



**UNIVERSIDAD TÉCNICA DEL NORTE**  
**FACULTAD DE INGENIERÍA EN CIENCIAS AGROPECUARIAS Y**  
**AMBIENTALES**  
**CARRERA DE INGENIERÍA EN RECURSOS NATURALES**  
**RENOVABLES**

“MODELAMIENTO DE PLAGAS EN CULTIVOS DE IMPORTANCIA  
ECONÓMICA CON BASE EN ESCENARIOS DE CAMBIO CLIMÁTICO EN  
LA PROVINCIA DE IMBABURA”

TRABAJO DE INTEGRACIÓN CURRICULAR PARA OBTENER EL TÍTULO  
DE INGENIERO/A EN RECURSOS NATURALES RENOVABLES

**AUTORES:**

Richard Paúl Chávez Menacho

Kenny Paola Ponce Maspud

**DIRECTOR:**

Ing. Gabriel Alexis Jácome Aguirre MSc.

**Ibarra, 2024**



# UNIVERSIDAD TÉCNICA DEL NORTE

## DIRECCIÓN DE BIBLIOTECA

### 1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO		
<b>CÉDULA DE IDENTIDAD:</b>	1003883095	
<b>APELLIDOS Y NOMBRES:</b>	Chávez Menacho Richard Paúl	
<b>DIRECCIÓN:</b>	Cotacachi – Imbabura	
<b>EMAIL:</b>	<a href="mailto:rpehavezm@utn.edu.ec">rpehavezm@utn.edu.ec</a>	
<b>TELÉFONO FIJO:</b>	<b>TELÉFONO MOVIL</b>	0939514235

DATOS DE CONTACTO		
<b>CÉDULA DE IDENTIDAD:</b>	1004761332	
<b>APELLIDOS Y NOMBRES:</b>	Ponce Maspud Kenny Paola	
<b>DIRECCIÓN:</b>	Ibarra, Huertos Familiares, Ibarra y Segundo Luis Moreno	
<b>EMAIL:</b>	<a href="mailto:kpponcecm@utn.edu.ec">kpponcecm@utn.edu.ec</a>	
<b>TELÉFONO FIJO:</b>	<b>TELÉFONO MOVIL</b>	0960470673

DATOS DE LA OBRA	
<b>TÍTULO:</b>	Modelamiento de plagas en cultivos de importancia económica con base en escenarios de cambio climático en la provincia de Imbabura
<b>AUTOR (ES):</b>	Chávez Menacho Richard Paúl Ponce Maspud Kenny Paola
<b>FECHA:</b>	01 de julio del 2024
SOLO PARA TRABAJOS DE GRADO	
<b>CARRERA/PROGRAMA:</b>	<input checked="" type="checkbox"/> GRADO <input type="checkbox"/> POSGRADO
<b>TÍTULO POR EL QUE OPTA:</b>	Ingeniero/a en Recursos Naturales Renovables
<b>ASESOR / DIRECTOR:</b>	MSc. Gabriel Jácome

## 2. CONSTANCIAS

Los autores manifiestan que la obra objeto de la presente autorización es original y se la desarrolló sin violar derechos de autor de terceros, por lo tanto, la obra es original y que son los titulares de los derechos patrimoniales, por lo que asumen la responsabilidad sobre el contenido de la misma y saldrán en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 01 días del mes de julio de 2024

### LOS AUTORES:



.....

Richard Paul Chávez Menacho

C.I.: 1003883095



.....

Kenny Paola Ponce Maspud

C.I.: 1004761332

**CERTIFICACIÓN DIRECTOR DEL TRABAJO DE INTERGRACIÓN  
CURRICULAR**




Ibarra, a los 01 días del mes de julio de 2024

MSc. Gabriel Alexis Jácome Aguirre

DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR

**CERTIFICA:**

Haber revisado el presente informe final del trabajo de Integración Curricular, el mismo que se ajusta a las normas vigentes de la Universidad Técnica del Norte; en consecuencia, autorizo su presentación para los fines legales pertinentes.

(f)  .....

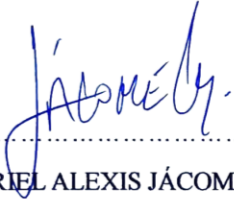
MSc. GABRIEL ALEXIS JÁCOME AGUIRRE

C.C.: ..1003432802...

## APROBACIÓN DEL COMITÉ CALIFICADOR



El Comité Calificador del trabajo de Integración Curricular “MODELAMIENTO DE PLAGAS EN CULTIVOS DE IMPORTANCIA ECONÓMICA CON BASE EN ESCENARIOS DE CAMBIO CLIMÁTICO EN LA PROVINCIA DE IMBABURA” elaborado por CHÁVEZ MENACHO RICHARD PAÚL y PONCE MASPUD KENNY PAOLA, previo a la obtención del título de INGENIERO/A EN RECURSOS NATURALES RENOVABLES, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte:

(f): .....

MSc. GABRIEL ALEXIS JÁCOME AGUIRRE

C.C.: 1003432802.....

(f): .....

PhD. JULIA KARINA PRADO BELTRÁN

C.C.: 1712818283.....

## **AGRADECIMIENTO**

*Quiero expresar mi profundo agradecimiento a mi familia, por su apoyo incondicional y aliento a lo largo de este proceso académico. Su respaldo ha sido mi mayor fortaleza y motivación.*

*A la Universidad Técnica del Norte por brindarnos las herramientas y el conocimiento necesario para nuestro crecimiento académico y profesional. La formación recibida nos ha permitido nutrirnos de sabiduría y nos ha preparado para enfrentar los desafíos con excelencia.*

*Al MSc. Juan Guamán por su invaluable orientación y apoyo a lo largo de toda la investigación. Su guía experta y su dedicación han sido fundamentales para la culminación de este trabajo.*

*A nuestro director MSc. Gabriel Jácome y a nuestra asesora PhD Julia Prado por su valioso acompañamiento y compromiso en el desarrollo y mejora de la investigación. Su constante contribución ha enriquecido significativamente este proceso.*

*Gratitud a las instituciones AGROCALIDAD e INAMHI por su colaboración y por proporcionarnos información que ha sido esencial para la ejecución de este estudio.*

*A todos y cada una de las personas cuya contribución fue fundamental para el desarrollo de esta investigación.*

**- Richard**

## AGRADECIMIENTO

*En este emocionante capítulo académico que llega a su fin, no puedo más que sentir un profundo agradecimiento hacia la institución que me vio crecer Universidad Técnica del Norte, familia y amigos especiales que han iluminado mi camino. Su apoyo constante y amor incondicional han sido la fuente de mi fortaleza y motivación a lo largo de este viaje.*

*A mi querido papá, quien me enseñó que un apellido se lleva con orgullo y dignidad; a mi amada mamá, quien me hizo fuerte con un carácter inquebrantable y un amor incondicional; y a Katty, mi roca, mi apoyo constante, gracias por creer en mí de manera inamovible. Sus palabras de aliento y sacrificios han sido mi mayor inspiración. Mis amigos queridos, Pablo, Mile, Sheylita y Vane, su amistad ha sido como un faro brillante en los momentos más oscuros de mi vida, iluminando mi camino y dándome fuerzas para seguir adelante. Su ánimo constante y su apoyo resiliente han sido el motor que me ha impulsado a alcanzar este logro. Estoy profundamente agradecida por tenerlos en mi vida.*

*Este hito no es solo mío, sino de todos nosotros. Juntos hemos demostrado que, con amor, apoyo y amistades valiosas, se pueden superar desafíos y lograr grandes metas. Miro hacia el futuro con gratitud y entusiasmo, sabiendo que, con este grupo de personas excepcionales a mi lado, no hay límites para lo que podemos lograr.*

*Gracias por formar parte de este emocionante viaje.*

**-Kenny**

## DEDICATORIA

*Esta investigación se la dedico a mi padre Manuel y mi madre María, quienes siempre me han apoyado a pesar de los momentos difíciles. Son mi motivo de seguir adelante, mi inspiración y mi persuasión. Me han inculcado humildad, honestidad y muchos valores. Gracias por influenciarme a ser constante y a esforzarme en todo. Por todo esto y más, por ustedes y para ustedes.*

*A mis hermanas, Evelin, Blanca y Cinthia, y mi hermano, Jhostin. Han sido fundamental para lograr este objetivo. Jamás me han abandonado en mis peores momentos. Muchas gracias por ayudarme a fortalecer mis cualidades y fortalezas. Sin ustedes no lo hubiese logrado.*

*A mis amigos, Anahí Poso, Génesis Buitrón, Edwin Sánchez, Doris Cevallos y Miguel Guaichico, quienes a lo largo del proceso académico se convirtieron en mentores y aliados emocionales. Gracias a ustedes, entendí el sentido de la vida, ya que su influencia ha dado un propósito a mi camino. También a mis amigos foráneos, quienes me brindaron refugio en los momentos de soledad y tristeza para convertirlos en momentos de júbilo.*

*Y por supuesto, a mi compañera de tesis y amiga Kenny. A pesar de nuestras diferencias, hemos logrado superar todos los obstáculos presentados a lo largo de esta etapa universitaria. Los días y las noches de trabajos grupales, las risas en los momentos divertidos y las charlas de críticas constructivas mutuas en los diferentes semestres culminan con este trabajo. Gracias por el aguante y sé que serás una gran profesional.*

**Con mucho cariño,**

**Richard**



## DEDICATORIA

*Me gustaría dedicar este trabajo a mi mayor fuente de inspiración y motivación para seguir adelante: mi querida Lía, mi bebé arcoíris. Un bebé arcoíris es aquel que llega después de momentos oscuros y difíciles, y tú has sido y eres esa luz en medio de la oscuridad. Gracias a ti, encuentro en tu sonrisa diaria la motivación para mejorar y superarme cada día. Quiero que sepas que siempre estaré para ti y que eres mi mayor orgullo.*

*Me complace presentar este trabajo a todas las personas que, de alguna manera, contribuyeron a mi crecimiento y determinación. A aquellos que me desafiaron, a quienes me enseñaron lecciones difíciles, y también a los que, aunque me miraron con escepticismo, me inspiraron a demostrar mi capacidad. Reconozco a todos aquellos que me alentaron a superar obstáculos y alcanzar mis metas, incluso a aquellos que me rompieron el corazón y me enseñaron lecciones valiosas sobre la fuerza de la resiliencia.*

*A mi compañero de tesis y amigo Richi, eres una verdadera máquina, pero recuerda nunca dejarte opacar por nadie. Observa lo que hemos logrado juntos; este trabajo nos ha enseñado que, sin importar la magnitud del desafío, siempre podemos superarlo. Me alegra profundamente que hayas sido mi compañero en este camino, y espero que nuestro espíritu competitivo nunca desaparezca. Confío plenamente en que alcanzarás la profesionalidad que deseas.*

**-Kenny**

## ÍNDICE DE CONTENIDO

Contenido.....	Páginas
<b>RESUMEN.....</b>	<b>XV</b>
<b>ABSTRACT.....</b>	<b>XVI</b>
<b>CAPÍTULO I. INTRODUCCIÓN.....</b>	<b>1</b>
1.1 Revisión de antecedentes o estado del arte.....	1
1.2 Problema de investigación y justificación.....	4
1.3. Objetivos.....	6
1.3.1. <i>Objetivo general</i> .....	6
1.3.2 <i>Objetivos específicos</i> .....	6
1.4 Pregunta directriz de la investigación.....	6
<b>CAPÍTULO II. MARCO TEÓRICO.....</b>	<b>7</b>
2.1 Marco teórico referencial.....	7
2.1.1 <i>Cultivos agrícolas de importancia económica en Imbabura</i> .....	7
2.1.2 <i>Plagas en cultivos agrícolas</i> .....	8
2.1.3 <i>Climatología</i> .....	12
2.1.4 <i>Cambio climático</i> .....	15
2.1.5 <i>Métodos de modelado de especies</i> .....	18
2.1.6 <i>Machine Learning o Aprendizaje Automático</i> .....	20
2.1.7 <i>Estrategias de Manejo Integrado de Plagas (MIP)</i> .....	23
2.2. Marco legal.....	24
2.2.1 <i>Constitución de la República del Ecuador</i> .....	24
2.2.2 <i>Objetivos del Desarrollo Sostenible (ODS)</i> .....	25
2.2.3 <i>Convención Marco de las Naciones Unidas Sobre el Cambio Climático (CMNUCC)</i> .....	25
2.2.4 <i>Código Orgánico del Ambiente (COA)</i> .....	26
2.2.5 <i>Reglamento al Código Orgánico del Ambiente (RCODA)</i> .....	26
2.2.6 <i>Acuerdo Ministerial 95</i> .....	27
<b>CAPÍTULO III. METODOLOGÍA.....</b>	<b>28</b>
3.1 Descripción del área de estudio.....	28
3.1.1 <i>Clima</i> .....	28

3.1.2 Actividades agropecuarias.....	29
3.2 Métodos.....	30
3.2.1 Caracterización de los factores ambientales influyentes en el umbral de desarrollo .....	30
3.2.2 Desarrollo del modelo de proyección de riesgo de presencia de plagas .....	40
3.2.3 Propuesta de Estrategias de Manejo Integral de Plagas (MIP).....	48
3.3 Materiales y equipos .....	52
<b>CAPÍTULO IV. RESULTADOS Y DISCUSIÓN.....</b>	<b>53</b>
4.1 Caracterización de los factores ambientales influyentes en el umbral de desarrollo.....	53
4.1.1 Variable temperatura .....	53
4.1.2 Factor altitud .....	62
4.2 Modelo de proyección del umbral y condiciones de desarrollo.....	66
4.2.1 Entrenamiento y evaluación de modelos individuales .....	66
4.2.2 Proyección de riesgo de presencia .....	76
4.3 Estrategias de Manejo Integrado de Plagas.....	83
4.3.1 Análisis de información relacionada con los cultivos y plagas.....	83
4.3.2 Identificación de problemas y matriz de Vester.....	84
4.3.3 Estrategias de prevención y mitigación de <i>F. occidentalis</i> y <i>B. cockerelli</i> S en los cultivos de fréjol, aguacate y papa.....	87
<b>CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>101</b>
5.1 Conclusiones .....	101
5.2 Recomendaciones .....	102
<b>REFERENCIAS .....</b>	<b>104</b>
<b>ANEXOS.....</b>	<b>128</b>

## INDICE DE TABLAS

<b>Tabla 1.</b> Taxonomía de <i>B. cockerelli</i> S. ....	9
<b>Tabla 2.</b> Taxonomía de <i>F. occidentalis</i> .....	11
<b>Tabla 3.</b> Enfoques y modelos para el modelado de plagas .....	19
<b>Tabla 4.</b> Algoritmos de aprendizaje automático .....	22
<b>Tabla 5.</b> Información de las estaciones meteorológicas .....	32
<b>Tabla 6.</b> Número de datos entrenados por cada dataset.....	44
<b>Tabla 7.</b> Categorías o variables resultantes de un modelo.....	44
<b>Tabla 8.</b> Clase y etiqueta de riesgo de presencia. ....	46
<b>Tabla 9.</b> Escala de valores para matriz de Vester.....	50
<b>Tabla 10.</b> Materiales y Equipos .....	52
<b>Tabla 11.</b> Error y MSE estimado para los datos de estaciones meteorológicas....	53
<b>Tabla 12.</b> Estadísticos de la prueba t de Student y Wilcoxon.....	54
<b>Tabla 13.</b> Medidas de bondad de predicción .....	56
<b>Tabla 14.</b> Valores de coeficientes de correlación e índices de desempeño entre datos de TerraClimate e INAMHI .....	57
<b>Tabla 15.</b> Valores estadísticos de la prueba z para estaciones .....	58
<b>Tabla 16.</b> Valores estadísticos de comparación .....	59
<b>Tabla 17.</b> Umbral de desarrollo de temperatura para <i>B. cockerelli</i> S. ....	60
<b>Tabla 18.</b> Umbral de desarrollo de temperatura para <i>F. occidentalis</i> .....	62
<b>Tabla 19.</b> Umbral de desarrollo de elevación para <i>B. cockerelli</i> S. ....	63
<b>Tabla 20.</b> Umbral de desarrollo de elevación para <i>F. occidentalis</i> .....	65
<b>Tabla 21.</b> Precisión y tiempo de entrenamiento de los mejores clasificadores para datos de temperatura .....	67
<b>Tabla 22.</b> Precisión y tiempo de entrenamiento de los mejores clasificadores para datos de elevación .....	68
<b>Tabla 23.</b> Valores de AUC del mejor clasificador para temperatura y elevación .	69
<b>Tabla 24.</b> Tasa de error por clase según la matriz de confusión del mejor clasificador para temperatura y elevación .....	70
<b>Tabla 25.</b> Precisión y tiempo promedio de entrenamiento de los clasificadores finales para <i>B. cockerelli</i> S., <i>F. occidentalis</i> y su interacción conjunta.....	72

<b>Tabla 26.</b> Área en hectáreas de la interacción de <i>B. cockerelli</i> S. en el pasado, presente y futuro con el modelo MPI-ESM1-2-HR .....	78
<b>Tabla 27.</b> Área en hectáreas de la interacción de <i>F. occidentalis</i> en el pasado, presente y futuro con el modelo MPI-ESM1-2-HR .....	80
<b>Tabla 28.</b> Área en hectáreas de la interacción de <i>B. cockerelli</i> S. y <i>F. occidentalis</i> en el pasado, presente y futuro con el modelo MPI-ESM1-2-HR .....	82
<b>Tabla 29.</b> Problemas identificados en los cultivos de papa. ....	85
<b>Tabla 30.</b> Problemas identificados en los cultivos de fréjol y aguacate. ....	86
<b>Tabla 31.</b> Matriz PER para el programa de control biológico en el cultivo de aguacate, fréjol y papa.....	91
<b>Tabla 32.</b> Matriz PER para el programa de control cultural y físico en el cultivo de aguacate, fréjol y papa.....	96
<b>Tabla 33.</b> Matriz PER para el programa de capacitación y sensibilización .....	99

## INDICE DE FIGURAS

<b>Figura 1.</b> Características morfológicas de <i>B. cockerelli</i> S.....	10
<b>Figura 2.</b> Características morfológicas de <i>F. occidentalis</i> .....	12
<b>Figura 3.</b> Gradiente ambiental vertical.....	15
<b>Figura 4.</b> Categorías y técnicas de <i>Machine Learning</i> .....	20
<b>Figura 5.</b> Ubicación del área de estudio .....	28
<b>Figura 6.</b> Ubicación de las estaciones meteorológicas.....	32
<b>Figura 7.</b> Diagrama de flujo del modelo propuesto .....	41
<b>Figura 8.</b> Ventana de configuración de una sesión nueva .....	43
<b>Figura 9.</b> Clases de predicción del modelo conjunción ( <i>B. cockerelli</i> S. y <i>F. occidentalis</i> ) en función de temperatura y elevación.....	46
<b>Figura 10.</b> Esquema del Modelo Presión – Estado – Respuesta .....	51
<b>Figura 11.</b> Serie temporal de datos de Inguincho y corrección de outliers .....	55
<b>Figura 12. A.</b> Rango de umbral de desarrollo y rango óptimo de <i>B. cockerelli</i> S. con base a la temperatura media; <b>B.</b> Rango de umbral de desarrollo y rango óptimo de <i>F. occidentalis</i> con base a la temperatura media .....	60
<b>Figura 13. A.</b> Rango de umbral de desarrollo y rango óptimo de <i>B. cockerelli</i> S. con base a la elevación; <b>B.</b> Rango de umbral de desarrollo y rango óptimo de <i>F. occidentalis</i> con base a la elevación.....	64
<b>Figura 14.</b> Histograma (a) y cajas y bigotes (b) de la variable altitud .....	65
<b>Figura 15.</b> Riesgo de presencia de <i>B. cockerelli</i> S. en el pasado, presente y futuro en función de la temperatura y elevación.....	77
<b>Figura 16.</b> Riesgo de presencia de <i>F. occidentalis</i> en el pasado, presente y futuro en función de la temperatura y elevación.....	80
<b>Figura 17.</b> Riesgo de presencia compartida de <i>B. cockerelli</i> S. y <i>F. occidentalis</i> en el pasado, presente y futuro en función a la temperatura y elevación.....	82
<b>Figura 18.</b> Plano cartesiano de activos y pasivos de <i>B. cockerelli</i> S.....	85
<b>Figura 19.</b> Plano cartesiano de activos y pasivos de <i>F. occidentalis</i> .....	87

