos aleatorios fueron descritos a través de valores mínimos, máximos, promedios y desviaciones estándar, con el objetivo de describir detalladamente las diferentes condiciones ambientales en los sitios con presencia y distribución de la especie en el espacio geográfico de estudio, así como el área que no ha sido ocupada por esta.

Al conjunto de variables se les aplicó una prueba de correlación de Spearman. Se seleccionaron las variables menos correlacionadas, con un nivel de significancia del 5% y un intervalo de confianza del 95% (Dormann *et al.*, 2013) para disminuir la multicolinealidad. En este proceso se excluyeron las variables con la correlación más alta (> 0.8). Además, como segundo filtro para reducir la multicolinealidad entre las variables climáticas se utilizó el Análisis de Componentes Principales (ACP), donde se empleó el peso de cada variable en relación con los componentes para determinar su importancia (Waldock *et al.*, 2022). El análisis se ejecutó utilizando la correlación de Spearman, el método de rotación de Varimax y la normalización de Kaiser. Finalmente, las variables seleccionadas para los siguientes análisis de modelación fueron la Bio4: Estacionalidad de la temperatura, Bio5: Temperatura máxima del mes más cálido, Bio7: Intervalo anual de temperatura, Bio15: Estacionalidad de las precipitaciones, Bio16: Precipitaciones del trimestre más húmedo y Bio19: Precipitación del trimestre más frío.

Por la falta de normalidad en los datos, se ejecutó la prueba no paramétrica Kruskal-Wallis para evaluar diferencias significativas de cada variable bioclimática entre las tres categorías de puntos: a nivel mundial, presencia y aleatorios en Ecuador. Se seleccionó el coeficiente de Spearman y se ejecutaron 10 000 simulaciones Monte Carlo con un intervalo de confianza para el valor-p al 99%. Específicamente para las comparaciones múltiples por pares se evaluó mediante el procedimiento de Dunn/Prueba bilateral.

Modelo de Nicho Ecológico

Siguiendo las recomendaciones de Owens y Rahbek (2023) sobre la importancia de utilizar datos ambientales en tres dimensiones para mejorar la precisión de los Modelos de Nicho Ecológico (MNE), se empleó el paquete NicheToolBox (ntbox) en RStudio para estimar el nicho ecológico tridimensional de la especie en su espacio ambiental, a través de elipsoides de volumen mínimo como modelo y acompañándolas de estadísticas adicionales (Osorio-Olvera *et al.*, 2020). Para ello, se utilizaron los registros de presencia y tres variables climáticas de mayor influencia (Bio7: Intervalo anual de temperatura, Bio15: Estacionalidad de las precipitaciones, Bio16: Precipitaciones del trimestre más húmedo) según el modelo lineal generalizado calibrado con las variables seleccionadas y menos correlacionadas luego de los análisis estadísticos previos.

Para la comparación y calibración de varios modelos de nicho ecológico de la especie se utilizó un enfoque de conjunto que integró seis métodos de modelado de la distribución con distintas complejidades: Modelos Lineales Generalizados (GLM), Modelos Aditivos Generalizados (GAM), Bosques Aleatorios (Random Forest, RF), Modelos Potenciados Generalizados (Generalized Boosted Model, GBM), Árboles de Regresión Aditivos Bayesianos (Bayesian Additive Regression Trees, BART) y Máxima Entropía (MaxEnt). Los cinco primeros métodos generan probabilidades de presencia, lo cual es crucial para una combinación evaluable de predicciones provenientes de diferentes enfoques. Por su parte, MaxEnt estima directamente la favorabilidad del píxel para la presencia de la especie, permitiendo la comparación con los métodos basados en probabilidad mediante la resta de la prevalencia. Los modelos GLM, GAM, MaxEnt y RF son ampliamente utilizados en los MDE (Peterson, Soberón, Pearson, Anderson y Martínez, 2011), mientras que BART representa un método novedoso con resultados prometedores en este campo (Carlson, 2020; Baquero *et al.*, 2021). Todos los modelos se instalaron en el software R, y se usaron paquetes especializados: "gam" (Hastie, 2023), "randomForest" (Liaw y Wiener, 2002), "embarcadero" (Carlson, 2020), "fuzzySim" (Barbosa, Real, Muñoz y Brown, 2013), "maxent" (Phillips, Dudík y Schapire, 2004), "gbm" (Natekin y Knoll, 2013) y "terra" para la calibración de estos. En este proceso, se integraron los registros de presencia de la especie y las variables bioclimáticas reducidas mediante la correlación de Spearman, garantizando una calibración precisa de los modelos.

Los mapas de favorabilidad ambiental para la presencia de la especie según los seis MDE, se convirtieron en mapas binarios de presencia (1) y ausencia (0). Este procesamiento se realizó en el software ArcGIS 10.8 (ESRI, 2020) y se usó como umbral de corte el valor de prevalencia de los modelos para reducir la cantidad de polígonos y evitar sobreajustes. Esta transformación permitió predecir áreas geográficas con condiciones ambientales adecuadas para la distribución potencial de la especie, según su nicho ecológico, sin limitarse a las áreas donde ya se ha registrado su presencia.

Evaluación. El rendimiento de cada algoritmo de modelado se evaluó con el paquete R "modeva" versión 2.0 (Barbosa, Real, Muñoz y Brown, 2013), con los datos de entrenamiento de los modelos. Dado que la literatura sugiere la utilización de diversas métricas para abordar diferentes perspectivas del rendimiento del modelo (Lake, Briscoe y Moeller, 2020), se seleccionó un conjunto integral de estas entre las que destacan: True Skill

Statistic (TSS), que evalúa el rendimiento en la clasificación considerando la proporción de presencias y ausencias clasificadas correctamente, usa la prevalencia de calibración como umbral (Allouche, Tsoar y Kadmon, 2006); Área Bajo la Curva (AUC), que mide la capacidad general de discriminación del modelo para diferenciar entre presencias y ausencias; y la pendiente de calibración de Miller, que analiza la confiabilidad del modelo evaluando la desviación entre las probabilidades predichas y las frecuencias observadas de ocurrencia (Miller, Hui y Tierney, 1991; Pearce y Ferrier, 2000).

Validación cruzada. La separación espacial de los conjuntos de datos de calibración y validación permite evaluar si los modelos funcionan bien tanto en áreas cercanas como en áreas más distantes, lo cual es importante si los modelos se extrapolan en el espacio o en el tiempo (Valavi, Elith, Lahoz y Guillera, 2019). Para cada algoritmo de modelación, se construyeron cuatro MDE diferentes, en los que un conjunto de datos se dejó fuera del modelo de forma secuencial, y se usó para la validación de las predicciones del modelo (Fielding y Bell, 1997). Los datos se dividieron inicialmente en cuatro conjuntos de bloques de validación cruzada: las celdas de la cuadrícula del área de estudio se segmentaron en cuatro grupos con el paquete "blockcv" versión 2.1.1 de R (Valavi *et al.*, 2019), con una selección sistemática y asignación de bloques espaciales en cuatro conjuntos de 10 × 10 km². La validación cruzada de bloques es más confiable que la validación cruzada aleatoria, la cual subestima el error de predicción y da como resultado una selección errónea del modelo (Araújo, Pearson, Thuiller y Erhard, 2005; Valavi *et al.*, 2019). Los valores de las métricas se promediaron en los cuatro conjuntos de validación cruzada para cada método de modelado. Para el AUC se fijó como criterio de aceptabilidad 0.7, lo que delimita predicciones deficientes (Rapacciuolo *et al.*, 2012), ya que puede variar de 0 a 1. Para TSS que varía entre -1 a 1, el criterio de aceptabilidad se fijó en 0.4. Los valores de AUC y TSS <0.4 se consideran pobres, 0.4-0.8 útiles, y >0.8 excelentes. Para la pendiente de calibración de Miller, se usó un criterio de aceptabilidad de 0.5 por encima o por debajo del valor ideal de 1.

Después de la validación cruzada, los mejores modelos se ajustaron nuevamente utilizando el conjunto de datos completo (Araújo *et al.*, 2019). Los valores de probabilidad se convirtieron a favorabilidad, que es una función de la probabilidad de presencia y la relación presencia-ausencia de las especies en la muestra modelada (Real, Barbosa y Vargas, 2006). Esto eliminó el efecto de la prevalencia en los valores predichos, lo que hace que las predicciones sean medibles y directamente comparables entre métodos de modelación (Real, Barbosa y Bull, 2017). Para resumir las predicciones del modelo y medir su consenso, se usó la función "prcomp" del paquete "stats" en R.

Zonas de Cultivos Susceptibles a la Distribución de la Plaga

Para identificar las zonas de posible riesgo por la presencia o expansión de *S. frugiperda* en los cultivos más vulnerables a su coexistencia, se empleó la capa de uso de suelo del Ecuador continental del 2022. De este mapa, mediante el software ArcGis (ESRI, 2020) se extrajo la categoría de agricultura y sus subcategorías, incluyendo cultivos perennes, cultivos de ciclo corto y clasificaciones más específicas asociadas a los cultivos hospederos de la plaga. Con esta capa específica de cultivos y los mapas de distribución potencial de la plaga, se realizaron análisis espaciales de superposición que identificaron las zonas de coexistencia entre cultivos-plaga (Ferrer-Sánchez, Mafaldo, Plasencia-Vázquez y Urdánigo, 2022). Finalmente, se calculó el área (km²) de cada polígono que predice la distribución potencial de la especie en los cultivos susceptibles.

RESULTADOS Y DISCUSIÓN

Las variables climáticas se diferenciaron entre las zonas con presencia y ausencia de *S. frugiperda*, entre tres niveles zonales: presencia mundial, presencia en Ecuador y ausencia en Ecuador (puntos aleatorios en la zona de ausencia). Sin embargo, la elevación a la cual se encontraron los registros de presencia en Ecuador (913.38 ± 1159.98) no difiere respecto a los registros a nivel mundial (692.48 ± 742.47 ; $p = 0.322$). La temperatura media anual (Bio1; 21.36 ± 5.07 ; $p < 0.0001$), la isothermalidad (Bio3; 81.41 ± 5.25 ; $p < 0.0001$), la temperatura mínima en el mes más frío (Bio6; 15.18 ± 5.26 ; $p < 0.0001$), la temperatura media del trimestre más frío (Bio11; 20.45 ± 4.87 ; $p < 0.0001$), la precipitación media anual (Bio12; 1318.40 ± 1010.24 ; $p < 0.0001$), la precipitación del mes más húmedo (Bio13; 244.93 ± 136.53 ; $p < 0.0001$), la estacionalidad de la precipitación (Bio15; 82.57 ± 44.64 ; $p < 0.0001$) y la precipitación del trimestre más húmedo (Bio16; 648.34 ± 394.56 ; $p < 0.0001$) fueron mayores en las zonas con presencia de *S. frugiperda* en Ecuador respecto a la presencia en el rango mundial. La isothermalidad (85.88 ± 3.54) y todas las variables de precipitación con excepción de la estacionalidad (41.49 ± 24.75), fueron mayores en los puntos aleatorios respecto a las zonas con presencia en Ecuador ($p < 0.0001$; Figura 2).