**UNIVERSIDAD TÉCNICA DEL NORTE**  
**FACULTAD DE INGENIERÍA EN CIENCIAS AGROPECUARIAS Y**  
**AMBIENTALES**  
**CARRERA DE INGENIERÍA EN RECURSOS NATURALES**  
**RENOVABLES**

**“MODELAMIENTO DE PLAGAS EN CULTIVOS DE IMPORTANCIA**  
**ECONÓMICA CON BASE EN ESCENARIOS DE CAMBIO CLIMÁTICO**  
**EN LA PROVINCIA DE IMBABURA”**

Chávez Menacho Richard Paúl

Ponce Maspud Kenny Paola

**RESUMEN**

Los insectos fitófagos como *Bactericera cockerelli* Sulc y *Frankliniella occidentalis* tienen una incidencia y severidad significativa en los principales cultivos de Imbabura. Las condiciones climáticas que influyen en su desarrollo se ven alteradas por el cambio climático, por lo que las superficies agrícolas en la provincia presentarán riesgo de presencia de estas especies. Por tal motivo, la presente investigación desarrolló un modelo de proyección del umbral y condiciones óptimas de desarrollo de *B. cockerelli* S. y *F. occidentalis* con el fin de estimar el riesgo de presencia en Imbabura para los años 1990, 2020 y 2060 basados en los escenarios SSP245 (optimista) y SSP58 (pesimista). Para ello, se utilizó datos de temperatura histórica y elevación, los cuales se entrenaron con los clasificadores automáticos de la herramienta *Machine Learning* del software MATLAB. Además, las funciones de predicción de los clasificadores de mayor precisión se ajustaron en un programa final para proyectar el riesgo en diferentes años. Los resultados evidenciaron que *B. cockerelli* S. tiene una superficie de riesgo alto de 3 014.57 ha en 1990, el cual aumenta a 13 032.22 ha en 2020 y a 16 351.50 ha en 2060 con el escenario optimista, mientras que bajo el escenario pesimista aumenta a 26 965.88 ha. Para *F. occidentalis* la superficie con riesgo alto en 1990 es de 49 000.55 ha el cual aumenta a 69 813.21 ha en 2020 y a 78 225.61 ha en 2060 con el escenario optimista, de manera similar, bajo el escenario pesimista la extensión aumenta a 91 778.66 ha en 2060. En conclusión, el modelo desarrollado tiene una precisión de 99.97% con un costo computacional de 30.16 segundos. En cuanto a las especies analizadas, se evidencia que el cambio climático aumentará las superficies con condiciones favorables para estas especies en el periodo de tiempo de 1990 – 2060 bajo ambos escenarios. Finalmente, se utilizó la matriz de Vester y la metodología PER para proponer estrategias de manejo integrado de estas plagas en cultivos de fréjol, aguacate y papa, con un enfoque en el control biológico y cultural.

**Palabras claves:** Cambio climático, *Machine learning*, *Bactericera cockerelli*, *Frankliniella occidentalis*, Manejo integrado de plagas (MIP).

## ABSTRACT

Phytophagous insects such as *Bactericera cockerelli* Sulc and *Frankliniella occidentalis* have a significant incidence and severity in the main crops of Imbabura. Climate conditions that influence their development are altered by climate change, so agricultural surfaces in the province will present a risk of presence of these species. Therefore, the present research developed a model for projecting the threshold and optimal conditions for the development of *B. cockerelli* S. and *F. occidentalis* to estimate the risk of presence in Imbabura for 1990, 2020, and 2060 based on the SSP245 (optimistic) and SSP58 (pessimistic) scenarios. To do this, historical temperature and elevation data were used, which were trained with automatic classifiers from the Machine Learning tool in MATLAB software. Additionally, the prediction functions of the most accurate classifiers were adjusted in a final program to project the risk in different years. The results showed that *B. cockerelli* S. has a high-risk surface area of 3,014.57 ha in 1990, which increases to 13,032.22 ha in 2020 and to 16,351.50 ha in 2060 under the optimistic scenario, while under the pessimistic scenario it increases to 26,965.88 ha. For *F. occidentalis*, the high-risk area in 1990 is 49,000.55 ha, which increases to 69,813.21 ha in 2020 and to 78,225.61 ha in 2060 under the optimistic scenario, similarly, under the pessimistic scenario the area increases to 91,778.66 ha in 2060. In conclusion, our model has a precision of 99.97% with a computational cost of 30.16 seconds. Regarding the analyzed species, it is evident that climate change will increase the areas with favorable conditions for these species in the period from 1990 to 2060 under both scenarios. Finally, the Vester matrix and the PER methodology were used to propose integrated management strategies for these pests in bean, avocado, and potato crops, with a focus on biological and cultural control.

**Keywords:** Climate change, *Machine learning*, *Bactericera cockerelli*, *Frankliniella occidentalis*, Integrated pest management.



# CAPÍTULO I

## INTRODUCCIÓN

### 1.1 Revisión de antecedentes o estado del arte

La producción de cultivos de importancia económica se encuentra influenciado por factores bióticos y abióticos. Entre los factores bióticos se encuentran los insectos, organismos generalistas que tienen la capacidad de desarrollarse en diversas condiciones ambientales (Aguilar, 2018). Los insectos fitófagos son competidores de los humanos por los recursos generados por la agricultura, pues el daño que causan en diversas especies vegetales reduce el rendimiento y calidad de productos, por lo que se consideran plagas (Oerke & Dehne, 2004). Las plagas y enfermedades de cultivos constituyen las principales limitantes para la seguridad y soberanía alimentaria (Sharma et al., 2017). Debido a ello, se incrementa la intensificación de los campos agrícolas y el deterioro ambiental (Tilman et al., 2011).

Para mitigar los efectos negativos de los insectos plaga, alrededor del mundo, numerosas investigaciones han buscado conocer el rango de distribución, los patrones de crecimiento y propagación de estas especies para evaluar el riesgo de invasión en otras áreas. Inicialmente los modelos matriciales para dinámica poblacional han sido utilizados desde hace varias décadas (Tonnang et al., 2017). Posteriormente, los modelos de fenología permitieron estimar umbrales de temperatura para la supervivencia de especies poiquilotérmicas, además de simular la tasa de reproducción y otros parámetros de la tabla de vida de una especie (B. B. Fand et al., 2014; Khadioli et al., 2014). En la actualidad, los modelos de distribución de especies (SDM, por sus siglas en inglés) se han mejorado y permiten identificar áreas de riesgo de presencia de plagas.

Sin embargo, los nuevos enfoques de análisis y predicción de plagas de cultivos incluyen técnicas de aprendizaje automático o *Machine Learning* (ML) (Kim et al., 2014). Es así como Tripathy et al. (2011) desarrollaron un sistema de toma de decisiones en tiempo real para predecir la ocurrencia de plagas a partir de datos de una red inalámbrica de sensores (*Gaussian Naive Bayes*). De manera similar, Lee & Yun (2023) crearon un modelo para predecir el riesgo de plagas y enfermedades a partir de información ambiental del entorno de desarrollo de cultivos, mediante técnicas de aprendizaje profundo y obteniendo un rendimiento predictivo alto de 0.917 de Área bajo la curva característica operativa del

receptor (AUROC, por sus siglas en inglés). Este modelo es aplicable en diversos cultivos para la prevención de plagas y enfermedades. Por otro lado, en India, Dwivedi et al. (2023) determinaron que, de los distintos modelos de aprendizaje automático evaluados, los modelos de redes neuronales producen predicciones precisas de la infestación de plagas para el té utilizando información de temperatura y precipitación.

En relación con el cambio climático, diversos estudios estiman efectos tanto negativos como positivos sobre las plagas y enfermedades, pues su rango de distribución se verá modificado por el cambio en los patrones de precipitación y aumento de temperatura (Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO], 2008). Por ejemplo, en Australia los modelos CLIMEX para 2090 indican una reducción de las áreas idóneas para el desarrollo de *Plutella xylostella* durante todo el año (Zalucki & Furlong, 2008). Mientras que, en Corea del Sur el cambio climático aumentará sustancialmente la distribución potencial y el riesgo de invasión de *Thrips palmi* en áreas agrícolas (Hong et al., 2019).

Por otro lado, los insectos poiquilotérmicos dependen de la temperatura del ambiente (KocmánKoVá et al., 2009). Yan et al. (2017) predijeron que 76 especies de plagas poiquilotérmicas de cultivos tienen una probabilidad de aumentar su presencia en diferentes regiones del mundo. Dentro de este tipo de plagas se encuentran *Bactericera cockerelli* Sulc (*Hemiptera: Triozidae*), conocido como el psílido de la papa, y *Frankliniella occidentalis* (*Thysanoptera: Thripidae*) comúnmente llamado trips de las flores (Castillo, 2019; Kirk & Terry, 2003). Este último es una plaga polífaga que afecta a diversas especies vegetales en todo el mundo.

*B. cockerelli* S. se encuentra distribuido en Asia, Centroamérica, Europa, Norteamérica, Oceanía y Sudamérica, y según Wan et al. (2020), el 79.06% de la superficie mundial de cultivo de papa y el 96.14% de Sudamérica y Eurasia tienen riesgo de invasión por esta plaga. No obstante, hasta la actualidad en Sudamérica, el psílido se ha reportado únicamente en Colombia, Ecuador y Perú (Organización Europea y Mediterránea de Protección Vegetal [EPPO], 2023). Por su parte, *F. occidentalis*, originaria del oeste de Norteamérica (California), actualmente se encuentra distribuido en África, Asia, Centroamérica, Europa, Norteamérica, Oceanía y Sudamérica.

A nivel regional, existen avances importantes acerca del estudio de *B. cockerelli* S. y *F. occidentalis*. En México, Argentina y Colombia, se han realizado diversas investigaciones mediante técnicas geoestadísticas para conocer las formas de distribución en los campos agrícolas y en sus hospederos, a partir de datos muestreados y su ubicación geográfica usando semivariogramas (Maldonado et al., 2016; Ramírez et al., 2013). No obstante, son escasos los estudios de evaluación del riesgo de presencia de estas plagas en otras áreas y más aún mediante el desarrollo de modelos de aprendizaje automático.

En Ecuador, Toapanta (2020) determinó que *B. cockerelli* S. tiene una probabilidad de distribución actual muy alta en 59 653.60 hectáreas (ha) y alta en 536 610.20 ha, de la superficie de la Sierra ecuatoriana. Además, bajo el escenario pesimista (RCP 8.5) del Modelo MOHC-HADGEM2-ES, la superficie con idoneidad muy alta para *B. cockerelli* S. se proyecta en 87 515 ha y 81 765 ha, para los años 2050 y 2080, respectivamente. Castillo (2019) asegura que, en las provincias de Carchi, Imbabura, Pichincha y Cotopaxi, ya se han reportado pérdidas totales de lotes de papa (*Solanum tuberosum*) durante el periodo entre 2014 y 2018, atribuidas a este psílido. Por su parte, *F. occidentalis* es la plaga más común en 14 florícolas de Pichincha y en especies ornamentales de Latacunga, siendo el insecto más incidente en cultivos ornamentales de varias provincias (Godoy, 2014; Gómez, 2020).

En Imbabura, los reportes de monitoreo de vigilancia a nivel provincial de los últimos años indican que *B. cockerelli* S. y *F. occidentalis* poseen un porcentaje de incidencia y severidad considerable en cultivos de mayor importancia económica (Agencia de Regulación y Control Fito y Zoosanitario [AGROCALIDAD], 2022). En ese sentido, Calderón (2022) generó un modelo de distribución potencial en Imbabura implementando el algoritmo de Máxima Entropía (MaxEnt), en el cual obtuvo que el 0.72% (3 436 ha) de la superficie total de la provincia cumple con un hábitat natural idóneo para el establecimiento de *B. cockerelli* S.

## 1.2 Problema de investigación y justificación

Zumbado & Azofeifa (2018) mencionan que aproximadamente el 3% de las especies de insectos son plagas que afectan en forma negativa y causan daños cuantiosos en cultivos cada año. FAO (2022) estima que, a nivel global, la producción de cultivos es devastada por plagas hasta un 40% cada año. Debido a ello, las plagas y las enfermedades de los vegetales se ubican entre las causas más importantes de la deficiente salud vegetal y pérdida de biodiversidad, ya que se les atribuyen pérdidas en cultivos valoradas en 220 000 millones de USD (FAO, 2020). Esto representa un valor alto, considerando que el aporte de la agricultura al Producto Interno Bruto (PIB) mundial es de aproximadamente 4% al año (FAO, 2022).

Los efectos del cambio climático favorecen la propagación de plagas, las cuales evolucionan y se vuelven cada vez más destructivas, de este modo, amenazan la supervivencia de los organismos vegetales y cultivos de mayor importancia económica (Organización de las Naciones Unidas [ONU], 2021). Según la FAO (2008), los cambios en los patrones de precipitación y aumento de temperatura crean nuevos nichos ecológicos que permiten la propagación y establecimiento de las plagas y enfermedades en nuevas áreas geográficas y su desplazamiento de una región a otra. Los impactos directos sobre las plagas se manifiestan en el desarrollo, la fisiología, la reproducción y la propagación, mientras que, indirectamente inciden en las relaciones con el entorno y con otros organismos (Hannah et al., 2020; Pörtner et al., 2021; Prakash et al., 2014). Esta situación supone un riesgo creciente para la seguridad alimentaria y el medio ambiente.

En Ecuador, en el año 2022, el sector primario representó un aporte de 7.57% al PIB del país (Banco Central del Ecuador, 2022). Por ende, el sector agropecuario es el cuarto más importante a nivel nacional (Haro et al., 2022). No obstante, debido a los daños directos de las plagas y enfermedades, la calidad fitosanitaria de los principales productos se ha visto comprometido (Ministerio de Agricultura, Ganadería, Acuacultura y Pesca [MAGAP], 2016). Según los reportes de Agrocalidad de 2020 a 2022, los insectos *B. cockerelli* S. y *F. occidentalis* tienen una frecuencia de incidencia crítica promedio de 11.17% y 26.41%, respectivamente, en todos los cultivos a campo abierto de Imbabura. Debido a ello, dichas especies son de importancia para la producción agrícola y la economía de Imbabura, ya que

la provincia tiene una superficie 132 626 ha de producción agrícola (AGROCALIDAD, 2022; Instituto Nacional de Estadística y Censos (INEC), 2022).

Toledo & Rodas (2022) mencionan que *B. cockerelli* S. es una plaga de importancia económica e invasora, ya que puede causar desórdenes fisiológicos, enfermedades fitoplásmicas y bacterianas en diversos cultivos hortícolas. Además, es probable que tenga incidencia en más de 20 familias taxonómicas de plantas. Esta situación se agrava aún más por los cambios que ha experimentado en los últimos años en cuanto a su distribución, rango de hospedantes y su capacidad para transmitir patógenos (Prager & Trumble, 2018). MAG (2021) señala que en Ecuador se puede encontrar en una amplia lista de especies vegetales tales como la *S. tuberosum*, *Capsicum annuum*, entre otras.

*F. occidentalis* se encuentra entre los insectos de mayor riesgo del orden Thysanoptera debido a su frecuente presencia y al daño que causa por la extracción de savia, así como también por la transmisión de enfermedades virósicas, principalmente en cultivos hortícolas y plantas ornamentales (Castresana et al., 2008). Además, afecta los folíolos y flores, provocando distorsiones y necrosamientos incoloros intermitentes, de este modo generando graves pérdidas económicas (Muñoz et al., 2008).

El control de plagas agrícolas en el país representa un desafío, pues los controles químicos, biológicos y etológicos se han limitado a determinadas superficies agrícolas, sin un enfoque de prevención en otras áreas con riesgo de establecimiento (Cevallos et al., 2021; Chirinos et al., 2020). Lo anterior se relaciona con la escasez de estudios de estimación de superficies con riesgo de presencia de *B. cockerelli* S. y *F. occidentalis*. En este sentido, el estudio se enmarca en el objetivo 3 del eje Económico y el objetivo 12 del eje de Transición Ecológica del Plan de Creación de Oportunidades 2021 – 2025. En el objetivo 3, específicamente en la política 3.1 que plantea mejorar la productividad agrícola desarrollando programas con un enfoque de conservación y mantenimiento de la fertilidad de los suelos. Del mismo modo, en la política 12.3 del objetivo 12 que busca implementar prácticas sostenibles que fomenten la producción y concientización mediante la investigación, innovación y transferencia de tecnología para la adaptación al cambio climático (Secretaría Nacional de Planificación y Desarrollo [SENPLADES], 2021).

En virtud de lo expuesto, la presente investigación pretende generar un modelo de proyección que estime el riesgo de presencia de *B. cockerelli* S. y *F. occidentalis*, bajo la

perspectiva de aprendizaje automático y considerando el cambio climático. Además de proponer estrategias de manejo integrado de plagas, con el fin de otorgar a las autoridades competentes información fundamental que contribuya como insumo para la creación de programas de prevención y manejo de plagas.

### **1.3. Objetivos**

#### ***1.3.1. Objetivo general***

- Modelar el umbral y condiciones de desarrollo de las plagas *Bactericera cockerelli* S. y *Frankliniella occidentalis* que afectan a los cultivos de importancia económica con base en escenarios de cambio climático en la provincia de Imbabura.

#### ***1.3.2 Objetivos específicos***

- Caracterizar los factores ambientales que influyen en el umbral de desarrollo de *Bactericera cockerelli* S. y *Frankliniella occidentalis*.
- Desarrollar un modelo de proyección del umbral y condiciones de desarrollo de las plagas ante escenarios de cambio climático.
- Proponer un Manejo Integrado de Plagas en los cultivos de mayor importancia económica en la provincia de Imbabura.

### **1.4 Pregunta directriz de la investigación**

¿Cuál es la superficie con riesgo de presencia actual y futura para *Bactericera cockerelli* S. y *Frankliniella occidentalis* en Imbabura?

## CAPÍTULO II

### MARCO TEÓRICO

#### 2.1 Marco teórico referencial

##### 2.1.1 Cultivos agrícolas de importancia económica en Imbabura

La agricultura es fundamental en Imbabura, ya que los cultivos agrícolas no solo son una fuente crucial de ingresos para las familias locales, sino que también generan empleo en el sector rural, contribuyendo así a la reducción de la pobreza en la región (MAG, 2019). Durante el primer semestre de ese año, el sector agrícola generó más de tres millones de puestos de trabajo en todo el país, destacando su impacto significativo en la economía y el empleo a nivel nacional. La Agricultura Familiar Campesina (AFC) provee la mayor cantidad de alimentos que se consume en Ecuador, pues alrededor del 64% de la producción agrícola está en manos de pequeños productores (Martínez, 2013; FAO, 2011).

##### 2.1.1.1 Cultivo de Frejol (*Phaseolus vulgaris* L., 1753)

En Imbabura, en el 2022 la superficie plantada de fréjol seco es de 3 016 ha y cosechada es 2 918 ha, mientras que, la superficie plantada de fréjol tierno es de 618 ha y cosechada es 585 ha. Además, es la leguminosa de grano comestible más importante del Ecuador, por lo tanto, las áreas de la región interandina, que abarcan provincias como Carchi, Imbabura, Pichincha, Cotopaxi, Tungurahua, Chimborazo, Bolívar, Cañar, Azuay y Loja, sobresalen como zonas de producción para el fréjol. El fréjol florece en condiciones específicas que incluyen una cantidad de lluvia que oscila entre 500 mm y 900 mm, temperaturas moderadas de 12 a 18°C, altitudes elevadas que van desde 2 000 a 3 000 m s. n. m., suelos de tipo franco arcilloso con un buen sistema de drenaje y un nivel de acidez del suelo en el rango de 5.6 a 5.7 (INEC, 2022; Instituto Nacional de Investigaciones Agropecuarias [INIAP], 2014a).

##### 2.1.1.2 Cultivo de aguacate (*Persea americana* M., 1768)

De acuerdo con la investigación de Sotomayor et al. (2019), el aguacate ha adquirido una gran importancia a nivel mundial debido a sus propiedades nutraceuticas generando un incremento considerable en el consumo *per cápita* y su demanda en los mercados nacionales e internacionales. En Ecuador, el aguacate se cultiva en varias provincias aprovechando los valles Interandinos, por lo que se encuentra en provincias como; Carchi, Imbabura,

Pichincha, Tungurahua, Azuay y Loja. En Imbabura, en el 2022 la superficie plantada fue 1 468 ha con 942 ha cosechadas. Para el desarrollo del aguacate la altitud se encuentra en un rango de 1 800 a 2 500 m s. n. m. Las temperaturas ideales oscilan entre los 16°C y 20°C. En cuanto a la precipitación, el cultivo necesita 600 a 900 mm de lluvia. Se obtiene un mejor crecimiento en suelos tipo franco a franco arenoso, con un buen sistema de drenaje. Es importante también que el pH del suelo se encuentre en un rango de 5.6 a 7.5 (INEC, 2022; INIAP, 2014b).

### **2.1.1.3 Cultivo de papa (*Solanum tuberosum* L., 1753)**

De acuerdo con el INIAP (2014b) en Ecuador la papa es uno de los cultivos más importantes, por ejemplo, en el año 2014 contó con la participación de más de 82 000 agricultores. En Imbabura la superficie plantada en 2022 fue 406 ha con 350 ha cosechadas. Para el cultivo de la papa, es necesario contar con condiciones climáticas y edáficas específicas. En términos de altitud, entre los 2 600 y 3 600 m s. n. m. El rango óptimo de la temperatura va desde los 15 a 20 °C, no obstante, es importante destacar que el inicio de la tuberización requiere temperaturas inferiores a los 15°C, mientras que durante la tuberización se prefiere un rango de 14°C a 20 °C. En relación con la precipitación, se necesitan aproximadamente entre 600 y 1 500 mm de lluvia por ciclo de cultivo. En lo que respecta al suelo, la papa muestra un mejor crecimiento en suelos francos con buena capacidad de drenaje, profundidad de 30 a 35 cm y un contenido adecuado de materia orgánica. Además, el pH óptimo para su cultivo se encuentra entre 5 y 6 (INEC, 2021; INIAP, 2009).

### **2.1.2 Plagas en cultivos agrícolas**

Según lo establecido por la FAO (2018), una plaga incluye especies vegetales, animales o agentes patógenos dañinos para plantas o productos vegetales. Por su parte, Cardona & Mesa (2015) definen las plagas como organismos cuya densidad poblacional excede un nivel, percibido como inaceptable económicamente. Zumbado & Azofeifa (2018) caracterizan a los insectos plaga por su abundancia y los perjuicios que causan a cultivos y organismos vivos, lo que se traduce en pérdidas económicas y una reducción en la producción de alimentos en el ámbito agrícola. Toledo & Rodas (2022) han identificado a *B. cockerelli* S. como una especie invasora nociva que produce problemas y transmite enfermedades en cultivos hortícolas. De la misma manera, Castresana et al. (2008)



caracteriza a *F. occidentalis* como un agente destructor tanto en cultivos hortícolas como en plantas ornamentales.

### 2.1.2.1 Insectos poiquilotérmicos

Los insectos poiquilotermos son organismos cuyo desarrollo está determinado por la temperatura ambiental. El estado térmico de los insectos varía de acuerdo con las condiciones térmicas de su entorno, pues producen poco calor y lo gastan fácilmente, de modo que, el medio en el que viven es determinante para completar su ciclo de vida (Scharf, 2016). En consecuencia, el ciclo de desarrollo del huevo a adulto será más corto cuanto mayor sea la temperatura (Castro et al., 2016; Velásquez, 2006). La zona donde una especie tiene limitada su temperatura se denomina "zona vital". Dentro de esta área, cada especie tiene su rango térmico óptimo, en la cual sus procesos metabólicos se llevan a cabo de manera más eficiente. En general, dicho rango para la mayoría de este grupo se encuentra entre 25°C y 30 °C. A medida que una especie se aleja de este intervalo, las condiciones de vida se vuelven menos favorables, su desarrollo se retrasa y cuando alcanza el límite, se detiene. A este límite se le conoce como el "punto cero de desarrollo" (Velásquez, 2006).


### 2.1.2.2 Generalidades de *B. cockerelli* S.

*B. cockerelli* S. es una especie de insecto perteneciente a la familia Psyllidae tal como se muestra en la Tabla 1 (Hodkinson, 2009). En cuanto a su morfología, según estudios realizados en laboratorio por MAG (2021) identifica a *B. cockerelli* S. por su tamaño de 2.8-3.2 mm de longitud, 0.6 mm de ancho en el metatórax, y color verde claro en individuos recién pupados, mientras que los adultos maduros son negros con áreas más claras como se muestra en la Figura 1. La cabeza y tórax muestran líneas blancas distintivas, y el abdomen destaca por una franja horizontal en el primer segmento, facilitando la identificación. *B. cockerelli* S.

**Tabla 1.** Taxonomía de *B. cockerelli* S.

<b>Taxón</b>	<b>Categoría</b>
Orden	Hemiptera
Sub-orden	Sternorrhyncha
Super-Familia	Psylloidea
Familia	Psyllidae
Género	Bactericera
Especie	<i>Bactericera cockerelli</i> S.

Por otro lado, MAG (2021) afirma que, esta especie lleva a cabo su ciclo vital en la parte superior de la planta, con una duración de 24 a 35 días, abarcando fases como huevo, ninfa (dividida en cinco fases) y adulto. Las ninfas se ubican en la parte inferior de las hojas y se alimentan activamente de la planta, mientras que los adultos buscan sitios de alimentación en nervaduras de hojas y tallos, succionando la savia del floema. Jácome et al. (2022) detalla las tres etapas del ciclo de vida, desde el huevo hasta el adulto, describiendo las características de cada estadio, destacando que el adulto es verde-amarillento con alas transparentes al emerger.



**Figura 1.** Características morfológicas de *B. cockerelli* S.

**Nota.** Cabeza (Ca), tórax (T), abdomen (Ab), antenas (A), banda blanca del primer segmento abdominal (BPS), banda transversal (BT), banda blanca en forma de V invertida (BV), alas en forma de techo de doble caída (W).

**Fuente:** MAG (2021).

La distribución de esta especie es amplia en la Sierra ecuatoriana, pues ha sido detectada en varias zonas productoras de la región, incluyendo Carchi, Chimborazo, Cotopaxi, Pichincha, Tungurahua, Loja e Imbabura (Castillo et al., 2018; Manobanda, 2020; Toapanta, 2020). Rubio et al. (2011) destacaron que la altitud donde se la encuentra y es óptima para su desarrollo es entre los 2 600 a 3 200 m s.n.m. De este modo, por encima de los 3 500 m s. n. m., se observa una disminución significativa en las poblaciones. Por su parte, Falconez (2020) señala que el psílido es evidente a altitudes superiores a 1 000 m s. n. m. Mientras que, Calderón (2022) afirma que la especie podría encontrarse en altitudes que varían desde 2 618 m s.n.m., hasta 3 103 m s. n. m.

Por otro lado, en un estudio reciente en Ecuador, Jácome et al. (2022) encontraron variaciones en la duración del ciclo biológico en diferentes lugares, destacando la influencia de temperaturas óptimas para el desarrollo. En cuanto al umbral de desarrollo, Abdullah (2008) menciona que las condiciones para un desarrollo óptimo son de 26-27 °C y 60-70 % de humedad relativa. Según Tran et al. (2012) el psílido tarda unos 90.3 días en completar su desarrollo a 8 °C, pero este tiempo se reduce a 25.5 días a 32 °C, lo que evidenció las altas tasas de mortalidad a estas temperaturas extremas (8 y 32 °C) en plantas hospedantes con una humedad del 50 al 60 %.

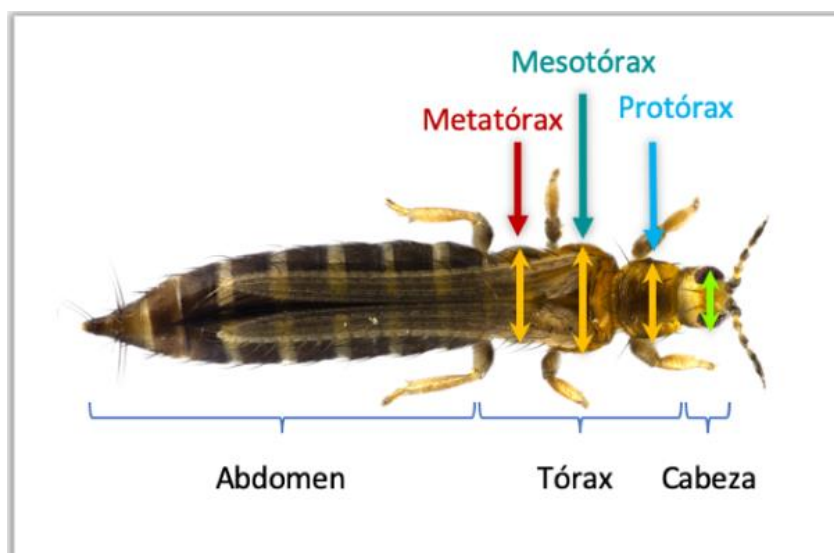
### 2.1.2.3 Generalidades de *F. occidentalis*

*F. occidentalis* también conocido el trips de las flores es una especie perteneciente a la familia Thripinae tal como se muestra en la Tabla 2 (Palacios et al., 1994).

**Tabla 2.** Taxonomía de *F. occidentalis*

<b>Taxón</b>	<b>Categoría</b>
<b>Orden</b>	Thysanoptera
<b>Familia</b>	Tripidae
<b>Subfamilia</b>	Thripinae
<b>Género</b>	Frankliniella
<b>Especie</b>	<i>Frankliniella occidentalis</i> Pergande, 1895

La morfología muestra variaciones estacionales en su coloración, con adultos invernales de tono marrón oscuro y generaciones de verano de tono más claro, mientras que los adultos inmaduros presentan manchas oscuras en el abdomen como se muestra en la Figura 2 (Lacasa & Martínez, 2018). En cuanto al ciclo biológico, de acuerdo con el estudio de Cardenas & Corredor (1989) comienza con huevos de forma reniforme y dimensiones de 0.27 mm de largo por 0.11 mm de ancho. Las ninfas emergen entre el cuarto y quinto día, y el segundo instar ninfal tiene una duración de 5 a 8 días, con un cuerpo amarillo claro. El ciclo de desarrollo incluye prepupa (4-6 días) con cono bucal membranoso y pupa (3-5 días) con ojos rojos y antenas cubiertas por membrana. En la etapa adulta, las hembras tienen una longitud promedio de 1.7 mm, con una longevidad de 60 a 121 días en condiciones de laboratorio (Cardenas & Corredor, 1989; Palacios et al., 1994).



**Figura 2.** Características morfológicas de *F. occidentalis*  
**Fuente:** Tomado de Torrado (2019)

Los daños que ocasiona son principalmente en los órganos de las plantas debido a la afección directa: en cuanto a su follaje, presenta pequeñas deformaciones continuas en forma de cicatrices; las flores reducen su tamaño y presentan manchas irregulares de color blanco, que posteriormente se necrosan debido a la perforación de los tejidos superficiales y succión de contenido, provocando la muerte del tejido circundante. No obstante, dichas afecciones dependen de la densidad poblacional en el cultivo. Además, causa un daño indirecto al ser vector del virus de la marchitez manchada del tomate (TSWV) (Palacios et al., 1994). Por otro lado, la duración del ciclo biológico de la especie se ve influenciada por factores como temperatura y humedad. Lacasa & Martínez (2018) mencionan que la temperatura mínima requerida para su desarrollo es de 10 °C, en contraste, a 35 °C, la mortalidad larval aumenta significativamente. Pujota (2013) expone que el rango de temperatura óptima varía de 18 y 25 °C con una duración de 19 días de ciclo biológico.

### **2.1.3 Climatología**

La climatología es la ciencia encargada del estudio del clima y sus variaciones a lo largo del tiempo cronológico (Instituto Nacional de Meteorología e Hidrología [INAMHI], 2013). De este modo, permite describir los cambios de las variables climáticas como precipitación, temperatura, viento, presión barométrica, radiación, entre otras. Estos datos posteriormente son utilizados para crear series de registros climáticos, documentando su comportamiento y generando información histórica (Santillán & Zamora, 2021). El clima es cambiante en diversas escalas de tiempo y espacio, dicha fluctuación se ha presentado a través de la

historia desde años (variación climática interanual) a milenios (cambios climáticos globales). Zea et al. (2001) afirman que estas oscilaciones se han originado por los cambios en la forma de interacción entre los componentes del sistema climático (la atmósfera, los océanos, la superficie de la tierra y las placas de hielo) y sus diferentes factores condicionantes.

### **2.1.3.1 Variables climáticas**

Las variables climáticas son aquellas condiciones y/o propiedades de la atmósfera que en su conjunto definen el estado físico del clima en un espacio y tiempo determinado. Además, son susceptibles de una valoración cuantitativa y cualitativa, para el análisis de sus comportamientos (Zea et al., 2001).

- **Variable temperatura**

La temperatura es la cantidad de calor específico presente en una masa de aire en un lugar y tiempo determinado (Barros & Troncoso, 2010). Como elemento constitutivo del clima presenta variaciones que inciden directa o indirectamente en las especies. Fernández & Johnston (2006) afirman que la temperatura altera diversas funciones vitales como, por ejemplo, la velocidad de las reacciones químicas, especialmente las actividades enzimáticas que da como resultado cambios en la velocidad de crecimiento vegetal, por ende, es el principal factor que determina la adaptación de las especies vegetales. Del mismo modo, el ciclo de vida de las especies de animales depende de la temperatura, especialmente los insectos poiquilotérmicos, por ende, la temperatura es una de las variables climáticas de mayor importancia para los insectos (Scharf, 2016).

### **2.1.3.2 Factores climáticos**

Los factores climáticos se refieren a los diversos elementos que contribuyen a moldear el clima de una región. Estos factores interactúan de manera compleja para determinar las condiciones climáticas de un lugar específico y modifican los elementos climáticos. De este modo, da lugar a los diferentes tipos de clima en la Tierra (Barros & Troncoso, 2010).

- **Factor altitud**

La altitud se define como la distancia vertical de un punto de la Tierra con respecto al nivel del mar (m s. n. m.). Es un factor clave para determinar el clima de una región, pues a medida que uno asciende a mayores altitudes, la temperatura tiende a disminuir, es decir que

la temperatura es inversamente proporcional a la altitud, se ha determinado que por cada 1 000 m s. n. m., la temperatura disminuye 6.4°C lo que se conoce como gradiente térmico (Barros & Troncoso, 2010). La altitud de una región caracteriza los distintos pisos climáticos. Por ende, influye en la distribución de especies de plantas y animales.

### **2.1.3.3 Estaciones meteorológicas**

Las estaciones meteorológicas son instalaciones ubicadas en un determinado lugar con el fin de realizar mediciones de las variables meteorológicas mediante diferentes instrumentos y/o equipos instalados, para posteriormente caracterizar las condiciones del estado físico de la atmósfera en las diferentes zonas del país (Barros & Troncoso, 2010). En Ecuador existe una red meteorológica compuesta por diferentes tipos de estaciones que se diferencian por los instrumentos de medición y la frecuencia de las observaciones. El Instituto Nacional de Meteorología e Hidrología (INAMHI) es la institución meteorológica e hidrológica principal del país cuyo objetivo es generar y gestionar íntegramente información hidrometeorológica, cuenta con una red de estaciones meteorológicas convencionales y automáticas, los cuales generan información fundamental para poner a disponibilidad de la ciudadanía (Instituto Nacional de Meteorología e Hidrología [INAMHI], 2023).

### **2.1.3.4 Información climática de TerraClimate**

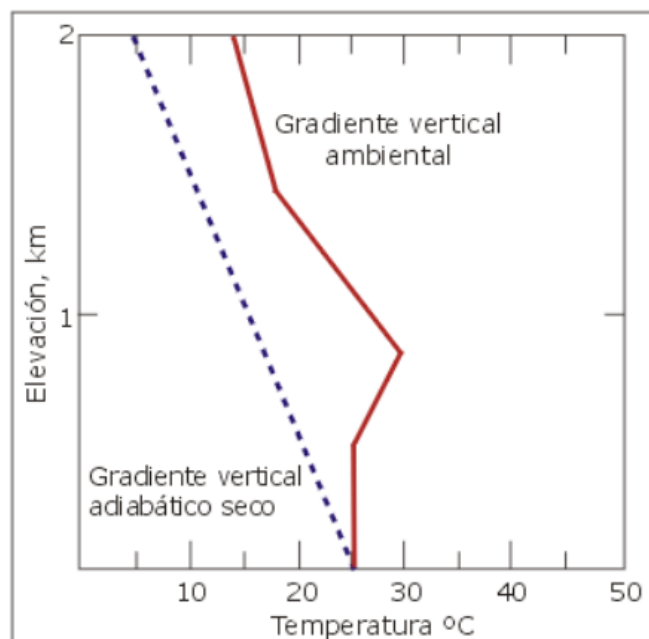
TerraClimate es un conjunto de datos globales de alta resolución que proporciona datos mensuales sobre el clima y el balance hídrico climático desde 1958 hasta 2015 (Abatzoglou et al., 2018). El conjunto de datos incluye variables climáticas primarias como precipitación, temperatura máxima, temperatura mínima, presión de vapor, acumulación de precipitación, radiación de onda corta en la superficie descendente, velocidad del viento., así como las siguientes variables derivadas: Evapotranspiración de referencia (ASCE Penman-Montieth), Escorrentía, Evapotranspiración real, Déficit de agua climática, Humedad del suelo, Equivalente de agua de nieve, Índice de severidad de sequía de Palmer, Déficit de presión de vapor.

El conjunto de datos está disponible a una resolución espacial de 4.64 km aproximadamente y una cuadrícula de 0.5°. Para obtener la alta resolución espacial, TerraClimate combina normales climatológicas de alta resolución espacial del conjunto de datos WorldClim con datos variables en el tiempo de CRU Ts4.0 y el reanálisis japones de 55 años (JRA55) utilizando interpolación asistida por el clima. Dicho de otro modo, el

proceso utiliza anomalías interpoladas de CRU Ts4.0/JRA55 para ajustar la climatología de alta resolución espacial de WorldClim, generando así un conjunto de datos de alta resolución espacial que abarca un período temporal más amplio (Abatzoglou et al., 2018). Estos conjuntos de datos son un recurso valioso para la investigación climática. Se han utilizado en varios estudios para analizar el cambio climático, los incendios forestales y el impacto del clima en los insectos defoliadores (Abdi, 2019; Lemenkova, 2022).

### 2.1.3.5 Gradiente vertical ambiental

De acuerdo con el Centro Panamericano de Ingeniería Sanitaria y Ciencias del Ambiente (2005), el perfil real de la temperatura del aire en el entorno muestra cómo cambia la temperatura según la elevación. Este cambio, a veces llamado gradiente vertical prevalente o atmosférico, se debe a complicadas interacciones meteorológicas y generalmente implica que la temperatura disminuye a mayor altitud. Esto es crucial para entender cómo el aire se mueve verticalmente, ya que la temperatura del aire cercano afecta si una porción de aire asciende o desciende. En la Figura 3, cuando la temperatura aumenta con la altitud, se llama inversión de la temperatura.