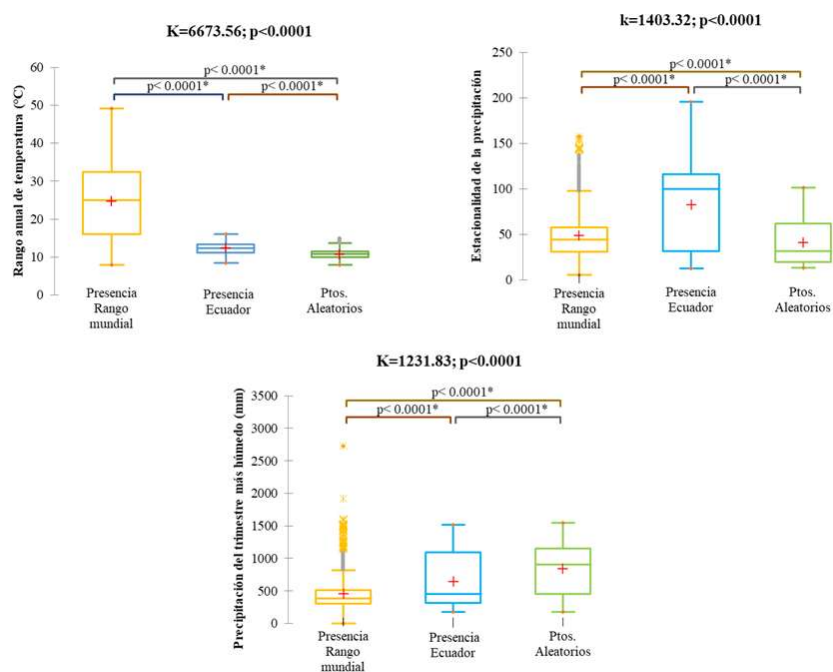


Figura 2. Comparación climática entre sitios con presencia/ausencia (puntos aleatorios) de *Spodoptera frugiperda* en Ecuador y con presencia a nivel mundial. Las variables climáticas representadas fueron las de mayor importancia en el modelo de nicho ecológico calibrado para la especie en este estudio.
Figure 2. Climate comparison between sites with presence/absence (random points) of *Spodoptera frugiperda* in Ecuador and with presence worldwide. The climate variables represented were those of greatest importance in the ecological niche model calibrated for the species in this study.

El ACP explicó más del 66% de la variabilidad total en los primeros dos componentes, lo que sugiere que estas dos dimensiones capturan patrones significativos en los datos iniciales. El espacio ambiental dimensional para la especie indicó que el área climáticamente favorable de los tres niveles zonales de presencia y ausencia de la plaga presenta una distribución espacial amplia (Figura 3). El espacio ambiental del componente F1 se encuentra constituido por los puntos de presencia y ausencia aleatoria en Ecuador, los cuales presentaron una distribución espacial amplia pero opuesta. Sin embargo, sus condiciones climáticas solo se asemejan en un extremo, puesto que los puntos de ausencia aleatoria se basan en las zonas con escasos registros de presencia de la plaga. Por otra parte, la nube de puntos de rango mundial se ubicó hacia las condiciones ambientales del componente F2, distanciada totalmente de los demás puntos, lo que indica que el área climática favorable difiere con las condiciones climáticas donde se encuentra la plaga en Ecuador. Esto refleja que la especie tiene una distribución geográfica y plasticidad ecológica y climática amplia, lo que implica que puede adaptarse a diferentes condiciones ambientales a nivel nacional y mundial (Figura 3).

El análisis de las cargas factoriales (≥ 0.8) del ACP reveló patrones significativos en la asociación entre las variables originales y los Componentes Principales (CP) obtenidos (Figura 3). En el espacio ambiental del primer CP (F1), destacaron variables de temperatura y precipitación, como temperatura mínima del mes más frío (Bio 6), rango anual de temperatura (Bio7), temperatura media del trimestre más frío (Bio11), precipitación del mes más lluvioso (Bio13) y precipitación del trimestre más húmedo (Bio16), que exhiben una carga factorial sustancial. Esto sugiere que estas variables desempeñan un papel crucial en la variabilidad capturada por dicho componente. Sin embargo, en el segundo CP (F2), las variables de más peso solo son de temperatura: temperatura máxima del mes más cálido (Bio5) y temperatura media del trimestre más cálido (Bio10) (Figura 3).

Del conjunto de variables bioclimáticas analizadas (Figura 4) para los registros de presencia en Ecuador, el rango anual de temperatura (Bio7) tuvo la mayor influencia en el modelado de la distribución de *S. frugiperda*, con un impacto superior al 40%. Este resultado sugiere que la especie en Ecuador se adapta mejor a climas con temperaturas relativamente constantes, sin fluctuaciones extremas a diferencia de lo observado a nivel mundial (Figura 2). Otras variables también contribuyeron significativamente, como la estacionalidad de la precipitación (Bio15) con aproximadamente un 37% y la precipitación del trimestre más húmedo (Bio16) con un 10% (Figura 4).

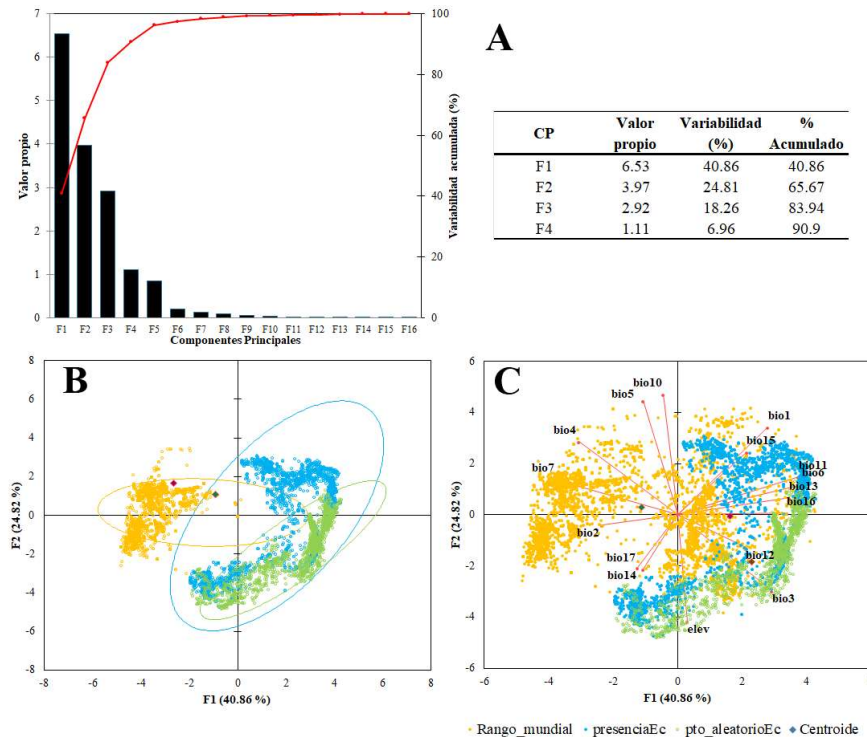


Figura 3. Análisis de Componentes Principales y variabilidad en el conjunto de datos climáticos en sitios con presencia/ausencia de *Spodoptera frugiperda* en Ecuador y con presencia a nivel mundial. A: Resultados del análisis; B: Representación de las observaciones en el espacio ambiental de los componentes 1 y 2, por grupos de datos mundiales y nacionales (presencia/ausencia); C: Representación de las observaciones en conjunto con las variables climáticas que estructuran los datos.

Figure 3. Principal Component Analysis and variability in the climate dataset at sites with presence/absence of *Spodoptera frugiperda* in Ecuador and with presence worldwide. A: Analysis results; B: Representation of observations in the environmental space of components 1 and 2, by global and national data groups (presence/absence); C: Representation of observations together with the climate variables that structure the data.

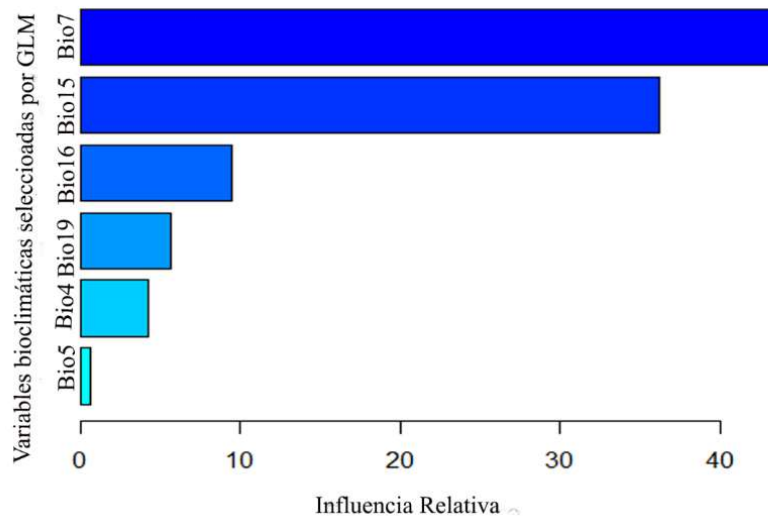


Figura 4. Influencia de las variables bioclimáticas en la construcción de los modelos predictores de la distribución potencial de *Spodoptera frugiperda*.
Figure 4. Influence of bioclimatic variables in the construction of predictive models of the potential distribution of *Spodoptera frugiperda*.

Espacio Ambiental

La representación del nicho ecológico de *S. frugiperda* en el espacio ambiental, basado en el rango anual de temperatura, estacionalidad de la precipitación y precipitación del trimestre más húmedo (Figura 5A), mostró preferencias por climas con una variación térmica moderada a lo largo del año (Bio7: 8.40 - 16.10 °C de variación anual), típica de la costa ecuatoriana y climas tropicales, y una marcada estacionalidad en las precipitaciones (Bio15: 12.70 - 195.78 mm). Esto refleja su tolerancia a distintos regímenes de variabilidad hídrica anual. Además, estuvo presente en sitios con precipitaciones del trimestre más húmedo (Bio16) con niveles moderados (173 - 1514 mm). Respecto al nicho ecológico segmentado (Figura 5B), reveló dos subconjuntos de registros de presencia asociados a condiciones ambientales diferentes debido a las regiones de Ecuador continental. Los elipsoides mostraron una leve superposición, lo que indica áreas de transición ambiental donde la especie se adapta a una gama más amplia de condiciones. En general, los registros se concentraron en climas con variaciones térmicas moderadas y precipitaciones intermedias, destacando la plasticidad ecológica de *S. frugiperda* para adaptarse en diversos ambientes.