**Figura 3.** Gradiente ambiental vertical  
Fuente: CEPIS (2005)

### 2.1.4 Cambio climático

La Convención Marco de las Naciones Unidas sobre el Cambio Climático (CMNUCC, 1992) define el cambio climático como una alteración a largo plazo en las condiciones

climáticas, la cual puede ser resultado tanto de las actividades humanas como de procesos naturales, como la actividad de las placas tectónicas, cambios en la radiación solar que alcanza la Tierra y procesos bióticos, entre otros. Además, es importante mencionar que, el cambio climático incluye; al calentamiento global, considerada como el aumento de la temperatura superficial promedio de la tierra debido al aumento de las concentraciones de Gases de Efecto Invernadero (GEI) y demás efectos adversos, como la alteración del equilibrio de ecosistemas que sustentan la vida y la biodiversidad, así como también fenómenos meteorológicos extremos, entre estas inundaciones, olas de calor, sequias más intensas y frecuentes, entre otras (Pallmall, 2021).

Lo anterior genera una incertidumbre que cada vez más se ve acentuada, pues desde la industrialización hasta el presente las diferentes actividades antrópicas como, por ejemplo, el uso de combustibles fósiles, que se han intensificado, lo que está causando un cambio alarmante en el clima global (Panel Intergubernamental del Cambio Climático [IPCC], 2014). Además, la IPCC prevé que la variabilidad climática sin adaptación socavarán la soberanía alimentaria y elevará la incertidumbre en la producción de muchos cultivos en los países tropicales, pues las especies de plantas pueden ser afectadas al límite de su extinción y obligadas a adaptarse en ambientes hostiles y, en contraste, las plagas y enfermedades aumentarán.

#### **2.1.4.1 Vías Socioeconómicas compartidas (SSP)**

Las Vías Socioeconómicas Compartidas (SSP, por sus siglas en inglés) son escenarios en las que se basan las proyecciones de los modelos del Proyecto de Intercomparación de Modelos Acoplados en su sexta fase (CMIP6), que describen futuros alternativos de desarrollo de la sociedad en ausencia de políticas climáticas de adaptación y mitigación, pues a diferencia de las Vías de Concentración Representativas (RCP) de la fase anterior (CMIP5) incluyen factores socioeconómicos como la economía, la desigualdad, el crecimiento poblacional, entre otros., que inciden sobre los niveles de emisiones de GEI, además, son basados en datos actualizados sobre las tendencias recientes de las emisiones GEI (O'Neill et al., 2016; Try et al., 2022). Cabe mencionar que, existe una mayor sensibilidad climática de equilibrio (ECS) con un rango de temperatura creciente de 1.5 a 4.5 °C (Pörtner et al., 2021).



En este sentido, las cinco narrativas diseñadas representan la manera en cómo podría evolucionar las tendencias de desarrollo global en las décadas siguientes (2015-2100) y los desafíos para la adaptación y mitigación (O'Neill et al., 2017). SSP1, "Sostenibilidad – Tomando el camino verde", describe un cambio gradual hacia la sostenibilidad, priorizando el bienestar humano sobre el crecimiento económico. Por otro lado, SSP2, "Mitad del camino", el mundo sigue tendencias históricas, con desafíos moderados de mitigación y adaptación, y una disminución progresiva en el uso de combustibles fósiles y recursos, aunque los sistemas ambientales continúan degradándose. A su vez, SSP3, "Rivalidad regional – Un camino rocoso", refleja la fragmentación internacional, el resurgimiento del nacionalismo y conflictos regionales, priorizando seguridad energética y alimentaria interna a expensas del desarrollo global, con un consumo intensivo de recursos, aumento de la desigualdad y degradación ambiental.

En contraste, SSP4, "Desigualdad – Un camino dividido", destaca la creciente desigualdad entre países y dentro de ellos, con una élite educada liderando la economía global y una población marginada con mala calidad de vida. El crecimiento económico es moderado en países desarrollados y las políticas ambientales presentan desafíos variables en diferentes regiones. Los desafíos para la adaptación son altos. Finalmente, SSP5, "Desarrollo impulsado por combustibles fósiles", asume un alto desarrollo económico y social basado en el uso intensivo de combustibles fósiles, energía y otros recursos, con altas emisiones de contaminantes y su subsecuente aumento de aproximadamente 5 °C para 2100, presentando desafíos altos en mitigación y bajos en adaptación (Escoto et al., 2017).

#### **2.1.4.2 Escenarios estándar (ScenarioMIP)**

El Scenario Model Intercomparison Project (ScenarioMIP) logró un consenso sobre cuatro combinaciones denominadas “escenarios estándar”, que se desarrollaron a partir de la relación entre los niveles de forzamiento radiactivo ( $W/m^2$ ) con los escenarios SSP, de este modo, cada una se encuentra codificada con el nombre de la vía básica seguido por el valor del forzamiento radiativo para el año 2100 (Riahi et al., 2017).

- **SSP1-2.6:** Escenario ajustado con base en el RCP2.6 para simular un desarrollo optimista con la meta de mantener el planeta debajo de 2°C. El valor de forzamiento es de 2.6  $W/m^2$ .

- **SSP2-4.5:** Posee 4.5 W/m<sup>2</sup> y como un ajuste del RCP4.5 manifiesta una tendencia media de futuras emisiones de GEI. Además, del mismo modo que el anterior, asume que se están tomando medidas de protección climática.
- **SSP3-7.0:** Con 7 W/m<sup>2</sup>, este escenario cierra la brecha entre los escenarios más catastróficos del CMIP5: RCP6.0 y RCP8.5. Se ubica en la parte media – alta del rango completo de escenarios.
- **SSP5-8.5:** Con 8.5 W/m<sup>2</sup>, este escenario se puede considerar como una reedición del RCP8.5, pero articulado con consideraciones socioeconómicas. Es el escenario más catastrófico.

### ***2.1.5 Métodos de modelado de especies***

La modelización de especies se refiere al desarrollo de modelos de comportamiento que permiten la toma de decisiones, en términos coloquiales un modelo es similar a un tablero en el cual se enumeran las variables que determinan la conducta de una especie y los factores externos que condicionan e inciden en la misma (Pérez, 2021). Existen diversos enfoques, métodos y herramientas para el modelado de especies de insectos, comúnmente utilizadas para predecir la dinámica de las poblaciones en presencia de diversos factores bióticos y abióticos y conocer la manera en cómo afectan dichos factores en las interacciones con sus enemigos naturales, así como también para describir los patrones de propagación y el riesgo de invasión a otras áreas, por otro lado, en los últimos años, las innovaciones en los métodos desarrollados se enfocan en explicar y predecir los efectos del cambio climático en la supervivencia y ciclo biológico de las plagas (Tonnang et al., 2017).

Se han desarrollado métodos y herramientas para el modelado de insectos de cultivos bajo distintos enfoques (Tonnang et al., 2017). En este sentido, la Tabla 3 resume los principales enfoques, modelos y herramientas.

**Tabla 3.** Enfoques y modelos para el modelado de plagas

Enfoque	Modelos	Descripción	Software y/o herramientas
Modelación del crecimiento y la dinámica de las poblaciones de plagas de insectos.	Modelos matriciales	Son determinados a partir de una tabla de vida que incluyen la estructura de edad de la población, las etapas del ciclo de vida y ciertos factores, con el fin de conocer la probabilidad de supervivencia, mortalidad y fecundidad.	Cadenas de Markov, modelo de Leslie y modelo de Lefkovitch.
	Modelos de fenología	Permite determinar parámetros de la tabla de vida como la tasa intrínseca de aumento natural ( $r_m$ ), tasa de reproducción neta ( $R_0$ ), tasa infinita de aumento, tiempo medio de generación ( $G$ ) y tiempo de duplicación ( $t$ ), a través de experimentos con temperaturas constantes y el uso de funciones matemáticas que explican el modelo fenológico.	Insect Life Cycle Modeling (ILCYM)
	Ecuaciones diferenciales	Su objetivo es comprender y replicar los patrones de cambios poblacionales a lo largo del tiempo para una especie en particular.	Ecuaciones diferenciales continuas y discretas. Por ejemplo, Lotka-Volterra
	Modelo de competición	Permiten realizar simulaciones numéricas aplicando la teoría de la estabilidad y análisis cuantitativos para conocer las interacciones entre dos o más especies, los cuales compiten por el mismo recurso (cultivo).	Sistemas de ecuaciones diferenciales
Identificación de áreas de riesgo de invasión de plagas y prioridad de manejo, así como para la toma de decisiones en el contexto del cambio climático.	Modelos inductivos	Estos modelos se basan en la teoría de que las condiciones idóneas de una especie se relacionan con la ocurrencia en un lugar determinado, es decir, se estima la probabilidad de ocurrencia de una especie en otras áreas relacionando el/los factor/es prevaeciente/s del lugar de ocurrencia (de arriba hacia abajo).	GARP MaxEnt
	Modelos deductivos	Estima la idoneidad ambiental de una especie mediante el modelado de su respuesta a las variables climáticas.	ILCYM
	Modelo inductivo y deductivo	Permite predecir las regiones donde una especie puede sobrevivir y reproducirse, a partir del supuesto de que se puede inferir las condiciones climáticas que la especie tolera conociendo su ocurrencia.	CLIMEX


**Fuente:** (Tonnang et al., 2017)

### 2.1.6 Machine Learning o Aprendizaje Automático

El aprendizaje automático o *Machine Learning* (ML) se considera un subcampo de la inteligencia artificial (IA) que integra y se apoya de disciplinas científicas como la estadística, la teoría de la información y la ciencia cognitiva (Ławrynowicz & Tresp, 2014). Un modelo de ML tiene la capacidad de aprender de datos de entrada por sí mismos con base a la experiencia, es decir, sin la necesidad de una programación por parte del usuario. Esto debido a que, los algoritmos que se emplean permiten que un sistema aprenda iterativamente (reiteradamente) de diferentes datos de entrada para mejorar, describir datos y predecir resultados (Hurwitz & Kirsch, 2018)

#### 2.1.6.1 Categorías de Aprendizaje Automático

Existen diferentes categorías y/o técnicas de ML (Figura 4), entre estas se encuentran los modelos no supervisados, supervisados y aprendizaje por refuerzo (Attri et al., 2023; Hurwitz & Kirsch, 2018).



**Figura 4.** Categorías y técnicas de *Machine Learning*  
Fuente: Aguirre & Gallegos (2019).

- **Aprendizaje No Supervisado**

Son modelos cuyos algoritmos no tienen un conocimiento a priori de las características propias de los datos y sus etiquetas, por lo que tienen la finalidad de comprender la naturaleza de grandes cantidades de datos para clasificarlas en función de los patrones o agrupaciones encontradas (Hurwitz & Kirsch, 2018). Es decir, clasifican los datos en grupos de características semejantes y agrega etiquetas. En esencia, es un proceso de datos previo del aprendizaje supervisado.

- **Aprendizaje Supervisado**

Son modelos cuyos algoritmos tienen un conocimiento a priori de los datos, es decir, ya existe cierta comprensión de la manera en cómo se clasifican los datos, de este modo, los algoritmos al conocer la entrada (atributos) y salida (etiquetas), tienen la finalidad de facilitar la toma de decisiones y predecir resultados futuros (Ławrynowicz & Tresp, 2014). Wilson (2019) afirma que durante el entrenamiento los algoritmos usados, generalmente de clasificación y regresión, buscan patrones de los datos que se relacionan con las salidas y, posterior al entrenamiento, cuando se suministre nuevas entradas, los algoritmos tendrán la capacidad de decidir la etiqueta más pertinente con la que se clasificaran. Por lo tanto, este tipo de modelos llevan a cabo un proceso iterativo de análisis de datos sin la intervención humana (Hurwitz & Kirsch, 2018).

- **Aprendizaje Semisupervisado**

Se encuentra entre el aprendizaje supervisado y no supervisado, pues combina datos no etiquetados y etiquetados para el entrenamiento de un modelo. Los datos no etiquetados tienen el fin de descubrir patrones y los datos etiquetados guían el proceso de aprendizaje (Attri et al., 2023).

- **Aprendizaje por refuerzo**

El aprendizaje del algoritmo se lleva a cabo cuando este interactúa tomando acciones en un entorno, de este modo recibiendo penalizaciones o recompensas por dichas acciones. El objetivo es que, en la retroalimentación, el algoritmo ajuste su comportamiento y su toma de decisiones para obtener mayores recompensas y mejorar el rendimiento del sistema (Attri et al., 2023).

### 2.1.6.2 Algoritmos de Aprendizaje Automático

Para resolver un problema existe varios algoritmos de aprendizaje automático que se la puede emplear, no obstante, es un desafío seleccionar el correcto, por ende, es esencial comprenderlos para identificar el más pertinente. En este sentido en la Tabla 4 se detalla de forma general los algoritmos de aprendizaje automático más utilizados (Attri et al., 2023).

**Tabla 4.** Algoritmos de aprendizaje automático

Algoritmo	Descripción
K-Vecinos más cercanos (KNN, por sus siglas en inglés)	Empleado para clasificar un conjunto de datos a partir de otros conjuntos de datos ya categorizadas y con conocimiento de sus clases (Gonzales, 2019). Es un clasificador robusto y versátil con aplicación en el reconocimiento de patrones, la minería de datos y la detección de intrusos.
Algoritmos de árbol de decisión	Empleado para tareas de clasificación y regresión. Tiene una estructura jerárquica en forma de árbol, pues descompone en una secuencia de etapas el conjunto de datos de entrenamiento. Cada rama representa una decisión en función de una condición y los nodos de hoja son el resultado de la decisión.
Máquina de vectores de soporte (SVM, por sus siglas en inglés)	Empleado para tareas de clasificación, aunque también tareas de regresión. Tiene como objetivo definir un límite de decisión óptimo, como una línea o hiperplano, que pueda separar eficientemente el espacio de n dimensiones en clases, lo que permite la rápida clasificación de puntos de datos nuevos en situaciones futuras.
Regresión logística	Empleado para resolver problemas de clasificación binaria. Predice la probabilidad de un evento binario (variable dependiente) en función de otras variables y la relación entre estas, mediante el uso de una función sigmoidea.
Regresión lineal	Es empleado ampliamente para predecir valores futuros de los datos en función de valores históricos. Permite modelar relaciones entre variables, de manera que, cuantifica su intensidad de correlación.
Algoritmo ingenuo de Bayes	Empleado para resolver problemas de clasificación binaria y multiclase. Permite asignar una clase a un conjunto de datos o dicho de otro modo colocar etiquetas. Se basa en el teorema de bayes y utiliza la regla de la máxima a posteriori (MAP).
Bosque aleatorio	Ejecuta tareas de clasificación y regresión. Este algoritmo, crea múltiples árboles a partir de un muestreo aleatorio e independiente de los datos y combina sus predicciones para obtener un resultado más preciso, además, tiene la capacidad de procesar conjuntos de datos de variables categóricas y continuas.

**Fuente:** (Attri et al., 2023; Hurwitz & Kirsch, 2018)

### **2.1.6.3 Validación cruzada *K-Fold***

El método de Validación cruzada *K-Fold* implica dividir el conjunto de datos en *K* subconjuntos de igual tamaño, y usar cada subconjunto como un conjunto de prueba para validación mientras que los *k-1* subconjuntos restantes se usan para el entrenamiento (James et al., 2013; Marcot & Hanea, 2021). Este proceso se repite *K* veces, y cada subconjunto se utiliza como conjunto de prueba exactamente una vez. Luego se promedian las métricas de rendimiento de cada pliegue para obtener una medida de rendimiento general del modelo. De este modo, proporciona una evaluación más completa del rendimiento del modelo y su capacidad para generalizar a nuevos datos (Wong, 2015). Esta técnica es particularmente valiosa para abordar cuestiones como el sobreajuste y garantizar que las métricas de rendimiento del modelo sean confiables y precisas (Lyu et al., 2022)

### **2.1.7 Estrategias de Manejo Integrado de Plagas (MIP)**

El Manejo Integrado de Plagas (MIP) es una combinación de distintas medidas y estrategias de control de plagas y enfermedades para reducir el riesgo al medio ambiente, a la salud humana y el costo de producción (Agencia de Cooperación Internacional del Japón [JICA], 2010). Yamberla (2022) menciona que consiste en la aplicación de programas de monitoreo, selección y ejecución de estrategias para el control de plagas de modo que el daño económico se mantenga debajo del umbral aceptable. Como un enfoque integral, el MIP establece previamente estrategias de prevención para mantener la sanidad vegetal tales como la preparación y abonamiento del suelo, riego, drenaje, entre otras., hasta mejorar la situación física. Así como también, el monitoreo diario para evaluar el estado del cultivo y las anomalías como la aparición de plagas y enfermedades.

Dentro de las estrategias del manejo integrado de plagas se encuentra el control biológico, que implica el uso de enemigos naturales y microorganismos para regular las poblaciones de plagas (Nicholls, 2008). Según Jacas et al. (2005), en el control biológico se pueden distinguir dos tipos de competencia: la microbiológica y la macrobiológica. La competencia microbiológica se manifiesta al utilizar microorganismos como virus, bacterias, hongos, entre otros. Sin embargo, la competencia macrobiológica se suscita con el uso de artrópodos como insectos, ácaros

y arañas, los cuales compiten con la plaga objetivo. Por otro lado, el control cultural busca crear condiciones desfavorables para las plagas y óptimas para la acción de sus enemigos naturales a través de técnicas como la rotación de cultivos, el manejo de malezas, cultivos intercalados y otras estrategias destinadas a mejorar la biodiversidad (Altieri & Nicholls, 1994).

En cuanto al control químico, este consiste en la aplicación prudente de productos químicos naturales o sintéticos que contribuyan a mantener las plagas a un nivel poblacional reducido (Yamberla, 2022). Se enfatiza en la selección de opciones menos tóxicas y en el ataque dirigido a especies de plagas específicas. De manera similar, el control físico es un método que implica el uso de trampas, barreras y otros medios físicos para evitar el ingreso de plagas en los cultivos e interrumpir su actividad fisiológica (Martínez, 2010). Por último, el control genético es una técnica que comprende la esterilización de especies mediante la radiación, hibridación y el uso de sustancias químico-esterilizantes para reducir la población de plagas.

## **2.2. Marco legal**

En Ecuador, la normativa legal que regula el funcionamiento del estado tiene un orden jerárquico de aplicación. En el Art. 425 de la Constitución de la República del Ecuador publicada en el Registro Oficial Nro. 449 en el año 2008, se establece que el orden jerárquico de aplicación de las normas es la siguiente: constitución, norma suprema del estado; los convenios, acuerdos y tratados internacionales; las leyes orgánicas; las leyes ordinarias y/o especiales; las normas regionales y las ordenanzas distritales; los decretos y reglamentos; las ordenanzas, los acuerdos y las resoluciones; y los demás actos y decisiones de los poderes públicos (Constitución de la República del Ecuador, 2008). En virtud de lo señalado, a continuación, se exponen los cuerpos legales en el cual se encuentra enmarcada la presente investigación, establecidas de acuerdo con el análisis de las normas de los distintos eslabones jerárquicos de la Pirámide de Kelsen.

### ***2.2.1 Constitución de la República del Ecuador***

La constitución de la República del Ecuador es la norma suprema nacional que ofrece lineamientos y disposiciones generales en el ámbito del desarrollo y ambiente, en los



cuales se sustenta la presente investigación. En este sentido, encontramos el Art. 13 del Título II-Derechos, Capítulo segundo, Sección primera que consagra el derecho al acceso a alimentos sanos y nutritivos producidos a nivel local, de manera similar, el Art. 281 del Título VI, Régimen de Desarrollo, Capítulo tercero, que trata acerca de la responsabilidad del estado de asegurar el desarrollo de la investigación científica e innovación tecnológica que permita garantizar la soberanía alimentaria. Además, el Art. 319 del Título VI, Capítulo sexto, Sección primera, que indica que el estado alentará la producción que satisfaga la demanda interna y garantice el buen vivir de la población, y velando por los derechos de la naturaleza (Constitución de la República del Ecuador, 2008).

### ***2.2.2 Objetivos del Desarrollo Sostenible (ODS)***

En 2015, las Naciones Unidas adoptaron los Objetivos de Desarrollo Sostenibles (ODS) para llevar a cabo acciones globales con el fin de proteger el planeta y garantizar el buen vivir, de manera que en el desarrollo exista un equilibrio entre los sistemas social, económico y ambiental. De este modo, encontramos el objetivo 2: hambre cero, en el cual resalta el objetivo 2.4 que habla acerca de la transición hacia sistemas agroalimentarios sostenibles con el fin de lograr una producción sostenible y resiliente de alimentos y fortalecer la capacidad de adaptación al cambio climático, sequías, inundaciones y otros eventos meteorológicos extremos (Naciones Unidas, 2018).

### ***2.2.3 Convención Marco de las Naciones Unidas Sobre el Cambio Climático (CMNUCC)***

La CMNUCC es una de las tres convenciones que se crearon tras la Cumbre de la Tierra, en Río de Janeiro, en 1992 y ratificado por Ecuador un año más tarde en 1993. Entre sus objetivos se encuentra asegurar que la producción de alimentos no se vea amenazada y permitir que el desarrollo económico prosiga de manera sostenible. Su característica fundamental se basa en la conciencia de que todos los países están expuestos a los impactos del cambio climático y busca reducir sus consecuencias mediante acciones, especialmente en países en vías de desarrollo que son más susceptibles (Secretaría de la CMNUCC, 1992).

#### **2.2.4 Código Orgánico del Ambiente (COA)**

En Ecuador, el Código Orgánico del Ambiente (CODA) publicado en el Suplemento del Registro Oficial N° 983 del 12 de abril de 2017, constituye la norma más importante en materia ambiental. De este modo, aborda temas de gran relevancia para la presente investigación, como el cambio climático, en ese sentido, encontramos el Art. 248 del Capítulo I, Título I, Libro cuarto del cambio climático, el cual hace referencia a los fines del Estado en materia de cambio climático para reducir y mitigar sus efectos, dentro de estos objetivos se resalta el objetivo 2 que hace énfasis en incentivar la educación, investigación, innovación y transferencia de tecnología, del mismo modo, el objetivo 8 que busca garantizar el acceso a la información necesaria que permita gestionar y crear programas de prevención de los riesgos originados por cambio climático.

#### **2.2.5 Reglamento al Código Orgánico del Ambiente (RCODA)**

El Reglamento al Código Orgánico del Ambiente (RCODA), Registro Oficial N° 507 del 12 de junio de 2019, es un instrumento que establece los lineamientos necesarios para la aplicación de lo dispuesto en el CODA. De este modo, se registran artículos referentes al fomento de las actividades agrícolas sostenibles, la mitigación y adaptación al cambio climático y la transferencia de tecnología. En el Libro Tercero, Título IX hace referencia a la producción y consumo sostenible mediante el Art. 667; el cual menciona que se promoverá la adopción de prácticas de producción y consumo sostenibles que contribuyan a mejorar el desempeño ambiental, mejorar la competitividad y reducir los riesgos para la salud humana y ambiente.

Por su parte, en el Libro Cuarto, Título I, Capítulo I, Art. 670, hace mención que la gestión del cambio climático se basa en el conjunto de políticas, estrategias, planes, programas, proyectos, medidas y acciones orientadas a abordar el cambio climático, considerando el literal A de adaptación y D que cita el desarrollo, innovación, desagregación y transferencia de tecnología. Asimismo, el capítulo VII respecto a la Transferencia de Tecnología y Gestión del Conocimiento, Sección 1a. Transferencia de Tecnología, Art. 708, menciona la importancia del desarrollo, innovación, desagregación, difusión y transferencia de tecnología que contribuya a la mitigación y adaptación al cambio climático para responder a las necesidades identificadas para la gestión de cambio climático a nivel nacional, local y sectorial.

Por otro lado, el Título II respecto a la Adaptación y Mitigación del Cambio Climático, Capítulo I, Art. 721, señala que el análisis de riesgo climático actual y futuro permite identificar los potenciales impactos del cambio climático en los sistemas sociales, económicos y ambientales. Dichos estudios partirán de la información climática histórica y proyecciones climáticas, que se generarán con base en los escenarios de cambio climático e información validados por la Autoridad Ambiental Nacional.

#### **2.2.6 Acuerdo Ministerial 95**

El Acuerdo ministerial 95 con Registro Oficial Edición Especial N° 9 de 17 de junio de 2013 establece en su Artículo 1 como Política de estado la “Estrategia Nacional de Cambio Climático”, instrumento que constituye parte del presente acuerdo. En dicho instrumento se contemplan “Lineamientos para la Acción” para los años entre 2017 a 2025, el cual tiene el objetivo de crear y fortalecer la capacidad de los sistemas social, económico y ambiental para afrontar los impactos del cambio climático y uno de sus objetivos específicos abarca la implementación de medidas que garanticen la soberanía alimentaria frente a los impactos del cambio climático.

## CAPÍTULO III

### METODOLOGÍA

#### 3.1 Descripción del área de estudio

La presente investigación se desarrolló en la provincia de Imbabura, que se encuentra localizada al norte del Ecuador desde los  $00^{\circ} 22' 16''$  hasta  $00^{\circ} 47' 42''$  latitud norte; y,  $78^{\circ} 07' 07''$  hasta  $78^{\circ} 32' 08''$  longitud oeste. Limita al norte con la provincia del Carchi, al sur con Pichincha, al este con Sucumbíos y al oeste con Esmeraldas (Figura 5). Está conformada por los siguientes cantones: Cotacachi, Ibarra, Urcuquí, Otavalo, Pimampiro y Antonio Ante, y su superficie total alcanza aproximadamente  $4\,794.31\text{ Km}^2$ . Por otro lado, el rango altitudinal varía entre 200 y  $4\,939\text{ m s. n. m.}$ , (Plan de Desarrollo y Ordenamiento Territorial de la Provincia de Imbabura 2015-2035 [PDOTI], 2015).




Figura 5. Ubicación del área de estudio

##### 3.1.1 Clima

El clima de Imbabura se encuentra condicionada por la orografía que presenta el territorio, dando lugar a una diversidad ecosistémica y climática (PDOTI, 2015). De este modo, en la provincia está presente cuatro climas según la clasificación de Pourrut

(1995). En primer lugar, se encuentra el clima ecuatorial de alta montaña, caracterizado por temperaturas entre 0°C y 8°C con precipitaciones entre 1 000 y 2 000 mm ubicadas en una altitud mayor a 3 000 m s. n. m. Por otro lado, el clima ecuatorial mesotérmico seco, donde el rango de temperatura varía entre 18 °C y 24°C con precipitaciones de alrededor de 500 mm, localizándose a altitudes que va desde los 1 600 a 2 000 m s. n. m. Asimismo, el clima ecuatorial mesotérmico semihúmedo, en el cual las temperaturas van desde 10°C a 20°C, la precipitación varía en un intervalo entre 1 000 y 2 000 mm y se encuentra en un rango altitudinal de entre 1 600 y 3 000 m s. n. m. Por último, el clima tropical megatérmico húmedo con temperaturas que varían en un rango entre 15°C y 24°C, precipitaciones con rangos desde 2 000 a 4 000 mm y se encuentra en una altitud que va desde 400 a 1 600 m s. n. m.

### ***3.1.2 Actividades agropecuarias***

La provincia de Imbabura destaca por su extensa dedicación a las actividades agropecuarias, con alrededor del 44% de su territorio destinado a este fin, incluyendo 15 806 hectáreas de cultivos permanentes y 13 474 hectáreas de cultivos transitorios (INEC, 2022). En el Cantón Antonio Ante, se estima que aproximadamente el 67.88% de su territorio se destina a la agricultura, con una amplia variedad de cultivos como maíz, fréjol, aguacate y caña de azúcar artesanal, destacando el aguacate como el cultivo más extenso con 99.18 hectáreas (Gobierno Autónomo Descentralizado Municipal Antonio Ante, 2012, 2020). Por otro lado, en el cantón Cotacachi el porcentaje de la Población Económicamente Activa del sector primario es de 36% y en el año 2015 se registró 7 594.14 ha que representan el 4.49 % del cantón destinado a un uso agrícola (Gobierno Autónomo Descentralizado Municipal Santa Ana de Cotacachi, 2015).

En contraste, Otavalo concentra el 17.60% de su territorio en actividades agrícolas, centrándose en la producción de cultivos de ciclo corto, siendo la papa el cultivo con mayor rendimiento con 16.30 T/ha (Gobierno Autónomo Descentralizado del Cantón Otavalo, 2020). Además, Pimampiro registró 3 855 hectáreas dedicadas a cultivos de ciclo corto en 2014, destacando el fréjol como el cultivo más representativo (Gobierno Autónomo Descentralizado Municipal San Pedro de Pimampiro, 2014). En San Miguel de Ibarra, aproximadamente el 12.24% del territorio se destina a la agricultura, con cultivos como maíz, caña de azúcar y cebolla blanca (Gobierno Autónomo

Descentralizado de San Miguel de Ibarra, 2021). Finalmente, en San Miguel de Urququí, el 33.46% de su superficie se dedica a cultivos, destacando los cultivos transitorios como el frejol seco (Gobierno Autónomo Descentralizado San Miguel de Urququí, 2014).

## **3.2 Métodos**

### ***3.2.1 Caracterización de los factores ambientales influyentes en el umbral de desarrollo***

Los factores que inciden en el umbral de desarrollo de *B. cockerrelli* S. y *F. occidentalis* se seleccionaron de acuerdo con la bibliografía existente con respecto a los rangos de supervivencia y rangos de desarrollo óptimo, pues son consideraciones fundamentales para el desarrollo del modelo propuesto en el presente estudio. Además, se tomó en cuenta la disponibilidad de información en diferentes fuentes tanto en plataformas de conjuntos de datos geospaciales como en estaciones meteorológicas de la localidad. De este modo, se seleccionó la temperatura como la variable climática más influyente y la altitud como el factor climático más determinante, para las cuales se obtuvo información de plataformas confiables para el área de estudio y se llevó a cabo el análisis con su respectiva validación.

Por otro lado, para *F. occidentalis* la bibliografía existente con respecto al rango altitudinal en la que se establecen es limitada. Por ende, con la información de los puntos de ocurrencia en Imbabura y tomando en cuenta los resultados de los rangos altitudinales en los que se han registrado en investigaciones anteriores, se estableció los rangos de altitud de acuerdo con un análisis de frecuencias.

### 3.2.1.2 Variable temperatura

- **Información histórica de temperatura**

En Ecuador, la información meteorológica presenta inconsistencias debido a factores como el movimiento de estaciones de un lugar a otro y la baja densidad de la red de estaciones meteorológicas puede presentar un problema en la representatividad de los datos a escala del área de estudio por la heterogeneidad climática (Burbano & Flores, 2022). En este sentido, como alternativa se utilizó las bases de datos climáticos mensuales de TerraClimate para Imbabura de las últimas tres décadas (1991-2020). Este periodo se consideró debido a que La Organización Meteorológica Mundial [OMM] (2017) recomienda que en estudios de climatología para el cálculo de normales climáticas mensuales, estacionales o anuales se debe analizar series continuas de un parámetro climático durante un periodo mínimo de 30 años.


Esta información se descargó y procesó en RStudio (Anexo 40) mediante la librería *ClimateR*. Para ello, se instaló el paquete *pacman* mediante el cual se cargó librerías necesarias para el análisis, visualización, manipulación y gestión de datos geoespaciales. Luego, se importó y proyectó el área de estudio con funciones de la librería *terra*. Para acceder a los datos de TerraClimate se instaló la librería *ClimateR* desde *GitHub*, de este modo se descargó las variables de temperatura máxima y mínima con la función *getTerraClim* especificando la variable, el periodo de tiempo y el área de estudio. Para escribir los archivos ráster (.tif) se utilizó la función *writeRaster*, primero se creó carpetas de almacenamiento y mediante la función se generó y exportó los archivos. Tomando en cuenta que también se requiere la temperatura media, se ha empleado la metodología establecida por Allen et al. (1998), en el cual se obtiene a partir de la temperatura mínima y máxima. De este modo, luego de leer y cargar la temperatura mínima y máxima, se calculó la temperatura media y se exportó los archivos.

Por otro lado, para la validación de la base de datos de TerraClimate se adquirió información de temperatura media mensual de estaciones meteorológicas ubicadas dentro del área de estudio y cerca de sus límites (Tabla 5 y Figura 6). Además, se consideró las que presentaban un mayor registro de datos. Esta información fue

proporcionada por el INAMHI a una escala temporal mensual del periodo entre 1991 y 2020.

**Tabla 5.** Información de las estaciones meteorológicas

Nombre	Código	Latitud	Longitud	Altitud
Inguincho	M0001	0.2575	-78.4080	3140
Otavalo	M0105	0.2433	-78.2500	2550
Cahuasqui-FAO	M0107	0.5181	-78.2111	2335
San Gabriel	M0103	0.6042	-77.8194	2860
El Angel	M0102	0.6189	-77.9449	3000
Cayapas	M0154	0.8622	-78.9508	55
La Concordia	M0025	-0.0248	-79.3803	379



**Figura 6.** Ubicación de las estaciones meteorológicas

**a) Validación de información de TerraClimate con estaciones del INAMHI**

**- Relleno de datos y pronóstico**

En la información de las estaciones consideradas existió datos faltantes que no superaban el 17% en el periodo de años 1991-2018. Por lo cual, para la imputación de los datos faltantes en este periodo se empleó las técnicas numéricas de interpolación puntual denominado *Spline cúbico* y *Shape-Preserving interpolate* en el software MATLAB de acuerdo con el comportamiento específico de los datos de las estaciones (Perugachi-Salamea et al., 2014). La interpolación *spline* se utiliza para ajustar datos y



estimar los datos faltantes utilizando datos existentes, de manera similar, *piecewise cubic Hermite interpolation polynomial* (PCHIP) es utilizado para interpolar datos a partir de valores conocidos preservando la monotonía del conjunto de datos y evitando estimaciones no precisas (Benchekrout et al., 2023).

Perugachi-Salamea et al. (2014) describen que estas dos técnicas toman dos puntos consecutivos y van trazando segmentos de curvas polinómicas, en el caso de *Spline cúbico* las curvas son de grado tres, es decir, estos métodos generan más de un polinomio para interpolar toda la función, unen varios segmentos, los cuales están conformados a partir de intervalos. De este modo, se aseguró que la bondad del ajuste  $R^2$  de los polinomios sean mayores o igual a 0.9. Para determinar diferencias entre los valores interpolados y los reales, se calculó los errores (Ecuación 1) (Haro-Rivera & Escudero-Villa, 2017). Luego, se evaluó el tipo de distribución de los datos mediante la prueba de Kolmogorov-Smirnov (KS) (Ecuación 2), el cual trabaja con las funciones de distribución acumuladas de dos muestras a partir de la aproximación al valor crítico (Siegel, 1995). En función del tipo de distribución de los datos se aplicó las pruebas  $t$  de Student (Ecuación 3) y de Wilcoxon (Ecuación 4) (Álvarez, 1995). Estas pruebas para la comparación de dos grupos relacionados se ajustaron al 95% de precisión para comparar los datos interpolados y los reales.

$$e = \left| \frac{V_r - V_c}{V_r} \right| \quad \text{Ec. 1}$$

Donde,  $e$  es el error,  $V_r$  es el valor real y  $V_c$  el valor calculado.

$$KS = \max_x |F_1(x) - F_2(x)| \quad \text{Ec. 2}$$

Donde,  $KS$  es el estadístico por determinar,  $F_1(x)$  y  $F_2(x)$  corresponden a las funciones de distribuciones acumuladas de dos muestras y el operador  $\max_x$  permite encontrar la diferencia mayor o máxima para visualizar cuan diferentes pueden ser las distribuciones.

$$t = \frac{\bar{d}}{S_D/\sqrt{n}} \quad \text{Ec. 3}$$

Donde,  $t$  es el valor del estadístico de la prueba t-Student,  $\bar{d}$  es la media de las diferencias entre las observaciones emparejadas,  $S_D$  es la desviación estándar de las diferencias y  $n$  es el número de pares de datos.

$$Z = \frac{W - \left[ \frac{n(n+1)}{4} \right]}{\sqrt{\frac{n(n+1)(2n+1)}{24}}} \quad \text{Ec. 4}$$

Donde,  $W$  es la mínima suma de rangos entre la suma de rangos de las diferencias positivas y la suma de rangos de las diferencias negativas y  $n$  el número de pares de datos.

Se eliminó los *outliers* (datos atípicos) de las series de datos mensuales imputados anteriormente para evitar patrones no estacionarios y mejorar la precisión de las predicciones, para ello, se utilizó el *Moving Median* con un factor de umbral (*Threshold factor*) de tres como método de detección de *otuliers* a aquellos datos que se encuentren a más de tres veces de la desviación absoluta mediana local, luego, para reemplazar estos datos se utilizó el método *Shape-preserving cubic interpolation* (PCHIP) (Moreno, 2012). Posteriormente, para predecir valores mensuales de los años 2019 y 2020, se utilizó el software StatGraphics Centurion 18.1.13 para ajustar Modelos de media móvil integrada autorregresiva (ARIMA, por sus siglas en inglés) de tipo estacionales por la escala temporal mensual de los datos (Box et al., 2016). Para ello, se dividió los datos en dos conjuntos, el primer conjunto con el 80% de datos para entrenamiento y el segundo conjunto con 20% para validación (Guerra, 2022). El modelo ajustado es seleccionado mediante el Criterio de Información de Akaike (AIC) (Ecuación 5) el cual es recomendado por su eficacia para seleccionar el de mayor rendimiento entre los modelos de pronósticos (Miranda, 2021).

$$AIC = -2 \log(L) + 2k \quad \text{Ec. 5}$$

Donde,  $L$  es la verosimilitud y  $k$  representa el número de los parámetros del método ARIMA. De este modo, el modelo es más eficiente si el valor de  $AIC$  es menor.

#### - Validación de datos

Se utilizó un enfoque de punto (estación) a pixel mediante el cual se extrajo los valores mensuales de las celdas de la cuadrícula para cada una de las ubicaciones de las

estaciones (Muthoni, 2020). Para conocer cuán ajustado se encuentran los datos mensuales de TerraClimate a las observadas del INAMHI y evaluar la calidad de estas series temporales, se utilizó los siguientes índices de desempeño: Error cuadrático medio (RMSE) (Ecuación 6) y Error Medio Absoluto (MAE) (Ecuación 7) (Araghi et al., 2023; Filgueiras et al., 2022).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad \text{Ec. 6}$$

Donde,  $y_i$  es el valor de T(°C) observada,  $\hat{y}_i$  es el valor de T(°C) TerraClimate y  $n$  es el número de observaciones.

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad \text{Ec. 7}$$

Donde, es  $y_i$  es el valor de T(°C) observada,  $\hat{y}_i$  es el valor de T(°C) TerraClimate y  $n$  es el número de observaciones.

## **b) Validación de información de TerraClimate con el gradiente ambiental**

### **- Funcionalidad del gradiente ambiental vertical**

Se evaluó la funcionalidad del gradiente ambiental vertical propuesta por el CEPIS (2005) con información de las estaciones que se encuentran dentro de Imbabura. Para ello, se calculó la diferencia entre las medias del conjunto de datos de las estaciones con el valor de la temperatura media que representa el gradiente ambiental en la altitud de las ubicaciones de las estaciones, bajo la hipótesis nula de la inexistencia de diferencia entre estas. Para lo anterior se utilizó la prueba  $z$  debido a la naturaleza de distribución normal de los datos. La prueba  $z$  es una prueba de hipótesis que permite determinar si existe una diferencia significativa entre medias reales de dos conjuntos de datos (Ecuación 8); por lo que, se supone que las medias reales y las desviaciones estándar son conocidas. Esta prueba es una opción ante el inconveniente que genera el uso de la prueba  $t$  de student debido a la implicación de una desviación estándar alta en la determinación de que dos medias son diferentes, a pesar de que en realidad no pueden diferir mucho (Wilks, 1995).

$$Z = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \quad \text{Ec. 8}$$

Donde,  $z$  es el valor de la estadística de prueba,  $\bar{x}_1$  es el promedio del primer conjunto de datos,  $\bar{x}_2$  corresponde al promedio del segundo conjunto de datos,  $n_1$  es el número de mediciones en el primer conjunto de datos,  $n_2$  es el número de mediciones del segundo conjunto de datos,  $\sigma_1$  es la desviación estándar conocida de la primera población y  $\sigma_2$  es la desviación estándar conocida de la segunda población.