Distribución Geográfica Potencial

El mapa de favorabilidad ambiental para la presencia de *S. frugiperda* en el espacio geográfico de Ecuador continental, generado por el modelo GLM (Figura 6A), mostró una alta favorabilidad (> 0.90) en áreas limitadas de las regiones Costa y Sierra, con predominio en las provincias del centro y sur costero (Guayas, Los Ríos, Manabí y Loja). En el resto del territorio continental la favorabilidad fue homogéneamente moderada (>0.40). Por su parte, el modelo GAM (Figura 6B) presentó una favorabilidad heterogénea, con mayores áreas de alta favorabilidad (> 0.90) en el centro y sur de la Costa, mientras que en el norte de esta región predominaron áreas de ausencia. En la Sierra también hubo favorabilidad ambiental (> 0.80), a excepción de las zonas con relieve más complejo que evidencian muy baja favorabilidad (< 0.20). Asimismo, el modelo identificó favorabilidad moderada en la región Oriente (> 0.40), especialmente en la zona central amazónica (provincia Sucumbíos). MaxEnt mostró un patrón similar al de GAM (Figura 6C), con alta favorabilidad en la Costa y Sierra, y menor en el Oriente (< 0.20).

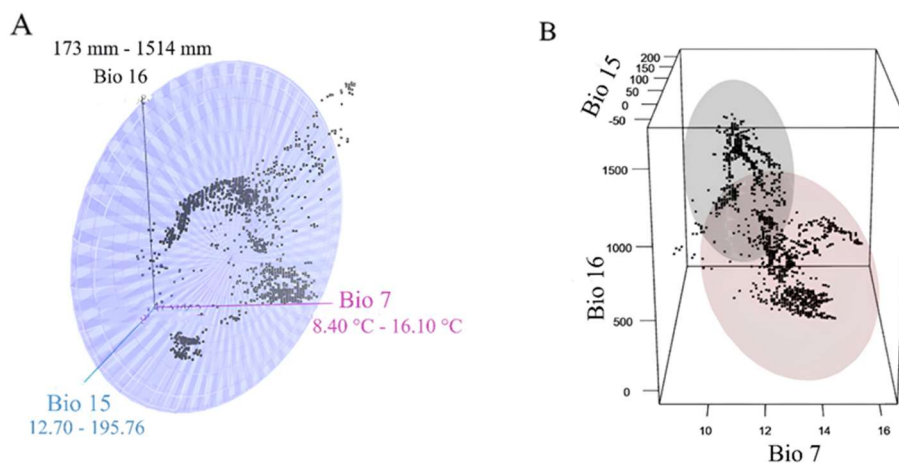


Figura 5. Nicho ecológico de *Spodoptera frugiperda* en el espacio ambiental de Ecuador continental. Nicho ecológico de volumen mínimo (A), Nicho ecológico de volumen mínimo segmentados en clústeres (B). En cada eje de las figuras, se encuentran los mínimos y máximos de cada variable climática: Rango anual de temperatura (Bio7), Estacionalidad de la precipitación (Bio15) and Precipitación del trimestre más húmedo (Bio16). El clúster rosado sugiere presencia en climas con mayor precipitación en el trimestre más húmedo, mientras que el gris representa zonas con menor precipitación.

Figure 5. Ecological niche of *Spodoptera frugiperda* in the environmental space of continental Ecuador. Ecological niche of minimum volume (A), Ecological niche of minimum volume segmented into clusters (B). On each axis of the figures, the minimum and maximum of each climatic variable are found: Annual temperature range (Bio7), Seasonality of precipitation (Bio15) and Precipitation of the wettest quarter (Bio16). The pink cluster suggests presence in climates with higher precipitation in the wettest quarter, while the gray cluster represents areas with lower precipitation.

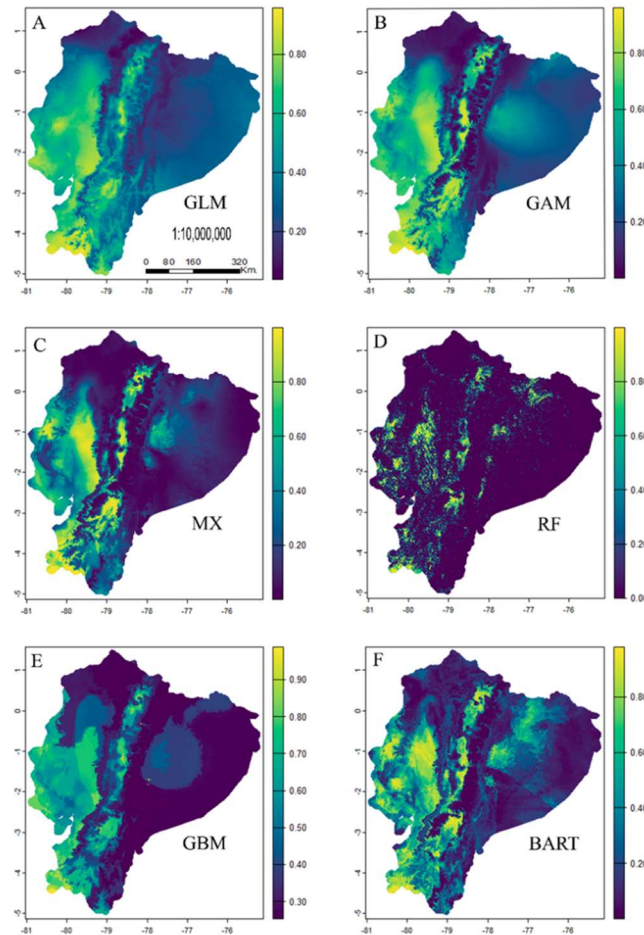


Figura 6. Mapas de favorabilidad ambiental para la presencia de *Spodoptera frugiperda* en Ecuador continental. GLM = modelo lineal generalizado; GAM = modelo aditivo generalizado; MX = MaxEnt (máxima entropía); RF = bosques aleatorios; GBM = modelos potenciados generalizados; BART = árboles de regresión aditivos bayesianos.

Figure 6. Environmental favorability maps for the presence of *Spodoptera frugiperda* in continental Ecuador. GLM = generalized linear model; GAM = generalized additive model; MX = MaxEnt (maximum entropy); RF = random forests; GBM = generalized boosted models; BART = bayesian additive regression trees.

El modelo RF (Figura 6D) presentó un patrón muy fragmentado, con áreas puntuales de alta favorabilidad (> 0.80) ubicadas principalmente en la Costa y la Sierra, y en menor proporción en el Oriente. Por otro lado, el modelo GBM (Figura 6E) reflejó una favorabilidad que varía de moderada a muy baja ($0.70 < 0.30$) en el Oriente y en el norte de la región Costa. En contraste, en el centro y sur de la Costa, así como en la Sierra, la favorabilidad aumenta hasta valores altos (> 0.90), principalmente en el extremo sur (provincia Loja). Finalmente, el modelo BART (Figura 6F) presentó una distribución de la favorabilidad más homogénea en comparación con los demás modelos, destacándose niveles altos (> 0.80) en las regiones Costa y Sierra.

Según los mapas binarios de presencia de *S. frugiperda*, el modelo MaxEnt (Figuras 7C) predijo la mayor extensión de distribución ($244\,389.69\text{ km}^2$), equivalente al 98.5% del territorio. Esto sugiere que la especie posee una alta capacidad de adaptación climática a las diferentes regiones del país. Sin embargo, hay mucha sobrepredicción en este resultado. Según Elith* *et al.* (2006), este modelo es una herramienta clave para evaluar riesgos de invasión biológica; pero puede sobrestimar la distribución potencial de la especie, ya que no considera las interacciones bióticas entre especies y es sensible a los datos de presencia utilizados (Lissovsky y Dudov, 2021).

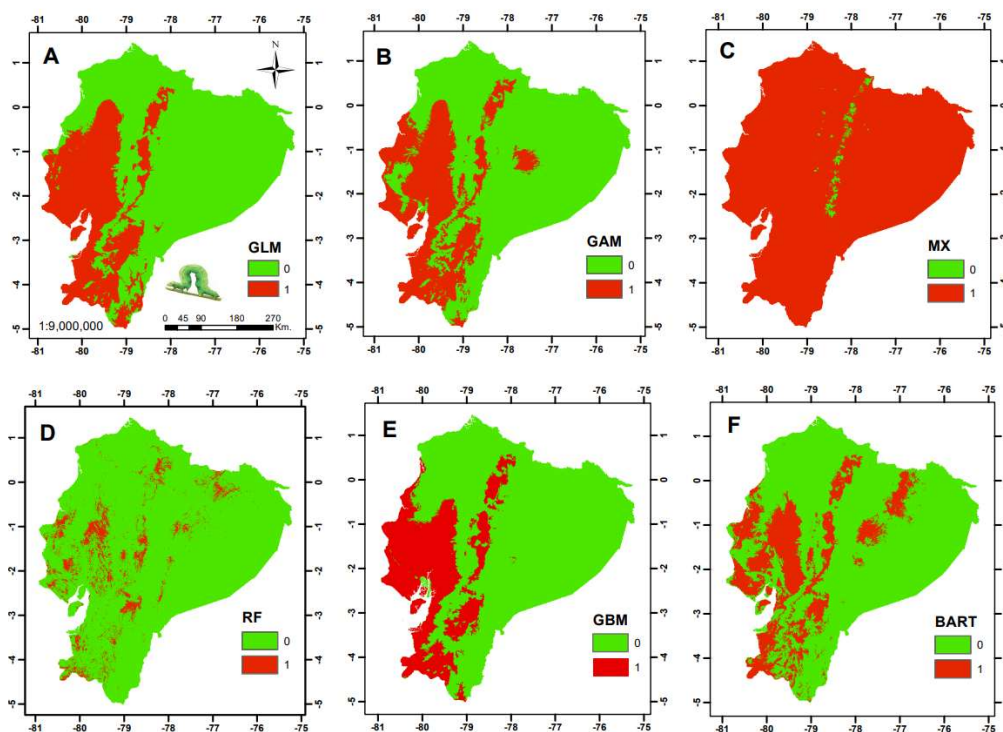


Figura 7. Distribución geográfica potencial de *Spodoptera frugiperda* en Ecuador continental. Presencia = 1; ausencia = 0; GLM = modelo lineal generalizado; GAM = modelo aditivo generalizado; MX = MaxEnt (máxima entropía); RF = bosques aleatorios; GBM = modelos potenciados generalizados; BART = árboles de regresión aditivos bayesianos.