#### - Comparación de TerraClimate y gradiente ambiental vertical

Para la validación de la temperatura media de TerraClimate (1991 a 2020), se obtuvo una muestra del total de píxeles de los archivos ráster (.tif) de TerraClimate en el área de estudio (261). Para ello, se aplicó la ecuación (Ecuación 9) para el cálculo de muestra representativa con un nivel de confianza del 90% y un margen de error del 10% (Aguilar-Barojas, 2005).

$$n = \frac{N * Z^2 * p * q}{e^2(N-1) + Z^2 * p * q} \quad \text{Ec. 9}$$

Donde,  $n$  es el tamaño de la muestra,  $N$  es la población total,  $Z$  representa el nivel de confianza,  $e$  corresponde al margen de error,  $p$  es la probabilidad de éxito o proporción esperada y por último,  $q$  es la probabilidad de fracaso ( $1 - p$ ).

De este modo, en función del número de la muestra resultante se seleccionó aleatoriamente la cantidad de puntos de la muestra en toda el área de estudio. Para dichos puntos se obtuvo la temperatura media del gradiente ambiental vertical a partir de la elevación y el uso de la siguiente ecuación (CEPIS, 2005):

$$y = -0.0054 * Z + 28.122 \quad \text{Ec. 10}$$

Donde:  $y$  es el valor de la temperatura media del aire (°C) y  $Z$  corresponde a la elevación del punto en metros.

Previo a la comparación entre el gradiente ambiental y la información de TerraClimate, se ejecutó la prueba de homocedasticidad de Levene para determinar si las varianzas son iguales o distintos (Marozzi, 2012). Esta prueba paramétrica compara las medias de las diferencias absolutas de los residuos de cada grupo y tiene mayor robustez (Ecuación 11) (Bisquerra, 1987; Brown & Forsythe, 1974). Además, da validez a las pruebas de hipótesis de igualdad de medias. Finalmente, se aplicó la prueba

ANOVA (Analysis of Variance, por sus siglas en inglés) para determinar si existen diferencias o similitud entre la temperatura media obtenida con la elevación y la temperatura media de TerraClimate de las mismas ubicaciones en cinco pliegues de 11 puntos (McHugh, 2011).

$$W = \frac{(N-k)}{(k-1)} \times \frac{\sum_{i=1}^k N_i (Z_i - Z_{..})^2}{\sum_{i=1}^k \sum_{j=1}^{N_i} (Z_{ij} - Z_i)^2} \quad \text{Ec. 11}$$

Donde,  $W$  es la estadística de prueba de Levene,  $N$  es el número total de observaciones,  $k$  es el número de grupos,  $N_i$  es el número de observaciones en el grupo  $i$ ,  $Z_i$  es la media del grupo  $i$ ,  $Z_{..}$  es la media general de todas las observaciones y  $Z_{ij}$  es la observación  $j$  en el grupo  $i$ .

### c) Establecimiento de umbral de desarrollo y rango óptimo

Se realizó una reducción de escala estadística (downscaling) para el raster de 4.6 km de resolución de temperatura media de TerraClimate, a una resolución espacial de 100 m utilizando la elevación como variable predictora. Previo a ello, se empleó la herramienta *Raster Calculator* de ArcMap 10.8 para calcular la temperatura media anual de los 30 años (1991–2020). Luego, para el downscaling se utilizó la herramienta integrada *Geographically Weighted Regression* (GWR) de SAGA en QGIS de Song Xiangyang y Gao Jiawei (2022). En esta herramienta se seleccionó como variable respuesta a la temperatura y como predictora a la elevación (Duan & Li, 2016; Szymanowski & Kryza, 2011). Además, el tipo de modelo de regresión seleccionado para el desescalado fue la función Gaussiana debido que la temperatura es una variable continua (ESRI, 2022). Es importante recalcar que la predicción realizada mostró métricas como el  $R^2$  por encima de 0.8 y un error de predicción muy bajo.

Posteriormente, se establecieron los umbrales de desarrollo y los rangos óptimos de las especies en estudio, de acuerdo con la bibliografía existente. Finalmente, se clasificó el raster de temperatura media según estos umbrales de desarrollo y óptimos, con el fin de identificar de manera preliminar las áreas donde pueden establecerse.

- **Información futura de temperatura**

Se seleccionó escenarios estándar del CMIP6 debido a que según estudios presentan mayor precisión reduciendo el error de los datos (Burbano & Flores, 2022). Los escenarios considerados fueron el SSP245 y SSP585 para el período de 2021 a 2060. Se optó por el SSP245 denominado “Mitad del camino” debido a que refleja las tendencias de emisiones medias de gases GEI, así como un crecimiento poblacional moderado y una reducción progresiva en la dependencia de los combustibles fósiles, junto con el uso más eficiente de los recursos y la energía (O’Neill et al., 2017), se puede concluir que es el escenario relativamente optimista y más realista con relación al mundo actual tomando en cuenta que el crecimiento de la población es más lento que en el pasado y se prevé exista un descenso de las tasas de fecundidad (Khokhar & Kashiwase, 2015).

En contraste, SSP585 denominado “Desarrollo impulsado por combustibles fósiles” que prevé una dependencia total de combustibles fósiles, uso intensivo de recursos y energía, que permite tendencias de emisiones altas y el aumento subsecuente de temperatura al límite dentro de las SSP (Escoto et al., 2017), este último es considerado el escenario más pesimista, por lo que se pretende conocer y/o estimar el riesgo de presencia de plagas bajo las condiciones planteadas por la misma en ausencia de una transición energética.

En cuanto al modelo climático global, el modelo MPI-ESM1-2-HR del CIMP6 ha demostrado ser eficiente y confiable en la simulación de múltiples variables climáticas en diversas regiones. Por ejemplo, en Panamá, según el estudio de Araúz (2023), este modelo demostró un buen desempeño. Rivera et al. (2022) afirma que dicho modelo ha sido sometido a rigurosas evaluaciones y comparaciones, lo que sugiere que es una herramienta confiable para estudiar los impactos del cambio climático. Además, en su investigación realizada en Guatemala, a través de simulaciones, determinó que el MPI-ESM1-2-HR se encontraba entre los 10 modelos que representan con mayor precisión la temperatura media regional.

En el contexto ecuatoriano, el modelo MPI-ESM1-2-HR es reconocido por su alta resolución horizontal, lo que le permite capturar con mayor detalle los procesos climáticos a pequeña escala, como destacan Morán & Novillo (2022) este modelo se emplea en estudios climáticos para realizar proyecciones futuras y análisis de escenarios

de cambio climático, lo que destaca su importancia y utilidad para comprender y enfrentar los desafíos climáticos en la región. En virtud de lo mencionado, para el presente estudio se consideró el modelo climático MPI-ESM1-2-HR.

En estudios climáticos y ambientales, es común utilizar datos del geoportal WorldClim. Por ende, para este estudio, se adquirió información proyectada al año 2060 bajo los escenarios SSP245 y SSP585 del modelo climático MPI-ESM1-2-HR. Siguiendo la recomendación de Rivera et al. (2021), se enfatiza la importancia de adquirir la información de WorldClim a una escala más precisa, es decir, a una resolución de 30 segundos, para obtener datos detallados y realizar un análisis preciso de las condiciones climáticas futuras.


### **3.2.1.3 Factor altitud**

Se adquirió un Modelo Digital de Elevación (DEM) de *Shuttle Radar Topography Mission* (SRTM) con píxeles de 30 metros de resolución espacial. La precisión de los datos del sistema SRTM tiene un nivel de confianza del 90% (Lobo & Kamp, 2006). Mediante la herramienta *resample* del programa ArcMap 10.8 se modificó la resolución espacial a 1 km para Imbabura mediante el método bilineal (Hamarash et al., 2022; He et al., 2022), y se empleó la herramienta *raster to point* para obtener puntos de los píxeles totales. Por otro lado, se obtuvo un total de 158 registros de presencia de *F. occidentalis* en los años entre 2019-2022, para los cuales se extrajo la elevación. Posteriormente, se realizó un análisis descriptivo de los datos de elevación, para ello, se obtuvo tablas de frecuencias relativas y acumuladas, gráficos estadísticos: de cajas y bigotes, histograma y de densidad suavizada, con el fin de determinar el rango de altitud en la que se encuentran el mayor porcentaje de registros. Finalmente, de igual manera con el fin de conocer de manera preliminar las superficies donde pueden establecerse las especies, se clasificó el DEM de acuerdo con los rangos del umbral de desarrollo y umbral óptimo.

### ***3.2.2 Desarrollo del modelo de proyección de riesgo de presencia de plagas***

Los datos históricos de la temperatura media de los años entre 1991 y 2020, junto con la información de elevación, se etiquetaron según clases mediante programas creados con funciones, bucles, estructuras de control e instrucciones. Para esta etiqueta se tomó en cuenta los umbrales y las condiciones óptimas de desarrollo para cada plaga y variable. Con los datos etiquetados se entrenó los clasificadores en la aplicación *Classification Learner* de la extensión *Machine Learning* de MATLAB (MathWorks, 2023). Esta aplicación tiene preempaquetado varios modelos de clasificación con diferentes algoritmos. Los clasificadores con mayor eficiencia fueron evaluados de acuerdo con métricas para seleccionar el más pertinente para la clasificación de los *dataset* (Guevara, 2019). De este modo, se ajustó un sistema de iteración con las funciones de predicción de los clasificadores con mayor eficiencia. En consecuencia, el sistema generó una tabla de resultados determinando el riesgo de presencia de las plagas (Figura 7).





**Figura 7.** Diagrama de flujo del modelo propuesto

### 3.2.2.1 Entrenamiento y evaluación de modelos de aprendizaje automático

- **Preprocesamiento y lectura de datos**

Los datos mensuales de TerraClimate en formato ráster (.tif) de 4.6 km de resolución espacial se procesaron en el software ArcMap 10.8 para obtener datos anuales de temperatura media, mínima y máxima del periodo entre 1991 y 2020. Luego, dichos datos anuales de 261 puntos (total de píxeles en el área de estudio) se sistematizó en archivos de texto denominado valores separados por comas (.csv). De manera similar, los datos de elevación se adecuaron para 9 284 puntos, que corresponden a todos los píxeles de 1km<sup>2</sup> del *DEM* de Imbabura. Teniendo en total cuatro bases de datos (*dataset*), tres de temperatura histórica (máxima, mínima y media) y una de elevación. Dichos archivos fueron importados a MATLAB de manera automática mediante la función *csvread* (Guevara, 2019).

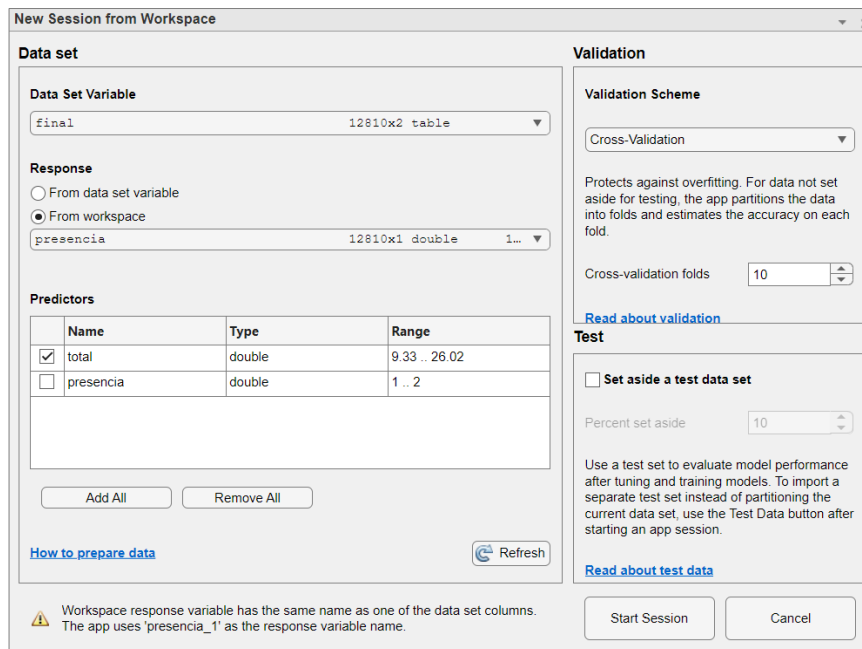
- **Desarrollo de programas para la etiqueta de datos**

Para crear los programas se utilizó el entorno interactivo de *Live Editor* de MATLAB (MathWorks, 2023<sup>a</sup>). Primero, los tres *dataset* anteriores se convirtieron en un arreglo homogéneo utilizando la función *table2array*. De modo que, luego, se estableció las etiquetas de las tres clases: 0, que indica que la plaga no va a sobrevivir; 1, que establece que la plaga se encuentra en el umbral donde puede sobrevivir y; 2, que la condición de la variable es óptima para la plaga. Finalmente, se adecuó un algoritmo o programa con bucles, estructuras de control, funciones e instrucciones para etiquetar las clases tomando en cuenta los umbrales y las condiciones óptimas de desarrollo para cada plaga y variable. En total se desarrolló los siguientes seis programas:

1. Temperatura para *B. cockerelli S.*
2. Temperatura para *F. occidentalis*
3. Temperatura para *B. cockerelli S.* y *F. occidentalis*
4. Elevación para *B. cockerelli S.*
5. Elevación para *F. occidentalis*
6. Elevación para *B. cockerelli S.* y *F. occidentalis*

- **Entrenamiento individual de clasificadores de aprendizaje automático**

Para entrenar los diferentes clasificadores se usó la aplicación *Classification learner* de MATLAB siguiendo el proceso descrito por Guevara (2019). A la aplicación se accede desde la pestaña APPS ubicado en la parte superior del software. La ventana que se despliega muestra las pestañas de los principales clasificadores automáticos, opciones y herramientas para el entrenamiento y evaluación de estos. Para importar los datos etiquetados desde *Workspace* se abrió una nueva sesión desde la pestaña *New Session*. En la nueva ventana que se despliega se configuró las opciones de modo que los *dataset* (final) con datos etiquetados necesarios para el entrenamiento sean importados desde la opción *Dataset Variable* (Figura 8).



**Figura 8.** Ventana de configuración de una sesión nueva

En la opción *Response* se seleccionó la columna de presencia como la respuesta o clases a clasificar y en *Predictors* la columna total que corresponde a los datos de temperatura o elevación. Posteriormente, en la opción de *Validation* se seleccionó el método de *Cross-Validation* (validación cruzada) con 10 *folds* (iteraciones) debido a que en el aprendizaje automático se recomienda trabajar con este número de pliegues (Refaeilzadeh et al., 2008).

Luego de iniciar la sesión, se entrenó los *dataset* con 33 tipos de clasificadores disponibles en la aplicación. De este modo, para cada *dataset* etiquetado por los

programas, se utilizó el 100% de datos para el entrenamiento (Tabla 6). Esto debido a que la validación cruzada permite maximizar el uso de los datos disponibles, ya que evalúa el rendimiento de un modelo sin la necesidad de dividir una cantidad de datos para la validación (Vabalas et al., 2019).

**Tabla 6.** Número de datos entrenados por cada *dataset*

<b>Dataset</b>	<b>Número de datos</b>
<i>B. cockerelli</i> S. elevación	9 284
<i>B. cockerelli</i> S. temperatura	23 490
<i>F. occidentalis</i> elevación	9 284
<i>F. occidentalis</i> temperatura	23 490
<i>B. cockerelli</i> S. y <i>F. occidentalis</i> -elevación	9 284
<i>B. cockerelli</i> S. y <i>F. occidentalis</i> -temperatura	23 490

- **Evaluación de clasificadores entrenados**

Se evaluó la eficiencia de los clasificadores mediante métricas. Primero, la matriz de confusión debido a que es la métrica más intuitiva, el cual permite determinar la precisión de los modelos y es utilizada ampliamente en clasificadores dónde la salida es más de dos clases (Davis & Goadrich, 2016). La matriz de confusión muestra los errores y aciertos de la clasificación de datos de un modelo en filas y columnas en cuatro categorías (Tabla 7): verdadero positivo (TP) se refiere a la identificación correcta de datos, falso positivo (FP) ocurre cuando se estima erróneamente la instancia negativa como positiva, verdadero negativo (TN) cuando el modelo predice correctamente la clase negativa y falso negativo (FN) cuando el modelo predice incorrectamente la instancia positiva como negativa (Souza et al., 2020). A partir de estas categorías de la matriz de confusión se derivan otras métricas como la eficiencia.

**Tabla 7.** Categorías o variables resultantes de un modelo

	Predicción Positiva	Predicción negativa
Instancia Positiva	TP	FN
Instancia Negativa	FP	TN

Es importante destacar que, para evitar el sobreajuste en las tasas de error de la matriz de confusión, se tomó en cuenta el peso relativo de la cantidad de datos por cada clase.

La siguiente métrica considerada es la precisión de fallas del aprendizaje o *accuracy*. La precisión mide el porcentaje de datos que el algoritmo de aprendizaje ha clasificado correctamente (González, 2021). Para calcular esta métrica se aplica la siguiente ecuación:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad \text{Ec. 12}$$

Donde, TP se refiere a la tasa de verdaderos positivos, TN es la tasa de verdadero negativo, FP es la tasa de falso positivo y FN la categoría de falso negativo.

Por otro lado, la Característica del Operador del Receptor o mayormente conocido como curva ROC se utilizó como métrica complementaria en la evaluación puesto que Davis & Goadrich (2016) afirman que producen una visión muy optimista del rendimiento de algoritmos si existe un gran sesgo en la distribución de clases.

- **Entrenamiento final de clasificadores de aprendizaje automático**

El modelo con mayor eficiencia para cada *dataset* entrenado anteriormente fue exportado al *Workspace* de MATLAB. En el *LiveEditor* se construyó un programa para la iteración de los seis modelos exportados. Este programa dio lectura a las bases de datos de entrenamiento y combinó los modelos de clasificación individuales. Dichos modelos clasificaron los datos de entrada de acuerdo con el aprendizaje de su entrenamiento. Posterior a ello, se compararon los valores resultantes de la predicción de las tres clases (no sobrevive, sobrevive, rango óptimo) para ambas variables (elevación y temperatura), dando mayor importancia a la temperatura para generar cuatro clases de riesgo.

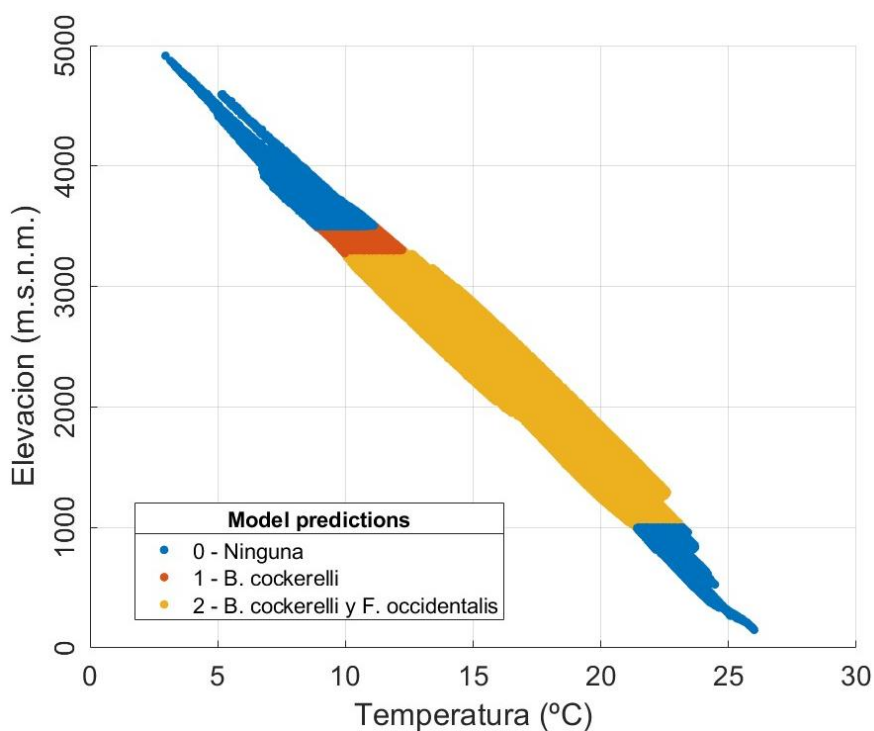
De esta forma, se generó y etiquetó las clases de riesgo de presencia, definiendo la supervivencia en los umbrales aptos (1), el umbral apto y óptimo (2), los rangos óptimos (3) y la clase no apta – no sobrevive (0), los detalles de cada clase de riesgo se presentan en la Tabla 8. Este proceso se llevó a cabo para cada especie. Posteriormente, con los datos etiquetados de las cuatro clases, se volvió a entrenar los principales algoritmos de clasificación para que el sistema aprendiera a categorizar éstas últimas clases de riesgo para cada especie, en función de ambas variables. Finalmente, se seleccionó el clasificador automático final que mejor se adaptó para la predicción de riesgo de

presencia de las especies en estudio, considerando la precisión (Ecuación 12) de los modelos y la eficiencia en términos de tiempo.

**Tabla 8.** Clase y etiqueta de riesgo de presencia.

Clase	Etiqueta	Detalle
0	Nula	No apta – no sobrevive: temperatura y elevación no apta
1	Baja	Supervivencia en el umbral: temperatura y elevación en el umbral apto
2	Media	Umbral apto y óptimo: temperatura en el umbral apto y elevación óptimo
3	Alta	Umbrales óptimos: temperatura en el umbral óptimo y elevación en el umbral apto y óptimo

Del mismo modo, la conjunción con datos etiquetados en tres clases con elevación y temperatura (Figura 9) también se entrenó nuevamente. De esta forma, se obtuvieron tres funciones de predicción: una para cada especie y otra para su conjunción.



**Figura 9.** Clases de predicción del modelo conjunción (*B. cockerelli* S. y *F. occidentalis*) en función de temperatura y elevación

### 3.2.2.3 Modelos de riesgo de presencia pasado, presente y futuros

- **Ajuste de un programa final de interacción**

Se construyó un programa final haciendo uso de las funciones de predicción de los clasificadores finales para cada especie. Este va a predecir el riesgo de presencia en las clases de supervivencia en los umbrales aptos ("Baja"), el umbral apto y óptimo ("Media"), los rangos óptimos ("Alta") y la clase no apta ("Nula") cuando se ingrese datos de las variables elevación y temperatura. Finalmente, el programa va a exportar los resultados a una tabla conformada por columnas de datos de temperatura, datos de elevación, resultado especie 1, resultado especie 2 y resultado combinación de especies.

- **Preparación de los datos de entrada**

Para obtener los datos de entrada, se realizó un downscaling a los rásters de temperatura media (4.6 km de resolución) de los años 1990 y 2020, a una resolución espacial de 100 m tal como se realizó anteriormente con los datos de temperatura media anual histórico. De igual manera, se aseguró que la predicción obtenga un  $R^2$  por encima de 0.8 y un error de predicción bajo. Por su parte, los datos futuros de 2060 para los escenarios SSP245 y SSP585 se obtuvieron con anterioridad a la resolución de 30 segundos de arco angular (1 km aproximadamente), por lo que se aplicó el mismo proceso de downscaling. Posteriormente, a estos archivos ráster se reajustó el tamaño de celda mediante la herramienta *resample* de ArcMap en función de la resolución de un archivo DEM (100m) del área de estudio a fin de garantizar que todos tengan el mismo tamaño y cantidad de píxeles (Jácome, 2018). Posteriormente, se utilizó la herramienta *Extract multivalues to points* para extraer los datos de temperatura media de los tres años y la elevación a puntos. Finalmente, estos datos de los puntos fueron exportados a archivos de texto (.csv).

- **Proyección del riesgo de presencia**

Para generar los mapas con de riesgo de presencia pasado (1990), presente (2020) y futuro (2060), se utilizó como entrada los datos de temperatura media y elevación en formato archivo de texto (.csv) del total de puntos que representan el total de píxeles de 100 metros de un ráster del área de estudio. Los archivos de texto (.csv) de cada año se importaron a MATLAB y se ingresaron al programa final como una tabla. Se especificó

las columnas que contienen los datos de temperatura media y elevación. Finalmente, al ejecutar este programa el resultado se generó en una tabla. Además, es importante recalcar que se modificó el nombre del archivo Excel (.xlsx) que se va a exportar con la tabla de resultados de acuerdo con el año correspondiente cada vez que se ejecutó.

- **Interpolación de mapas de riesgo de presencia**

Los resultados obtenidos mediante el programa final se exportaron a un archivo de texto (.csv) para luego proyectar sus coordenadas en el software ArcMap 10.8 y realizar la interpolación espacial de los datos. Posteriormente, se empleó la herramienta *Kriging*, siguiendo la metodología propuesta por Rosenberg (2004), la cual permite describir y modelar los patrones de variabilidad espacial de las densidades de distribución especies invasoras, lo que es fundamental para la comprensión y el manejo de estos riesgos. De este modo, en la ventana de configuración *enviromments* de la herramienta *Kriging*, específicamente en la opción de *raster analyst*, se seleccionó el polígono del área de estudio para extender el análisis para el área de interés. Para validar la interpolación espacial, se verificó que los valores de la media del error fueran próximos a cero, ya que un error cercano a cero indica una predicción más precisa y se ajusta bien a los datos reales, lo que sugiere que el método y la interpolación fue efectivo (ESRI, 2023).

Finalmente, para representar cartográficamente se adaptó la metodología utilizada por Corrales & Lobato (2023) mediante el uso de la herramienta *reclassify*. De esta forma, se llevó a cabo la clasificación en las cuatro categorías de riesgo de presencia (Tabla 8); "Nula", "Baja", "Media" y "Alta". Estas clasificaciones se agregaron a la tabla de atributos del ráster utilizando la herramienta *add field*, con el nombre de "Categoría". Posteriormente, se convirtieron a polígonos mediante la herramienta *raster to polygon*, lo que resultó en la generación de múltiples polígonos. Estos polígonos se fusionaron según su campo de "riesgo" utilizando la herramienta *merge* de geoprocésamiento, con el propósito de representar cartográficamente los resultados.

### **3.2.3 Propuesta de Estrategias de Manejo Integral de Plagas (MIP)**

A continuación, se describe el procedimiento llevado a cabo para establecer una propuesta para el Manejo Integrado de Plagas en función del riesgo de presencia de las especies y su impacto en los cultivos.



### 3.2.3.1 Levantamiento de información relevante de los cultivos

La información geográfica de los cultivos estudiados se obtuvo del inventario frutícola del Geoportal del Gobierno Autónomo Descentralizado Provincial de Imbabura, el Gobierno Autónomo Descentralizado de San Miguel de Ibarra y Agrocalidad. A través del programa ArcMap 10.8, se realizaron correcciones para subsanar posibles errores de coordenadas de ubicación en términos de cantón o cambio de cultivo. Es importante señalar que, dado que el fréjol y la papa son cultivos transitorios (ciclo vegetativo menor a 12 meses), se utilizó exclusivamente los registros. En contraste, el aguacate, al ser un cultivo permanente, facilitó la identificación de los predios en el área de estudio. De este modo, se registró 343 cultivos de fréjol, 536 de papa y 1 002 de aguacate.

Posteriormente, se realizó un muestreo probabilístico del total de registros y predios de los tres cultivos con un nivel de confianza del 90% y un margen de error del 10% para el cálculo de la muestra (Candia & Caiozzi, 2005). De esta forma se obtuvo una muestra representativa de 66 cultivos, los cuales fueron elegidos aleatoriamente tomando al área de estudio como homogénea (Otzen & Manterola, 2017). Para recopilar información relevante de los cultivos y las plagas en estudio, se realizó visitas a los registros y predios seleccionados y se aplicó encuestas. La encuesta fue diseñada basando en el trabajo de Chango (2022) y adaptado para el presente estudio, como se observa en el Anexo 39. Además, se la validó mediante una prueba piloto la cual fue de 20, utilizando el coeficiente alfa definido por Cronbach (1951) (Ecuación 13). Por último, se empleó el índice propuesto por Tuapanta et al. (2017) para evaluar el nivel de precisión en el estudio. Este índice clasifica el nivel de precisión en cinco categorías: excelente (0.9 a 1), muy bueno (0.7 a 0.9), bueno (0.5 a 0.7), regular (0.3 a 0.5), y deficiente (0 a 0.3).

$$\alpha = \frac{k}{k-1} \left[ 1 - \frac{\sum_{j=1}^k \sigma_{j^2}}{\sigma_{T^2}} \right] \quad \text{Ec. 13}$$

Donde  $K$  es la cantidad de ítems incluidos en la escala;  $\sigma_{j^2}$  es la varianza del ítem  $j$  para  $j = 1, \dots, k$ ; y  $\sigma_{T^2}$  representa la varianza de la suma total de todos los puntos (la varianza de toda la prueba).

### 3.2.3.2 Identificación y priorización de problemas

La matriz de Vester es una importante herramienta para identificar y priorizar problemas en diversas áreas. Por lo tanto, para identificar y priorizar los problemas derivados de la información recopilada y su relación causa-efecto, se empleó la matriz de Vester. Para construir esta matriz, en primer lugar, se define el problema objeto de análisis y los efectos que está generando. Luego, se procede a identificar las posibles causas que podrían estar contribuyendo a dichos efectos. Se elabora una lista de los problemas generales relacionados con el objeto de estudio y se priorizan aquellos más relevantes para su posterior análisis en la matriz (Parra & Muñoz, 2014).

En la construcción de la matriz, se disponen horizontalmente los problemas activos (problemas causas) en el eje X, mientras que en el eje Y se vuelven a listar los problemas pasivos (problemas consecuencia). Se cruzan estos elementos para evaluar la influencia que cada uno ejerce sobre los demás, asignándoles valores que indiquen el nivel de causalidad entre ellos (Montalba, 2018). El grado de incidencia de un problema con los otros se examina usando una escala de valoración (Tabla 9) (Sevilla, 2019). Este proceso permite desarrollar soluciones enfocadas en abordar las causas principales y los problemas críticos identificados, lo que facilita la resolución efectiva del problema

**Tabla 9.** Escala de valores para matriz de Vester


<b>Influencia</b>	<b>Rango</b>
<b>Sin relación</b>	0
<b>Baja Influencia</b>	1
<b>Mediana Influencia</b>	2
<b>Alta influencia</b>	3

### 3.2.3.3 Identificación de estrategias

Se identificaron las estrategias más adecuadas para los cultivos en función de la información obtenida de las encuestas y los resultados de la matriz de identificación y priorización de problemas. De este modo, para abordar los problemas críticos, se planteó programas enfocados en dar solución a sus causas y mitigar las consecuencias negativas que se derivan de ellas. Para ello, se combinó los métodos de control más pertinentes que permitan reducir los impactos negativos de las especies invasoras y los problemas críticos, fomentando la sostenibilidad y la gestión eficiente de los recursos naturales agrícolas (Toro, 2012).

- **Modelo Presión-Estado-Respuesta**

El modelo Presión-Estado-Respuesta (PER) es un instrumento útil para el análisis de vínculos existentes entre las condiciones ambientales y las actividades económicas. Establece que las actividades humanas ejercen presiones sobre el medio ambiente, lo que puede inducir cambios en su estado (Figura 10). La sociedad responde a estos cambios con políticas económicas y medioambientales, así como con programas para prevenir y mitigar las presiones. Los indicadores de presión describen las presiones ejercidas sobre el ambiente por las actividades humanas. Los indicadores de estado se refieren a la condición de los recursos naturales y del medio ambiente. Los indicadores de respuesta presentan los esfuerzos realizados por la sociedad para prevenir y mitigar la degradación del ambiente (Organization for Economic Co-operation and Development [OCDE], 1993).



**Figura 10.** Esquema del Modelo Presión – Estado – Respuesta  
Fuente: OCDE, 1993

De esta manera, tomando en cuenta las diferentes problemáticas identificadas y priorizadas mediante la matriz de Vester, se ajustó un esquema del modelo PER para cada programa, estableciendo vínculos entre las presiones (problemas activos) y el estado (problemas críticos y pasivos). Esta relación facilitó el planteamiento de estrategias finales que buscan abordar de manera integral los problemas críticos de los cultivos, asegurando así una gestión sostenible de los recursos agrícolas y del entorno.

### 3.3 Materiales y equipos

Los materiales y equipos que se utilizó en la investigación se detallan en la Tabla 10.

**Tabla 10.** Materiales y equipos

<b>Materiales</b>	<b>Actividad</b>
Datos de estaciones meteorológicas (INAMHI)	Adquisición de información de temperatura observada.
Datos de TerraClimate	Adquisición de información de temperatura.
<b>Software</b>	<b>Actividad</b>
RStudio3.6	Obtención y procesamiento de datos meteorológicos.
Microsoft Office 365 (Word, Excel)	Caracterización de los factores ambientales que influyen en el ciclo de vida de las especies.
MATLAB R2021a	Desarrollo del modelo de proyección con perspectiva de aprendizaje automático.
ArcMap 10.8	Análisis de presencia de plagas, procesamiento de información climática e interpolación de resultados.
STATGRAPHICS Centurion 18.1.13	Análisis estadísticos para validación de bases de datos.
<b>Equipos</b>	<b>Actividad</b>
Cámara fotográfica	Registro de material fotográfico de cultivos en salidas de campo.
Espacio de servidores	Entrenamiento del modelo para la interacción entre los umbrales de plagas y el aumento de temperatura.
2 computadores portátiles	Análisis de datos y desarrollo del modelo de respuesta.

## CAPÍTULO IV

### RESULTADOS Y DISCUSIONES

#### 4.1 Caracterización de los factores ambientales influyentes en el umbral de desarrollo

##### 4.1.1 Variable temperatura

El principal factor que interviene tanto en el ciclo como en el comportamiento de ambas plagas en estudio es la temperatura, pues es la variable climática más determinante para el ciclo de vida de las plagas de interés económico (Gamarra, 2019; Nicholls, 2008). Debido a ello, a continuación, se detalla la información obtenida al caracterizar la variable temperatura, así como la sistematización, relleno de datos a partir de métodos estadísticos y validación con información de estaciones del INAMHI y gradiente ambiental vertical (García & Durán-Ballén, 2023).

- **Relleno de datos y pronósticos**

En la imputación de los datos faltantes de las estaciones se utilizó la técnica numérica de interpolación *Spline cúbico* para las estaciones Inguincho, Otavalo, Cahuasqui FAO, San Gabriel y la Concordia, y *Shape-Preserving interpolate* para el Ángel y Cayapas debido a la mayor cantidad de datos faltantes dentro de la serie y evitar una variabilidad desmesurada en la curva interpolada (Benchekroun et al., 2023). De este modo, se obtuvo un error entre 0.012 y 0.059 y un error cuadrático medio (MSE) entre 0.001 y 0.046 (Tabla 11). Estos valores demuestran que los métodos de imputación aproximan de manera precisa los datos faltantes a las series observadas.

**Tabla 11.** Error y MSE estimado para los datos de estaciones meteorológicas

Estación	$e$	MSE
Inguincho	0.055	0.016
Otavalo	0.042	0.046
Cahuasqui FAO	0.042	0.020
San Gabriel	0.045	0.023
El Ángel	0.059	0.017
Cayapas	0.012	0.002
La Concordia	0.027	0.001

Haro-Rivera & Escudero-Villa (2017) utilizaron *Spline Cúbico* para interpolar datos faltantes de velocidad de viento, en la que concluyó que el error de los datos estimados con respecto a las series originales alcanza errores de hasta el 100% cuando los datos faltantes son numerosos y no tienen una distribución dispersa, en contraste, es menor (0.66%) cuando son pocos y de distribución dispersa. Lo que justifica que los datos de temperatura estimados de cada una de las estaciones en el presente estudio mostraron buena aproximación ya que los datos ausentes son aleatorios en las series de datos disponibles.

Como resultado de las pruebas de comparación se obtuvo valores del estadístico *t* de Student entre -1 y 0.93 y valores mayores que 0.05 de probabilidad (*p value*), lo que indica que no existe una diferencia significativa entre los datos estimados y los datos observados para las estaciones de Inguincho, Otavalo, San Gabriel y La Concordia. Con respecto a las estaciones de Cahuasqui FAO, El Ángel y Cayapas, la prueba de Wilcoxon exhibió valores del estadístico de esta prueba entre 0 y 1.34 y valores de *p* mayores a 0.05 (Tabla 12), evidenciando un sólido ajuste del método de interpolación y preservando la forma de las series de datos originales de las estaciones.

**Tabla 12.** Estadísticos de la prueba *t* de Student y Wilcoxon


Estación	Estadístico	<i>p value</i>
Inguincho	-0.81	0.42
Otavalo	0.93	0.35
Cahuasqui FAO	0.00	1.00
San Gabriel	-0.75	0.45
El Ángel	0.77	0.44
Cayapas	1.34	0.18
La Concordia	-1.00	0.32

*Nota.* Los estadísticos y el valor *p* de las estaciones Inguincho, Otavalo, San Gabriel y La Concordia pertenecen a la prueba *t* de Student, mientras que, para las de las estaciones de Cahuasqui FAO, El Ángel y Cayapas pertenecen a la prueba de rangos con signo de Wilcoxon.

Haro-Rivera & Escudero-Villa (2017) afirman en su estudio que cuando el número de datos faltantes se incrementan al inicio y final de la serie, la interpolación con el método *Spline cúbico* muestra diferencias significativas, mientras que, el método por mínimos cuadrados la distribución de los datos faltantes es dispersa. Lo anterior concuerda con lo evidenciado en este estudio, pues, a medida que aumenta la cantidad de datos faltantes, se presenta una tendencia hacia valores cercanos a 1.96 y 0.05 de estadísticos de las

pruebas y valores de  $p$ , respectivamente. Por otro lado, Childs et al. (1984) utilizaron el *Spline cúbico* para interpolar datos de radiación solar en ausencia de datos de duración de luz solar en el estudio de la relación entre estas, demostrando así que este método proporciona estimaciones más precisas y uniformes en comparación de la regresión lineal.

Por otro lado, en el pronóstico de datos para los años 2019 y 2020, la serie de tiempo con datos de las estaciones mostraron ser estacionarias, es decir, la tendencia de los datos en general se mueve alrededor de la media a través del tiempo (Figura 11). Aguado-Rodríguez et al. (2016) afirman que la capacidad predictiva de modelos ARIMA para variables meteorológicas como la temperatura es superior en comparación con otros modelos de enfoques más simples, ya que, en su estudio, el porcentaje de mejoría fue del 75.4% en relación con un modelo persistente para una estación. Por su parte, Palomino-Parra et al. (2020) mencionan que los modelos ARIMA con parámetros optimizados aumentan la precisión entre los datos pronosticados y los observados de las estaciones. En el presente estudio, los modelos ARIMA presentaron métricas de predicción confiables (Tabla 13).



**Figura 11.** Serie temporal de datos de Inguincho y corrección de *outliers*

El error cuadrático medio (RMSE) de las estaciones presenta valores por debajo de 0.55, siendo éste el más alto perteneciente a la estación de San Gabriel. En cuanto al error absoluto medio (MAE), los valores se encuentran entre 0.42 y 0.25 de error. Por otro lado, el error porcentual absoluto medio (MAPE) es muy bajo, encontrándose entre 3,19 y 0,94%. Estos resultados demuestran una buena precisión en las predicciones realizadas.