Figure 7. Potential geographic distribution of *Spodoptera frugiperda* in continental Ecuador. Presence = 1; absence = 0; GLM = generalized linear model; GAM = generalized additive model; MX = MaxEnt (maximum entropy); RF = random forests; GBM = generalized boosted models; BART = bayesian additive regression trees.

En contraste, el modelo RF predijo la menor área de presencia, con solo 16 677.79 km² (6.72%) distribuidos en las tres regiones del territorio (Figuras 7D), lo que implica un alto sobreajuste. Este método es ampliamente utilizado en estudios sobre insectos plaga, demostrando resultados sobresalientes (XiangHui et al., 2017; Hentschel, Möller, Wenning, Degenhardt y Schröder, 2018; Junttila et al., 2022). Incluso, Zhao, Xiao, Shen y Li (2022) sugieren que el algoritmo RF puede superar ligeramente el desempeño del algoritmo MaxEnt. Sin embargo, a pesar de su elevado potencial, algunos estudios han señalado ciertas limitaciones de RF, como el sesgo cuando las covariables están altamente correlacionadas (Strobl, Boulesteix, Kneib, Augustin y Zeileis, 2008) como es el caso de las variables climáticas, y su incapacidad para extrapolar más allá de los datos de entrenamiento (sobreajuste) (Mcinerney y Nieuwenhuis, 2009). Aunque en este estudio se hizo un análisis de correlación para evitar la multicolinealidad entre las variables climáticas, estas limitantes podrían explicar la escasa predicción que hizo RF más allá de la zona de calibración del modelo. Los demás modelos presentaron estimaciones intermedias, con mayor expansión en las regiones Costa y Sierra. Estos se catalogan como predictores moderados: GLM con 74 875.31 km² (30.17%; Figura 7A); GAM con 72 244.38 km² (29.11%; Figura 7B); GBM 64 167.06 km² (25.85%; Figura 7E) y BART con 56 372.48 km² (22.71%; Figura 7F).

Spodoptera frugiperda mostró preferencias por variaciones térmicas moderadas y precipitaciones intermedias; sin embargo, por su naturaleza euriadaptativa se adapta y establece en una amplia variedad de condiciones climáticas, como lo demuestra la fuerte infestación registrada en la región costera de Ecuador durante el invierno de 2017 (INIAP, 2019). Las regiones Costa y Sierra ecuatorianas, caracterizadas por una marcada diversidad climática, ofrecen un amplio rango de condiciones ambientales que influyen significativamente en la distribución y dinámica poblacional de esta plaga. En la región Costa, las temperaturas medias anuales cálidas oscilan entre 23 y 26 °C, superando los 30 °C durante los meses más cálidos, mientras que las precipitaciones estacionales varían entre 500 y 2000 mm anuales (Portilla, 2018). Estas condiciones son adecuadas para el desarrollo de *S. frugiperda*, ya que las temperaturas entre 19 °C y 23 °C incrementan significativamente la probabilidad de

aparición de la especie, mientras que temperaturas de hasta 35 °C optimizan su tiempo de desarrollo (Cokola *et al.*, 2020; Early *et al.*, 2018). Además, la región Costa, con su limitada cobertura forestal, se alinea con la tendencia global observada de mayor presencia de *S. frugiperda* en áreas abiertas y cálidas (Early *et al.*, 2018).

Por otro lado, la Sierra, caracterizada por temperaturas más frías debido a la altitud, presenta valles interandinos con temperaturas moderadas que pueden superar los 25 °C y precipitaciones anuales de entre 500 y 1500 mm (Portilla, 2018). Estas condiciones, aunque menos favorables que las de la Costa, permiten la presencia de *S. frugiperda* en áreas específicas. En contraste, la región Oriente tiene altos niveles de precipitación anual (Portilla, 2018), lo que explica la baja favorabilidad para la plaga. Según Cokola *et al.* (2020), áreas con parámetros pluviométricos elevados, no son favorables para esta plaga. Aunque la humedad es crucial para su desarrollo, precipitaciones excesivas, que superen los 1600 mm pueden resultar letales para las larvas y pupas de la plaga (Early *et al.*, 2018).

Los modelos GLM, GAM, MX y BART mostraron una alta consistencia en la identificación de las zonas con mayor idoneidad ambiental para *S. frugiperda* en el territorio continental ecuatoriano. Aunque hubo pequeñas discrepancias en la delimitación exacta de estas áreas, estas variaciones refuerzan la robustez de los hallazgos generales y destacan la capacidad de los modelos para capturar patrones esenciales en la distribución de la especie. Este nivel de concordancia entre diferentes enfoques metodológicos no solo valida la confiabilidad de los resultados obtenidos, sino que también incrementa la confianza en la precisión de las áreas identificadas como favorables para la plaga (Elith *et al.*, 2011; Muscarella *et al.*, 2014; Morales-Barbero y Vega, 2019).

Evaluación de los modelos. El modelo con el rendimiento más alto, según el conjunto de métricas evaluadas, fue Random Forest (RF), con una tasa de clasificación correcta (CCR) de 0.98, sensibilidad (Sensitivity) de 1.0, especificidad (Specificity) de 0.98, precisión de 0.06, tasa de verdaderos positivos (Recall) de 1.0 y True Skill Statistic (TSS) de 0.99. Este modelo con métricas perfectas en calibración pero que predice casi nula distribución geográfica (AUC < 0.7 en los 4 bloques) es un caso de sobreajuste extremo a los datos de entrenamiento. Por otro lado, el modelo con el rendimiento más bajo fue MaxEnt (MX), que presentó un CCR de 0.02, especificidad de 0.01 y precisión de 0.00. Los demás modelos demostraron un desempeño bueno, siendo capaces de predecir la distribución de la especie con un grado de confiabilidad y mejor que un modelo al azar (Figura 8).

De acuerdo con el AUC, el modelo RF presentó una capacidad de discriminación muy alta (1.0), seguido por BART (AUC = 0.90), para los datos de calibración solamente. El modelo GLM tuvo una capacidad de discriminación aceptable (0.77), mientras que GAM, GBM y MX mostraron una capacidad discriminatoria buena con valores de 0.83, 0.83 y 0.86, respectivamente. Sin embargo, el bajo CCR de MX implica que los resultados del modelo son malos. En relación con la métrica pendiente de calibración de Miller, el modelo con rendimiento sobresaliente fue GLM. Los modelos GAM, BART y GBM mostraron un buen rendimiento (pendiente cercana a 1), con una ligera sobreestimación en las predicciones. Por otro lado, el modelo MX subestimó las predicciones (0.64), solo el 64% de los casos con esa predicción realmente ocurren por lo que el modelo sobrestima, mientras que RF presentó los peores resultados (46.98), no confiables, con problemas de sobreajuste (Figura 9). Confiar en una sola métrica puede ser engañoso, ya que las métricas individuales tienden a seleccionar modelos con mal desempeño.

Validación cruzada. En todos los conjuntos de bloques evaluados, los modelos GLM, GAM, GBM y MX mostraron una capacidad de discriminación aceptable (AUC ~ 0.7) en dos o tres de los cuatro bloques analizados. Según la pendiente de calibración de Miller, GLM y GAM presentaron buena calibración únicamente en uno de los bloques, con una pendiente cercana a 1. En los bloques restantes, ambos modelos sobreestimaron ligeramente la precisión de las predicciones (<1). Por su parte, GBM y MX alternaron entre sobreestimar y subestimar la precisión en los cuatro bloques evaluados (<1; >1). El modelo BART tuvo un rendimiento aceptable (AUC ~ 0.7) en el 50% de los bloques para discriminar entre sitios con presencia y ausencia de la especie. No obstante, subestimó la precisión de las predicciones en los cuatro bloques de validación (<1). Finalmente, el modelo RF mostró el peor desempeño, tanto en capacidad de discriminación (AUC < 0.7) como en la precisión de las predicciones (<1), en los cuatro bloques.

Según estos resultados de rendimiento de los MDE, los algoritmos tradicionales se consideran confiables para predecir la distribución de *S. frugiperda*, destacándose GAM, GLM por su desempeño superior en diversas métricas. Estos resultados coinciden con los reportados por Baquero *et al.* (2021), donde los modelos empleados mostraron un alto consenso y una buena capacidad predictiva en áreas de validación cruzada de bloques. Mientras que los modelos GLM y GAM destacaron por obtener las puntuaciones más altas en confiabilidad (calibración) y BART logró el mejor equilibrio entre calibración y capacidad de discriminación. El desempeño destacado de GAM y GBM en criterios clave de rendimiento en diversos estudios, los posiciona como herramientas altamente confiables y efectivas para la clasificación de datos en contextos similares (Ren-Yan, Xiao, Min, Wei y Zhi, 2014; Watling *et al.*, 2015; Norberg *et al.*, 2019; Valavi *et al.*, 2019; Steen, Tingley, Paton y Elphick, 2021).

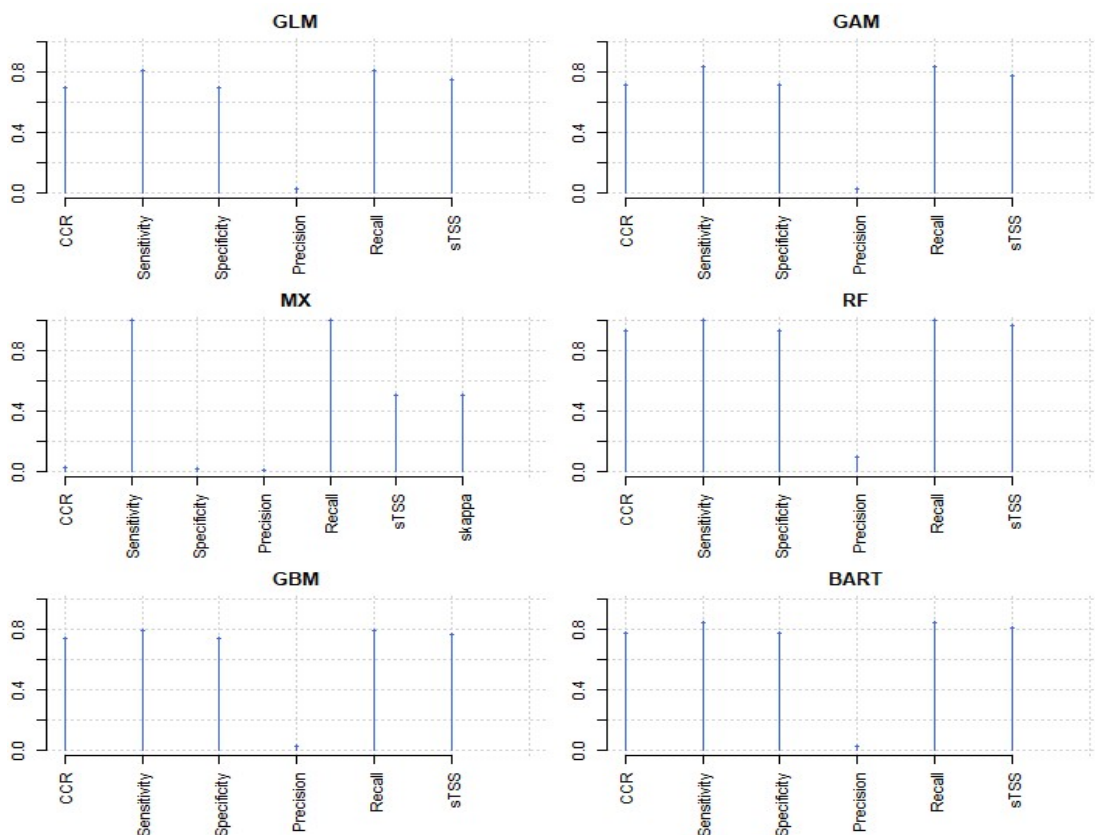


Figura 8. Rendimiento de los modelos de nicho ecológico calibrados para *Spodoptera frugiperda* en Ecuador continental a través de métricas con umbral de prevalencia. Tasa de clasificación correcta (CCR), sensibilidad, especificidad, precisión, recall y estadística de habilidad verdadera (sTSS); eje y = valores con umbral de prevalencia con un rango desde 0.0 hasta 1; eje x = métricas de rendimiento evaluadas; GLM = modelo lineal generalizado; GAM = modelo aditivo generalizado; MX = MaxEnt (máxima entropía); RF = bosques aleatorios; GBM = modelos potenciados generalizados; BART = árboles de regresión aditivos bayesianos; curva cerca de la diagonal = modelo bien calibrado.

Figure 8. Performance of ecological niche models calibrated for *Spodoptera frugiperda* in continental Ecuador using threshold prevalence metrics. Correct classification rate (CCR), sensitivity, specificity, precision, recall and true skill statistic (sTSS); y-axis = prevalence threshold values with a range from 0.0 to 1; x-axis = performance metrics evaluated; GLM = generalized linear model; GAM = generalized additive model; MX = MaxEnt (maximum entropy); RF = random forests; GBM = generalized boosted models; BART = bayesian additive regression trees; curve close to the diagonal = well-calibrated model.

La capacidad de GAM para modelar relaciones no lineales y su flexibilidad en la incorporación de múltiples predictores explican su alto rendimiento en la clasificación de los datos (van Oijen, 2020). Por su parte, GBM, mediante su enfoque de aprendizaje secuencial, incrementa la precisión del modelo, haciéndolo particularmente eficaz para clasificar problemas complejos y no lineales (Ridgeway, 2004).

Zonas de Cultivos Susceptibles

Los modelos GLM, GBM y GAM (Figura 10A, 10B y 10E) presentaron estimaciones similares respecto a la extensión de áreas en riesgo por la coexistencia de *S. frugiperda* y cultivos hospederos. Estas áreas se concentran principalmente en la región Costa, abarcando las provincias Los Ríos, Guayas, Manabí, Santa Elena y Santo Domingo de los Tsáchilas. Asimismo, en la región Sierra, las provincias con mayor riesgo son Imbabura, Pichincha, Loja, Chimborazo, Cañar y Tungurahua. De acuerdo con estos modelos (Figura 11), el cultivo de maíz duro se encuentra como el más susceptible, con áreas potencialmente afectadas estimadas en 3628 km² (GLM), 3603 km² (GBM) y 3548 km² (GAM). Le siguen el arroz, con valores de 3152 km² (GLM), 3169 km² (GBM) y 3144 km² (GAM). En tercer lugar, se encuentra la palma africana, con extensiones de 1237 km² (GLM) y 1020 km² (GAM), aunque el modelo GBM sitúa en esta posición a la caña de azúcar industrial, con 959 km².

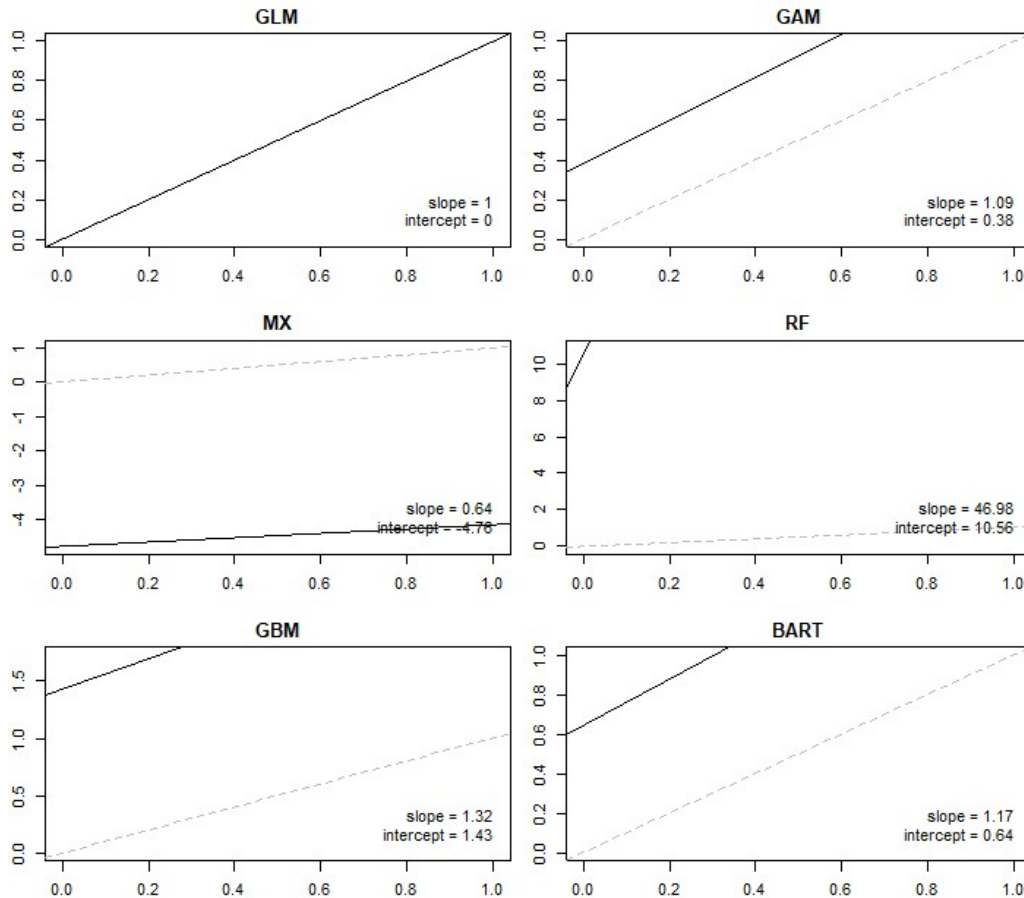


Figura 9. Evaluación de los modelos de nicho ecológico de *Spodoptera frugiperda* en Ecuador continental con la métrica línea de calibración de Miller, para medir la precisión de las predicciones. eje x = probabilidad predictiva; eje y = frecuencia observada de eventos; GLM = modelo lineal generalizado; GAM = modelo aditivo generalizado; MX = MaxEnt (máxima entropía); RF = bosques aleatorios; GBM = modelos potenciados generalizados; BART = árboles de regresión aditivos bayesianos.

Figure 9. Evaluation of ecological niche models of *Spodoptera frugiperda* in continental Ecuador with Miller's calibration line metric to measure the accuracy of predictions. x-axis = predictive probability; y-axis = observed frequency of events; GLM = generalized linear model; GAM = generalized additive model; MX = MaxEnt (maximum entropy); RF = random forests; GBM = generalized boosted models; BART = bayesian additive regression trees.

Por otro lado, el modelo MX predice áreas en riesgo con una mayor cobertura para todos los cultivos hospederos (Figura 10C). En contraste, el modelo RF estima las zonas de riesgo con una menor extensión territorial (Figura 10D). Los modelos BART, MX y RF también identifican zonas de riesgo en las regiones Costa y Sierra, con una ligera extensión hacia el Oriente, particularmente en las provincias Napo, Orellana y Sucumbíos (Figura 10F). De manera general, todos los modelos coinciden en que los cultivos con menor área en riesgo por la presencia de la plaga son el maíz suave, la soya y la papa; sin embargo, esta especie es una plaga polífaga con preferencias alimentarias selectivas que podría infestar dichos cultivos en extensas áreas como respuesta a variaciones ambientales o a escasez de otros hospederos.

En Ecuador, al igual que en toda Sudamérica, los cultivos más vulnerables a su presencia, en orden decreciente, incluyen el maíz, el arroz, la soya y otros cereales, así como cultivos oleaginosos como la palma africana y cultivos industriales como la caña de azúcar, además de tubérculos como la papa (Casmuz y Juárez, 2010). No obstante, en ausencia de sus alimentos preferidos, la plaga puede adaptarse a una amplia variedad de plantas y malezas, las cuales influyen significativamente en su crecimiento y desarrollo (Acharya, Malekera, Dhungana, Sharma y Lee 2022; Casmuz y Juárez, 2010; Xiang-Ning *et al.*, 2023). Es por ello por lo que la evaluación de las áreas en riesgo es crucial para la planificación y gestión de prácticas de manejo integrado, tanto de cultivos como de suelos.

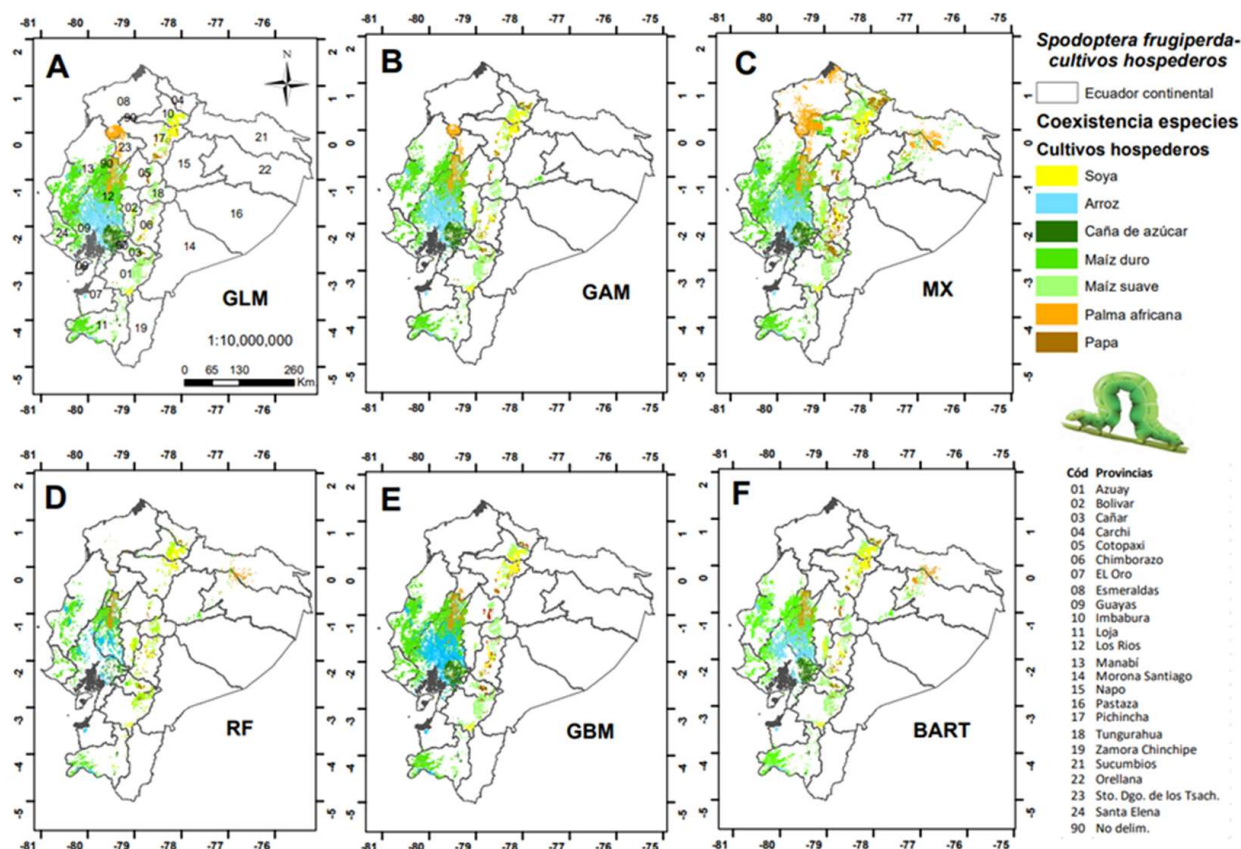


Figura 10. Zonas de riesgo por la coexistencia plaga-cultivos hospederos en Ecuador continental a partir de la modelación del nicho ecológico de *Spodoptera frugiperda*. GLM: GLM = modelo lineal generalizado; GAM = modelo aditivo generalizado; MX = MaxEnt (máxima entropía); RF = bosques aleatorios; GBM = modelos potenciados generalizados; BART = árboles de regresión aditivos bayesianos.

Figure 10. Areas at risk due to pest-host crop coexistence in continental Ecuador based on the modeling of the ecological niche of *Spodoptera frugiperda*. GLM = generalized linear model; GAM = generalized additive model; MX = MaxEnt (maximum entropy); RF = random forests; GBM = generalized boosted models; BART = bayesian additive regression trees.

Implicaciones para el manejo y la vigilancia. Los resultados proporcionan una línea base operativa para focalizar monitoreo e intervenciones de manejo integral de plagas en la Costa y valles interandinos específicos de la Sierra, priorizando maíz duro y arroz, y vigilando palma/caña donde el modelo señala convergencia de riesgo. Para aplicaciones operativas (alertas tempranas, asignación de recursos), se recomienda preferir GLM/GAM/GBM o ensamblajes que ponderen calibración y discriminación, evitando el uso aislado de RF o MaxEnt como fuentes únicas de decisión, salvo que se apliquen estrategias explícitas de recalibración y control de complejidad.

El sobreajuste en RF y sobrepredicción en MaxEnt señalan la necesidad de una selección de complejidad/regularización aún más estricta en implementaciones operativas. Por ello se recomienda para futuros estudios ensamblar modelos con ponderación por calibración (p. ej.: pendiente de Miller) además de AUC/TSS, y aplicar recalibración a algoritmos propensos a descalibración. Además, se deben actualizar forzantes climáticos (p. ej.: CMIP6) e incorporar extremos e índices intraanuales que capten mejor la fenología y eventos de mortalidad por precipitación. La integración de capas dinámicas de hospederos (rotaciones, fenología del maíz/arroz) y sensores remotos para seguimiento y validación independiente podrían facilitar la comprensión y robustez de los resultados de las modelaciones. Es necesario profundizar en métricas de utilidad (p. ej.; curvas de beneficio/decisión) alineadas a costos de manejo, además de métricas puramente estadísticas.

En conjunto, el estudio confirma el valor de GLM/GAM/GBM como bases robustas (individuales o en ensamble) para mapear riesgo de *S. frugiperda* en Ecuador, delimita zonas agrícolas prioritarias en Costa y valles de la Sierra, y matiza la hipótesis inicial al demostrar que la temperatura elevada favorece la presencia mientras que la pluviosidad excesiva la limita. Estos productos son accionables para manejo integrado de plagas y planificación agroterritorial, y constituyen una línea base útil para escenarios de cambio climático y vigilancia fitosanitaria.

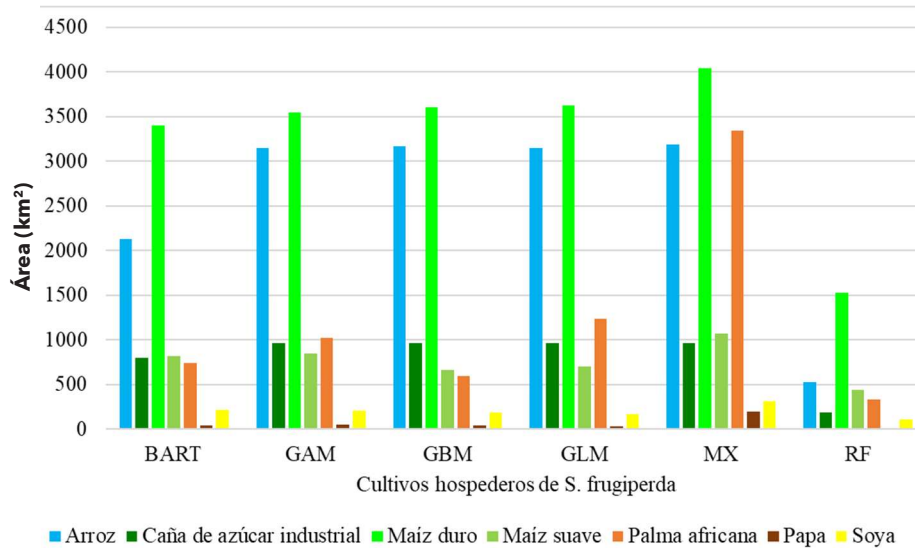


Figura 11. Área (km²) de las regiones de coexistencia plaga-cultivos hospederos en Ecuador continental, según los enfoques estadísticos empleados en la calibración del modelo nicho ecológico de *Spodoptera frugiperda*. GLM = modelo lineal generalizado; GAM = modelo aditivo generalizado; MX = MaxEnt (máxima entropía); RF = bosques aleatorios; GBM = modelos potenciados generalizados; BART = árboles de regresión aditivos bayesianos.

Figure 11. Area (km²) of the regions of pest-host crop coexistence in continental Ecuador, according to the statistical approaches used in the calibration of the ecological niche model of *Spodoptera frugiperda*. GLM = generalized linear model; GAM = generalized additive model; MX = MaxEnt (maximum entropy); RF = random forests; GBM = generalized boosted models; BART = bayesian additive regression trees.

CONCLUSIONES

Los modelos estadísticos tradicionales (GLM y GAM), junto con GBM, mostraron desempeño sólido y consistente para predecir la distribución potencial de *S. frugiperda* en Ecuador continental, con buena calibración (pendiente de Miller cercana a 1) y capacidad discriminatoria aceptable en la validación espacial. En particular, GLM presentó la mejor calibración según la pendiente de Miller; GAM y GBM mantuvieron un buen balance entre calibración y discriminación. BART alcanzó desempeño aceptable en la mitad de los bloques, aunque con tendencia a subestimar. Random Forest evidenció sobreajuste extremo (rendimiento casi perfecto en entrenamiento, pero $AUC < 0.7$ en los cuatro bloques y muy mala calibración), mientras que MaxEnt mostró sobrepredicción espacial y alternó entre sobre y subestimación según el bloque.

La estructura climática del nicho en Ecuador continental estuvo dominada por: rango anual de temperatura (Bio7) como factor más influyente (>40%), seguido de la estacionalidad de precipitación (Bio15) (~37%) y la precipitación del trimestre más húmedo (Bio16) (~10%). El espacio ambiental indicó preferencias por variaciones térmicas moderadas y precipitaciones intermedias, confirmando la plasticidad ecológica de la especie y su capacidad de establecerse bajo un rango relativamente amplio de condiciones.

La Costa emergió como el núcleo de alta favorabilidad y mayor continuidad espacial de idoneidad; la Sierra presentó bolsones de favorabilidad en valles interandinos; el Oriente mostró baja favorabilidad asociada a precipitaciones elevadas. Este patrón fue consistente entre GLM, GAM, MaxEnt y BART (con variación en la extensión exacta); RF produjo predicciones fragmentadas por el sobreajuste del modelo y MaxEnt la mayor cobertura, con riesgo de sobreestimación.

La superposición de mapas de favorabilidad con uso/cobertura del suelo delimitó zonas de mayor riesgo principalmente en Costa (Los Ríos, Guayas, Manabí, Santa Elena y Santo Domingo de los Tsáchilas) y en Sierra (Imbabura, Pichincha, Loja, Chimborazo, Cañar y Tungurahua). Entre los cultivos hospederos evaluados, el maíz duro concentró la mayor superficie potencialmente afectada (~3 548-3 628 km² según modelo), seguido por arroz (~3 144-3 169 km²). A continuación, se ubicaron palma africana o caña de azúcar (según el algoritmo), mientras que maíz suave, soya y papa mostraron menor extensión en riesgo, aunque susceptibles por la euriadaptación de la plaga.

La hipótesis que planteaba una distribución principalmente limitada a regiones cálidas y húmedas, con mayor riesgo en zonas propicias para maíz y otros cereales, queda parcialmente confirmada: las altas temperaturas son cruciales y explican la concentración de favorabilidad en la Costa y algunos valles de la Sierra; no obstante, la precipitación excesiva actúa como factor limitante, reduciendo la idoneidad en regiones muy húmedas del Oriente.

DECLARACIÓN DE ÉTICA

No aplicable.

CONSENTIMIENTO PARA PUBLICACIÓN

No aplicable.

DISPONIBILIDAD DE DATOS

Los conjuntos de datos utilizados o analizados durante el estudio actual están disponibles del autor correspondiente a solicitud razonable.

CONFLICTO DE INTERESES

Los autores declaran que no tienen intereses en competencia.

FINANCIACIÓN

Fondo Competitivo de Investigación Científica y Tecnológica (FOCICYT) 9^{na} Convocatoria de la Universidad Técnica Estatal de Quevedo, a través del proyecto: "Modelación de la distribución potencial del gusano cogollero (*Spodoptera frugiperda*) bajo diferentes métodos estadísticos y escenarios de cambio climático en Ecuador".

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización: F.A.P., A.H.P.V., M.C.V. y Y.F.S.; Metodología: F.A.P., A.H.P.V., M.C.V. y Y.F.S.; Investigación: F.A.P., A.H.P.V., M.C.V. y Y.F.S.; Escritura - preparación del borrador original: F.A.P., A.H.P.V., M.C.V. y Y.F.S.; Escritura - revisión y edición: F.A.P., A.H.P.V., M.C.V. y Y.F.S.; Administración del proyecto: Y.F.S.

AGRADECIMIENTOS

A la Universidad Técnica Estatal de Quevedo (UTEQ) por el apoyo logístico. A la Universidad Autónoma de Campeche a través del convenio marco con la UTEQ. A los revisores anónimos y el editor asociado por su contribución en la mejora del documento.

LITERATURA CITADA

- Acharya, R., Malekera, M. J., Dhungana, S. K., Sharma, S. R., & Lee, K. Y. (2022). Impact of rice and potato host plants is higher on the reproduction than growth of corn strain fall armyworm, *Spodoptera frugiperda* (Lepidoptera: Noctuidae). *Insects*, 13(3), 256. <https://doi.org/10.3390/insects13030256>
- Allouche, O., Tsoar, A., & Kadmon, R. (2006). Assessing the accuracy of species distribution models: Prevalence, kappa and the true skill statistic (TSS). *Journal of Applied Ecology*, 43(6), 1223-1232. <https://doi.org/10.1111/j.1365-2664.2006.01214.x>
- Alphey, N., & Bonsall, M. B. (2018). Genetics-based methods for agricultural insect pest management. *Agricultural and Forest Entomology*, 20(2), 131-140. <https://doi.org/10.1111/afe.12241>
- Araújo, M. B., Anderson, R. P., Márcia Barbosa, A., Beale, C. M., Dormann, C. F., Early, R., ... & Rahbek, C. (2019). Standards for distribution models in biodiversity assessments. *Science Advances*, 5(1), eaat4858. <https://doi.org/10.1126/sciadv.aat4858>
- Araújo, M. B., Pearson, R. G., Thuiller, W., & Erhard, M. (2005). Validation of species-climate impact models under climate change. *Global Change Biology*, 11(9), 1504-1513. <https://doi.org/10.1111/j.1365-2486.2005.01000.x>
- Baloch, M. N., Fan, J., Haseeb, M., & Zhang, R. (2020). Mapping potential distribution of *Spodoptera frugiperda* (Lepidoptera: Noctuidae) in central Asia. *Insects*, 11(3), 172. <https://doi.org/10.3390/insects11030172>
- Baquero, R. A., Barbosa, A. M., Ayllón, D., Guerra, C., Sánchez, E., Araújo, M. B., & Nicola, G. G. (2021). Potential distributions of invasive vertebrates in the Iberian Peninsula under projected changes in climate extreme events. *Diversity and Distributions*, 27(11), 2262-2276. <https://doi.org/10.1111/ddi.13401>

- Barbet-Massin, M., Jiguet, F., Albert, C. H., & Thuiller, W. (2012). Selecting pseudo-absences for species distribution models: how, where and how many? *Methods in Ecology and Evolution*, 3(2), 327-338.
- Barbosa, A. (2015). fuzzySim: Applying fuzzy logic to binary similarity indices in ecology. *Methods in Ecology and Evolution*, 6(7), 853-858. <https://doi.org/10.1111/2041-210X.12372>
- Barbosa, A., Real, R., Muñoz, A. R., & Brown, J. A. (2013). New measures for assessing model equilibrium and prediction mismatch in species distribution models. *Diversity and Distributions*, 19(10), 1333-1338. <https://doi.org/10.1111/ddi.12100>
- Bradley, J., & Leung, B. (2017). A quantitative synthesis of the importance of variables used in MaxEnt species distribution models. *Journal of Biogeography*, 44(6), 1344-1361. <https://doi.org/10.1111/jbi.12894>
- Carlson, C. J. (2020). embarcadero: Species distribution modelling with Bayesian additive regression trees in R. *Methods in Ecology and Evolution*, 11(7), 850-858. <https://doi.org/10.1111/2041-210X.13389>
- Casmuz, A., & Juárez, M. (2010). Revisión de los hospederos del gusano cogollero del maíz, *Spodoptera frugiperda* (Lepidoptera: Noctuidae). *Revista de la Sociedad Entomológica Argentina*, 69(3-4), 209-231.
- CABI (Centre for Agriculture and Bioscience International). 2025. *CABI Digital Library*. Wallingford, Oxfordshire, Reino Unido: CABI. Consultado el 13 de junio, 2024, desde: <https://www.cabidigitallibrary.org/>
- Cokola, M. C., Mugumaarhama, Y., Noël, G., Bisimwa, E. B., Bugeme, D. M., Chuma, G. B., ... & Francis, F. (2020). Bioclimatic zonation and potential distribution of *Spodoptera frugiperda* (Lepidoptera: Noctuidae) in south Kivu Province, DR Congo. *BMC Ecology*, 20(1), 66. <https://doi.org/10.1186/s12898-020-00335-1>
- Dormann, C. F., Elith, J., Bacher, S., Buchmann, C., Carl, G., Carré, G., ... & Lautenbach, S. (2013). Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. *Ecography*, 36(1), 27-46.
- Early, R., González-Moreno, P., Murphy, S. T., & Day, R. (2018). Forecasting the global extent of invasion of the cereal pest *Spodoptera frugiperda*, the fall armyworm. *NeoBiota*, 40, 25-50. <https://doi.org/10.1101/391847>
- Elith*, J., H. Graham*, C., P. Anderson, R., Dudík, M., Ferrier, S., Guisan, A., ... & E. Zimmermann, N. (2006). Novel methods improve prediction of species' distributions from occurrence data. *Ecography*, 29(2), 129-151. <https://doi.org/10.1111/J.2006.0906-7590.04596.X>
- Elith, J., Phillips, S. J., Hastie, T., Dudík, M., Chee, Y. E., & Yates, C. J. (2011). A statistical explanation of MaxEnt for ecologists. *Diversity and Distributions*, 17(1), 43-57. <https://doi.org/10.1111/j.1472-4642.2010.00725.x>
- ESRI (2020). *ArcGis User's Guide. Released 10.8*. Redlands, CA, USA: Environmental Systems Research Institute.
- Ferrer-Sánchez, Y., Mafaldo-Sajami, A. A., Plasencia-Vázquez, A. H., & Urdánigo-Zambrano, J. P. (2022). Riesgo para el cultivo de cacao por los cambios en la distribución potencial del fitopatógeno *Moniliophthora perniciosa* bajo escenarios de cambio climático en Ecuador continental. *Terra Latinoamericana*, 40, 1-10. <https://doi.org/10.28940/terra.v40i0.1338>
- Fick, S. E., & Hijmans, R. J. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37(12), 4302-4315. <https://doi.org/10.1002/joc.5086>
- Fielding, A. H., & Bell, J. F. (1997). A review of methods for the assessment of prediction errors in conservation presence/absence models. *Environmental Conservation*, 24(1), 38-49. <https://doi.org/10.1017/S0376892997000088>
- Fourcade, Y., Besnard, A. G., & Secondi, J. (2018). Paintings predict the distribution of species, or the challenge of selecting environmental predictors and evaluation statistics. *Global Ecology and Biogeography*, 27(2), 245-256. <https://doi.org/10.1111/geb.12684>
- Gaibor, R., Rodríguez, S., Guevara, C., Reyes, J., & Plaza, P. (2023). Variation over time of bioinsecticides effect on *Spodoptera frugiperda* incidence in corn (*Zea mays*) in dry season in Mocache, Los Ríos, Ecuador. *Tropical and Subtropical Agroecosystems*, 26, 1-12. <http://dx.doi.org/10.56369/tsaes.3958>
- GBIF (Global Biodiversity Information Facility). 2025. *GBIF Occurrence Download*. Copenhagen, Dinamarca: Global Biodiversity Information Facility. Consultado el 13 de junio, 2024, desde <https://www.gbif.org/es/>
- Hastie, T. (2023). *gam: Generalized additive models* (R package version 1.22-2). Vienna, Austria: Comprehensive R Archive Network (CRAN).
- He, L., Wang, T., Chen, Y., Ge, S., Wyckhuys, K. A. G., & Wu, K. (2021). Larval diet affects development and reproduction of East Asian strain of the fall armyworm, *Spodoptera frugiperda*. *Journal of Integrative Agriculture*, 20(3), 736-744. [https://doi.org/10.1016/S2095-3119\(19\)62879-0](https://doi.org/10.1016/S2095-3119(19)62879-0)
- Hentschel, R., Möller, K., Wenning, A., Degenhardt, A., & Schröder, J. (2018). Importance of ecological variables in explaining population dynamics of three important pine pest insects. *Frontiers in Plant Science*, 9, 1667 <https://doi.org/10.3389/fpls.2018.01667>
- Huang, Y., Dong, Y., Huang, W., Ren, B., Deng, Q., Shi, Y., ... & Ma, H. (2020). Overwintering distribution of fall armyworm (*Spodoptera frugiperda*) in Yunnan, China, and influencing environmental factors. *Insects*, 11(11), 805. <https://doi.org/10.3390/insects11110805>
- INIAP (Instituto Nacional de Investigaciones Agropecuarias). (2019). *Informe técnico anual 2019. Sección: Entomología*. Departamento Nacional de Protección Vegetal (DNPV), Estación Experimental Portoviejo. Portoviejo, Manabí, Ecuador: Instituto Nacional de Investigaciones Agropecuarias.
- Junttila, S., Näsi, R., Koivumäki, N., Imangholiloo, M., Saarinen, N., Raisio, J., ... & Honkavaara, E. (2022). Multispectral imagery provides benefits for mapping spruce tree decline due to bark beetle infestation when acquired late in the season. *Remote Sensing*, 14(4), 909. <https://doi.org/10.3390/rs14040909>
- Lake, T. A., Briscoe-Runquist, R. D., & Moeller, D. A. (2020). Predicting range expansion of invasive species: Pitfalls and best practices for obtaining biologically realistic projections. *Diversity and Distributions*, 26(12), 1767-1779. <https://doi.org/10.1111/ddi.13161>
- Li, X., & Wang, Y. (2013). Applying various algorithms for species distribution modelling. *Integrative Zoology*, 8(2), 124-135. <https://doi.org/10.1111/1749-4877.12000>
- Liaw, A., & Wiener, M. (2002). Classification and Regression by random Forest. *R News*, 2(3), 18-22.
- Lissovsky, A. A., & Dudov, S. V. (2021). Species-Distribution Modeling: Advantages and Limitations of Its Application. 2. MaxEnt. *Biology Bulletin Reviews*, 11(3), 265-275. <https://doi.org/10.1134/s2079086421030087>
- Lumivero. (2024). *XLSTAT (Version 2024)*. New York, NY, USA: Lumivero.
- Mcinerney, D. O., & Nieuwenhuis, M. (2009). A comparative analysis of kNN and decision tree methods for the Irish National Forest Inventory. *International Journal of Remote Sensing*, 30(19), 4937-4955. <https://doi.org/10.1080/01431160903022936>
- Miller, M. E., Hui, S. L., & Tierney, W. M. (1991). Validation techniques for logistic regression models. *Statistics in Medicine*, 10(8), 1213-1226. <https://doi.org/10.1002/sim.4780100805>
- Morales-Barbero, J., & Vega-Álvarez, J. (2019). Input matters matter: Bioclimatic consistency to map more reliable species distribution models. *Methods in Ecology and Evolution*, 10(2), 212-224. <https://doi.org/10.1111/2041-210X.13124>
- Munro, H., Montes, C., Gandhi, K., & Poisson, M. (2022). A comparison of presence-only analytical techniques and their application in forest pest modeling. *Ecological Informatics*, 68, 101525. <https://doi.org/10.1016/j.ecoinf.2021.101525>

- Muscarella, R., Galante, P. J., Soley-Guardia, M., Boria, R. A., Kass, J. M., Uriarte, M., & Anderson, R. P. (2014). ENM eval: An R package for conducting spatially independent evaluations and estimating optimal model complexity for Maxent ecological niche models. *Methods in Ecology and Evolution*, 5(11), 1198-1205. <https://doi.org/10.1111/2041-210X.12261>
- Nagoshi, R., Nagoshi, B., Cañarte, E., Navarrete, B., Solórzano, R., & Garcés, S. (2019). Genetic characterization of fall armyworm (*Spodoptera frugiperda*) in Ecuador and comparisons with regional populations identify likely migratory relationships. *PLoS One*, 14(9), 1-17. <https://doi.org/10.1371/journal.pone.0222332>
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurobotics*, 7, 21. <https://doi.org/10.3389/fnbot.2013.00021>
- Norberg, A., Abrego, N., Blanchet, F. G., Adler, F. R., Anderson, B. J., Anttila, J., ... & Ovaskainen, O. (2019). A comprehensive evaluation of predictive performance of 33 species distribution models at species and community levels. *Ecological Monographs*, 89(3), e01370. <https://doi.org/10.1002/ecm.1370>
- Osoorio-Olvera, L., Lira-Noriega, A., Soberón, J., Peterson, A. T., Falconi, M., Contreras-Díaz, R. G., ... & Barve, N. (2020). ntbox: An r package with graphical user interface for modelling and evaluating multidimensional ecological niches. *Methods in Ecology and Evolution*, 11(10), 1199-1206. <https://doi.org/10.1111/2041-210X.13452>
- Owens, H. L., & Rahbek, C. (2023). voluModel: Modelling species distributions in three-dimensional space. *Methods in Ecology and Evolution*, 14(3), 841-847. <https://doi.org/10.1111/2041-210X.14064>
- Pearce, J., & Ferrier, S. (2000). Evaluating the predictive performance of habitat models developed using logistic regression. *Ecological Modelling*, 133(3), 225-245. [https://doi.org/10.1016/S0304-3800\(00\)00322-7](https://doi.org/10.1016/S0304-3800(00)00322-7)
- Peterson, A. T., Soberón, J., Pearson, R. G., Anderson, R. P., Martínez-Meyer, E., Nakamura, M., & Araújo, M. B. (2011). *Ecological niches and geographic distributions*. Princeton, NJ, USA: Princeton University Press.
- Phillips, S. J., Dudík, M., & Schapire, R. E. (2004). A maximum entropy approach to species distribution modeling. Proceedings of the Twenty-First International Conference on Machine Learning, *ICML 2004*, 655-662. <https://doi.org/10.1145/1015330.1015412>
- Phillips, S. J., & Dudík, M. (2008). Modeling of species distributions with Maxent: new extensions and a comprehensive evaluation. *Ecography*, 31(2), 161-175. <https://doi.org/10.1111/j.0906-7590.2008.5203.x>
- Portilla, F. (2018). Introducción. In F. Portilla. *Agroclimatología del Ecuador* (pp. 17-40). Quito, Ecuador: Abya Yala. <https://doi.org/10.7476/9789978104927.0001>
- Rapacciuolo, G., Roy, D. B., Gillings, S., Fox, R., Walker, K., & Purvis, A. (2012). Climatic associations of British species distributions show good transferability in time but low predictive accuracy for range change. *PLoS One*, 7(7). <https://doi.org/10.1371/journal.pone.0040212>
- Real, R., Barbosa, A. M., & Bull, J. W. (2017). Species distributions, quantum theory, and the enhancement of biodiversity measures. *Systematic Biology*, 66(3), 453-462. <https://doi.org/10.1093/sysbio/syw072>
- Real, R., Barbosa, A. M., & Vargas, J. M. (2006). Obtaining environmental favourability functions from logistic regression. *Environmental and Ecological Statistics*, 13(2), 237-245. <https://doi.org/10.1007/s10651-005-0003-3>
- Ren-Yan, D., Xiao-Quan, K., Min-Yi, H., Wei-Yi, F., & Zhi-Gao, W. (2014). The predictive performance and stability of six species distribution models. *PLoS One*, 9(11). e112764. <https://doi.org/10.1371/journal.pone.0112764>
- Ridgeway, G. (2004). *The GBM package: Generalized boosted regression models* (R version 1.6-3). Vienna, Austria: Foundation for Statistical Computing.
- Steen, V. A., Tingley, M. W., Paton, P. W. C., & Elphick, C. S. (2021). Spatial thinning and class balancing: Key choices lead to variation in the performance of species distribution models with citizen science data. *Methods in Ecology and Evolution*, 12(2), 216-226. <https://doi.org/10.1111/2041-210X.13525>
- Strobl, C., Boulesteix, A. L., Kneib, T., Augustin, T., & Zeileis, A. (2008). Conditional variable importance for random forests. *BMC Bioinformatics*, 9, 1-11. <https://doi.org/10.1186/1471-2105-9-307>
- Valavi, R., Elith, J., Lahoz-Monfort, J. J., & Guillera-Aroita, G. (2019). blockCV: An r package for generating spatially or environmentally separated folds for k-fold cross-validation of species distribution models. *Methods in Ecology and Evolution*, 10(2), 225-232. <https://doi.org/10.1111/2041-210X.13107>
- Van Oijen, M. (2020). Linear modelling: LM, GLM, GAM and mixed models. In M. van Oijen (Ed.). *Bayesian compendium* (pp. 137-140). Cham, Switzerland: Springer International Publishing. https://doi.org/10.1007/978-3-030-55897-0_19
- Vélez, M., Betancourt, C., & Mendoza, J. (2021). Evaluación de diferentes momentos de aplicación de insecticida Metomil 90% para el control del gusano cogollero (*Spodoptera frugiperda*) en el cultivo de maíz. *Ciencia y Tecnología*, 14(2), 33-40. <https://doi.org/10.18779/cyt.v14i2.500>
- Waldock, C., Stuart-Smith, R. D., Albouy, C., Cheung, W. W., Edgar, G. J., Mouillot, D., ... & Pellissier, L. (2022). A quantitative review of abundance based species distribution models. *Ecography*, 2022(1). <https://doi.org/10.1111/ecog.05694>
- Watling, J. I., Brandt, L. A., Bucklin, D. N., Fujisaki, I., Mazzotti, F. J., Romanach, S. S., & Speroterra, C. (2015). Performance metrics and variance partitioning reveal sources of uncertainty in species distribution models. *Ecological Modelling*, 309, 48-59. <https://doi.org/10.1016/j.ecolmodel.2015.03.017>
- Xiang-Ning, S., Chuan-Ying, L., Yi-Jua, X., Shao-Huai, H., Wei-Ling, L., Zhang-Xuan, L., & Yu-Ping, Z. (2023). Feeding preference and adaptability of fall armyworm *Spodoptera frugiperda* on five species of host plants and six weeds. *Journal of Environmental Entomology*, 44, 263-272.
- XiangHui, R., JianXin, C., Yang, M., Peng, L., XinYue, N., & WenJie, L. (2017). Radom forest model analysis on environment factors of *Phyllotreta striolata* occurrence in *Brassica chinensis* field. *Journal of Agricultural Science and Technology*, 19, 117-123.
- Zambrano, J. L., Yáñez, C., Sangoquiza, C., Limongi, R., Alarcón, D., Zambrano, E., ... & Pinargote, L. (2019). Situación del cultivo de maíz en Ecuador: investigación y desarrollo de tecnologías en el INIAP [Resumen]. En *XXIII Reunión Latinoamericana del Maíz y IV Congreso de Semillas* (pp. 30-31). Mosquera, Colombia: AGROSAVIA.
- Zhang, D., Xiao, Y., Xu, P., Yang, X., Wu, Q., & Wu, K. (2021). Insecticide resistance monitoring for the invasive populations of fall armyworm, *Spodoptera frugiperda* in China. *Journal of Integrative Agriculture*, 20(3), 783-791. [https://doi.org/10.1016/S2095-3119\(20\)63392-5](https://doi.org/10.1016/S2095-3119(20)63392-5)
- Zhao, Z., Xiao, N., Shen, M., & Li, J. (2022). Comparison between optimized MaxEnt and random forest modeling in predicting potential distribution: A case study with *Quasipaa boulengeri* in China. *Science of The Total Environment*, 842, 156867. <https://doi.org/10.1016/j.scitotenv.2022.156867>