En su estudio, Miranda (2021) también utiliza medidas como MAE y RMSE para calcular la bondad de su modelo en el pronóstico de temperatura. A diferencia de lo obtenido en este estudio, este autor obtiene valores de MAE de 1.33 y 1.68 de RMSE. No obstante, afirma que el modelo SARIMA de pronóstico es efectivo.

**Tabla 13.** Medidas de bondad de predicción

<b>Estación</b>	<b>RMSE</b>	<b>MAE</b>	<b>MAPE (%)</b>
Inguincho	0.35	0.27	2.47
Otavalo	0.45	0.36	2.35
Cahuasqui FAO	0.54	0.42	2.54
San Gabriel	0.55	0.40	3.19
El Ángel	0.39	0.33	2.68
Cayapas	0.37	0.25	0.94
La Concordia	0.42	0.32	1.31

Mariño (2021) construyó varios modelos estadísticos funcionales para predecir la temperatura ambiental de 11 estaciones meteorológicas ubicadas en la provincia de Chimborazo. Para ello, generó modelos univariantes ARIMA para obtener coeficientes. Al evaluar los datos pronosticados, Mariño obtuvo valores promedio para las estaciones de 1,38 de MAE, 3.15 de RMSE y 0.21% de MAPE. Estos resultados de las métricas de error son más altos que los reportados en este estudio, lo que sugiere que el pronóstico de temperatura para las estaciones del INAMHI es confiable.

Finalmente, se graficaron las series de temperatura completas del periodo 1991 – 2020, como se observa en el Anexo 4, los datos rellenados siguen la misma tendencia que los datos originales.

- **Validación de información de TerraClimate e INAMHI**

Las series de los datos del INAMHI y TerraClimate (TC) mostraron diferentes concordancias para las estaciones. Los valores del RMSE obtenidos se encuentran entre 0.61 y 0.98, lo que indica una concordancia muy buena considerando este índice (Tabla 14). Las estaciones Inguincho y La Concordia obtuvieron un RMSE de 0.63 y 0.61, respectivamente, siendo estas las de mayor relación entre las bases de datos. Por su parte, el MAE presenta valores por debajo de 0.81. De manera similar, las estaciones antes mencionadas presentan los valores más bajos, con 0.47 para La Concordia y 0.51 para Inguincho. Muthoni (2020) en su comparación de temperatura mínima ( $T_{mín}$ ) y



temperatura máxima (T<sub>máx</sub>) de TC con estaciones ubicadas en seis países de la región de África Occidental, obtuvo un RMSE de 0.92 para T<sub>máx</sub> y 1.31 para T<sub>min</sub>, estos mostraron una concordancia muy buena similar al del presente estudio con un valor de RMSE más alto para T<sub>min</sub>. El ajuste descrito de la relación de los datos se evidencia gráficamente para cada estación en el Anexo 6, pues de manera diferenciada presentan una relativa dispersión en la nube de puntos.

**Tabla 14.** Valores de coeficientes de correlación e índices de desempeño entre datos de TerraClimate e INAMHI

Estación	RMSE	MAE
Inguincho	0,63	0,51
Otavalo	0,87	0,70
Cahuasqui-FAO	0,98	0,80
San Gabriel	0,73	0,59
El Angel	0,97	0,81
Cayapas	0,89	0,76
La Concordia	0,61	0,47

*Nota.* Las estaciones Cahuasqui-FAO, El Ángel y Cayapas tienen el coeficiente de correlación de Spearman.

De manera similar, Araghi et al. (2023) evaluaron la calidad de las series temporales de T<sub>mín</sub> y T<sub>máx</sub> derivadas de TC con 40 estaciones situadas en Irán, así obtuvieron que el MAE para T<sub>máx</sub> presentó un valor promedio de  $0,99 \pm 0.4$  para casi todas las estaciones y para T<sub>min</sub> MAE =  $1.3 \pm 0.7$ , demostrando un buen desempeño y concluyendo que las bases de datos de TC son confiables. Por su parte, Filgueiras et al. (2022) al evaluar la concordancia utilizando información de estaciones meteorológicas automáticas de Brasil (AWS), obtuvieron valores de MAE de 1.47 para la temperatura media, 2.02 para T<sub>max</sub> y 1.94 para T<sub>min</sub>. Los resultados de RMSE también se verifican similares al MAE, con el valor más bajo para la temperatura media (2.13), seguido por 2.53 para T<sub>min</sub> y 2.71 para T<sub>max</sub>. A pesar de obtener estos valores, afirman que las bases de datos de TC con las estaciones AWS tienen una buena concordancia.

Por otro lado, en la provincia de Chimborazo, Nono (2023) evaluó la temperatura de TerraClimate con 30 estaciones meteorológicas utilizando el coeficiente de correlación de Pearson (r). El análisis mostró una correlación casi perfecta, con un coeficiente r de 0.96, no obstante, el análisis lo realizó en conjunto una sola vez y no de manera personalizada para cada estación, lo que podría sobreestimar la concordancia en las ubicaciones de ciertas estaciones ya que las ubicaciones de las mismas influyen

considerablemente en la temperatura por la variabilidad orográfica en la región andina del Ecuador.

En el anexo 5 se verifica una concordancia buena entre los datos de la temperatura media, además, los datos de TerraClimate presentan patrones similares a los datos de las estaciones meteorológicas del INAMHI a lo largo de los 30 años.

- **Validación de información de TerraClimate con el gradiente ambiental**

La prueba  $z$  indicó que las medias de los datos históricos mensuales de las estaciones Inguincho, Otavalo, San Gabriel y La Concordia, no tienen diferencias estadísticamente significativas con la temperatura media obtenida con el gradiente ambiental vertical. El valor del estadístico  $z$  calculado es menor que el valor crítico  $z$  de 1.96 para alfa de 0.05 (Tabla 15), del mismo modo, el valor de  $p$  ( $p$  value) obtenido para todas las estaciones es mayor que 0.05, con lo cual se acepta la hipótesis nula que establece que las medias comparadas son iguales. De este modo, se demuestra que las estaciones meteorológicas y el gradiente ambiental vertical tienen datos similares.

**Tabla 15.** Valores estadísticos de la prueba  $z$  para estaciones

Comparación	Media estación	Media gradiente	$z$	$p$ value
Inguincho – Gradiente	10.55	10.95	0.68	0.50
Otavalo – Gradiente	14.78	13.84	-1.69	0.09
San Gabriel – Gradiente	12.42	12.32	-0.14	0.89
La Concordia – Gradiente	24.44	25.00	0.72	0.47

En la comparación entre la información de TerraClimate y el gradiente ambiental se obtuvo una muestra total de 55 puntos con un nivel de confianza del 90% y un rango de error de 10% (Anexo 7). La temperatura media de los puntos obtenidos mediante el gradiente ambiental y los datos de la TerraClimate mostraron no tener diferencias estadísticamente significativas, pues la prueba  $t$  de Student mostró medidas como el estadístico  $t$  menor que 1.96 para alfa de 0.05 y valor de  $p$  ( $>0.05$ ) (Tabla 16). Del mismo modo, la prueba ANOVA exhibió un valor de  $p$  mayor a 0.05 para todos los pliegues. Estas se respaldan con las pruebas  $F$  y de Levene, los cuales indican que las varianzas o las desviaciones estándar no tienen diferencias estadísticamente significativas.

**Tabla 16.** Valores estadísticos de comparación

Pliegue	Prueba F		t de Student		Prueba de Levene		ANOVA	
	F	Valor-P	T	Valor-P	Prueba	Valor-P	Razón-F	Valor-P
Pliegue 1	1.54	0.51	0.92	0.37	0.26	0.62	0.85	0.37
Pliegue 2	0.60	0.44	0.14	0.89	0.76	0.39	0.02	0.89
Pliegue 3	0.39	0.15	-0.88	0.39	2.34	0.14	0.78	0.78
Pliegue 4	0.69	0.56	-0.39	0.70	0.91	0.35	0.15	0.70
Pliegue 5	0.35	0.11	-0.05	0.96	2.48	0.13	0.002	0.96

Los resultados obtenidos revelan que los datos de TC se ajustan con la información real de temperatura, ya que el gradiente ambiental vertical refleja como la temperatura varía en función de la elevación en la localidad. Esta concordancia se observa también con la temperatura registrada por las estaciones del INAMHI. Por lo tanto, la información de temperatura de TC es confiable y se adapta a las condiciones de la localidad.

- **Umbral de desarrollo y rango óptimo en función de la temperatura**

Para *B. cockerelli* S., Abdullah (2008) afirma que las condiciones para un desarrollo óptimo son de 26 °C-27 °C y 60-70 % de humedad relativa, que requirió en promedio 34.7 días. Este rango de temperatura coincide con lo obtenido por Yang & Liu (2009), quienes en un experimento afirmaron que los estadios inmaduros se desarrollaron de manera precoz a 26.7 °C. No obstante, Capinera (2021) asegura que el rango óptimo de temperatura es de 21 °C–27 °C (Tabla 17). Considerando este rango óptimo y la temperatura media (Anexo 10), la provincia cuenta con un 9.69% de su superficie como óptima para el psílido, ubicadas en el suroeste de la zona de Intag (Las Golondrinas y García Moreno) y en el norte de Imbabura, específicamente en las parroquias La Merced de Buenos Aires, Lita y La Carolina (Figura 12A).


Por otro lado, Tran et al. (2012) aseveran que, en el cultivo de papa, a 8 °C el psílido tarda 90.3 días en completar su desarrollo (de huevo a adulto), tiempo que a 31 °C se reduce a 25.5 días, no obstante, observaron altas tasas de mortalidad a estas temperaturas extremas (8 y 31 °C) en cultivos hospedantes como el tomate y la papa con una humedad del 50 al 60 %. Las tasas de mortalidad a 8 °C fueron de 93% en el tomate y 89% en la papa, mientras que, a 31 °C las tasas fueron de 85% en el tomate y 87% en la papa. Por tal motivo, para este estudio se consideró un umbral bajo de 8 °C debido a que la tasa de mortalidad supera el 90%, además, Tran et al. (2012) sugieren que tanto en la observación de laboratorio como la de campo a temperaturas menores como 7 °C ya no ocurre el

desarrollo, mientras que, el umbral alto se estableció en 32 °C ya que por encima de este valor, la temperatura es perjudicial para el psílido ya que reduce la oviposición y la eclosión (List, 1928 como se citó en Capinera, 2021).

**Tabla 17.** Umbral de desarrollo de temperatura para *B. cockerelli* S.

Detalle de umbral	Valor de umbral
Temperatura mínima	8 °C
Temperatura máxima	32 °C
Temperatura óptima de desarrollo	21 – 27 °C

Tomando en cuenta el umbral mínimo de 8 °C, las áreas que no son aptas para el establecimiento se encuentran en zonas de gran elevación y abarcan un 3.33% de la superficie de Imbabura. Mientras que, no se registra temperaturas superiores a 32 °C en la provincia. Por otro lado, en un estudio realizado por Jácome et al. (2022) en tres localidades de la Sierra ecuatoriana, se determinó que *B. cockerelli* S. puede desarrollarse entre 13.91 °C y 20.58 °C. Esto evidencia la capacidad de la especie para desarrollarse en áreas con temperaturas aptas (umbral de desarrollo), las cuales abarcan casi en su totalidad a Imbabura con el 86.98% de su superficie.



**Figura 12.** A. Rango de umbral de desarrollo y rango óptimo de *B. cockerelli* S. con base a la temperatura media; B. Rango de umbral de desarrollo y rango óptimo de *F. occidentalis* con base en la temperatura media

En cuanto a *F. occidentalis*, Lacasa & Martínez (2018) afirman que la temperatura mínima requerida para su desarrollo es de 10 °C. Las larvas recién nacidas son particularmente sensibles a las temperaturas más bajas, mientras que a 35 °C, la mortalidad larval aumenta significativamente y la fecundidad disminuye. De manera similar, Gaum et al. (1994) determinaron que el umbral mínimo para el desarrollo es de 9.4 °C. Lo anterior se asemeja con lo obtenido por Jarosik et al. (1997), quienes en su estudio determinaron que el umbral inferior para el desarrollo preimaginal (desde la etapa de huevo hasta adulto) fue de 10.7 °C. Asimismo, Nondillo et al. (2008) demostraron experimentalmente bajo condiciones controladas que el umbral inferior es de 9.9 °C. Por lo que, el umbral inferior y superior considerado para el presente estudio es 10 °C y 35 °C, respectivamente (Tabla 18).

Por otro lado, Pujota (2013) menciona que el rango de temperatura óptima varía de 18 °C y 25 °C con una duración de 19 días de su ciclo biológico. Nondillo et al. (2008) estimaron los requerimientos térmicos para el desarrollo de la especie en cada estadio, obteniendo que la mejor tasa de desarrollo se encuentra entre 25 °C y 28 °C. De manera similar, Li (2008) determinó que la tasa de supervivencia de *F. occidentalis* fue más alta a 25 °C y más baja a los 30 °C. Así también, mencionan que a medida que la temperatura aumenta de 15 °C a 30 °C la tasa de desarrollo también se incrementa, lo cual muestra una relación proporcional. Además, Hedong (2007) encontró que la tasa de supervivencia en las diferentes etapas de desarrollo de la especie fue de 100% en temperaturas de 19 °C-28 °C.

De acuerdo con lo citado anteriormente, se estableció que el rango de desarrollo óptimo se encuentra entre 19 °C – 28 °C, este último valor (28 °C) coincide con Hedong (2007) y Nondillo et al. (2008), se consideró 19 °C debido a que a 15 °C la tasa de desarrollo aumenta significativamente, lo que sugiere que a 19 °C la tasa de desarrollo es idóneo. En la Figura 12B se muestra las ubicaciones de las superficies con temperaturas no aptas (12.34%), aptas (67.14%) y óptimas (20.52%). Las áreas óptimas se encuentran distribuidas por las parroquias Urcuquí, Ambuquí, Salinas, La Carolina, Lita, La Merced de Buenos Aires, Selva Alegre, García Moreno y Las Golondrinas.

**Tabla 18.** Umbral de desarrollo de temperatura para *F. occidentalis*

Detalle de umbral	Valor de umbral
Temperatura mínima	10 °C
Temperatura máxima	35 °C
Temperatura óptima de desarrollo	19-28 °C

#### **4.1.2 Factor altitud**

La altitud es un factor que influye en el ciclo de vida de *F. occidentalis* y *B. cockerelli* S., ya que las especies de insectos responden a los cambios de altitud a través de adaptaciones directas, como modificaciones fisiológicas y morfológicas, e indirectas, como la variación en la selección de plantas hospedantes y las interacciones con otros organismos. Por ejemplo, las densidades poblacionales de especies fitófagas están determinadas por la interacción tritrófica entre la planta huésped, el insecto, y sus depredadores y parasitoides, los cuales varían a diferentes niveles en función de la elevación. Esto indica que la altitud, al determinar la sincronía tritrófica, influye en la biología de insectos, incluyendo el consumo de alimentos, la eficiencia de la conversión de alimentos, las tasas de crecimiento, la supervivencia y la fecundidad (Hodkinson, 2005). Existe cambios significativos en las condiciones ambientales a lo largo del gradiente altitudinal. Entre estas se incluyen la temperatura, la densidad del aire y la presión parcial de oxígeno (Dillon et al., 2006). Por tanto, la elevación es un factor fundamental para el desarrollo de especies poiquilotérmicas.

Varios estudios han determinado el rango óptimo de altitud para el desarrollo de *B. cockerelli* S. Rubio et al. (2011) destacaron que la altitud ideal se encuentra entre los 2 600 a 3 200 m s.n.m. Sin embargo, observaron una disminución significativa en las poblaciones por encima de los 3 500 m s.n.m., sugiriendo la existencia de limitaciones ambientales a altitudes más elevadas. Calderón (2022) indica que la especie podría encontrarse en altitudes que varían desde 2 618 hasta 3 103 m s. n. m, proporcionando así un rango específico de distribución altitudinal similar al anterior. Vallejo (2020) respalda la adaptación de *B. cockerelli* S. en estos rangos al registrar altitudes que oscilan entre 2 400 y 3 000 m s. n. m., confirmando su buena adaptación a condiciones ambientales específicas de estas altitudes. Además, Falconez (2020) determinó condiciones óptimas para el desarrollo completo del psílido en altitudes de 2 919, 2 725 y 2 945 m s. n. m., correspondientes a Saquisilí, Salache y Machachi, respectivamente. De acuerdo con lo

citado anteriormente, para este estudio se estableció como rango óptimo las altitudes entre 2 600 y 3 200 m s. n. m. (Tabla 19). Imbabura posee altitudes bien marcadas que van desde los 147 m s. n. m. hasta los 4 919 m s. n. m (Anexo 3). Por lo tanto, presenta áreas con altitudes óptimas que abarcan el 22.72% de su territorio, ubicadas en todos los cantones, como se visualiza en la Figura 13A.


Por otro lado, Toledo-Perdomo & Rodas (2022) registraron la presencia de *B. cockerelli* S. a 2 286 m s. n. m., evidenciando su adaptación a altitudes más bajas. En contraste, Falconez (2020) señala que, en las zonas altoandinas, el psílido de la papa es evidente a altitudes superiores a 1 000 m s. n. m. Esta presencia se confirma en Imbabura, donde los registros de Agrocalidad muestran la ocurrencia del insecto en altitudes que van desde 1 014 hasta 3 376 m s. n. m. en diversos cultivos. De este modo, el umbral altitudinal mínimo para la presencia del psílido se consideró en 1 000 m s. n. m., mientras que el umbral máximo se estableció en 3 500 m s. n. m, puesto que a altitudes mayores no presenta condiciones ambientales favorables. Considerando estos umbrales, el área de estudio muestra que el 18.16% de su superficie no es apta, mientras que el 59.12% es apta.

**Tabla 19.** Umbral de desarrollo de elevación para *B. cockerelli* S.

Detalle de umbral	Valor de umbral
Altitud mínima	1 000 m s. n. m
Altitud máxima	3 500 m s. n. m
Altitud óptima de desarrollo	2 600 – 3 200 m s. n. m

Los rangos altitudinales de la especie se relacionan con la altitud en la que se encuentran los cultivos de papá (*S. tuberosum*), su huésped preferido, pues esta especie vegetal tiene su origen a altitudes de 2 000 m s. n. m., (Bajaj & Sopory, 1986). Según Samaniego et al. (2020) las zonas de producción se concentran en la Sierra ecuatoriana entre 2 700 y 3 400 m s. n. m. No obstante, los mejores rendimientos se producen en ubicaciones entre 2 900 y 3 300 m s. n. m (MAG, 2016). Este último rango es muy similar con el rango óptimo de la plaga lo que indica una relación con su huésped. Por su parte, Hijmans & Spooner (2001) al analizar la distribución geográfica de las especies de papa silvestre (*Solanaceae, sección Petota Dumort.*) emparentadas con la papa cultivada, determinaron que, en latitudes bajas, como en las que se encuentra Ecuador, el 75% de las observaciones se registran en zonas por encima de los 2 300 m s. n. m. y todas las

especies de papa silvestre mostraron una elevación promedio de 2 770 m s. n. m. Este hallazgo revela la preferencia de las especies de papa silvestre y la papa cultivada por altitudes elevadas en regiones andinas, por ende, resalta la importancia de las condiciones altitudinales en la ecología de *B. cockerelli* S.




**Figura 13. A.** Rango de umbral de desarrollo y rango óptimo de *B. cockerelli* S. con base a la elevación; **B.** Rango de umbral de desarrollo y rango óptimo de *F. occidentalis* con base a la elevación

Para *F. occidentalis*, el 88.61% de los puntos de ocurrencia en Imbabura se encuentran entre 1 575 y 2 725 m s. n. m. De las 12 clases generadas en la tabla de frecuencias (Anexo 8), este rango corresponde a las seis clases con mayor frecuencia relativa. Esto se evidencia en el histograma, donde la mayor cantidad de datos representados en columnas se ubica en este rango de altitudinal (Figura 14a). Bryan & Smith (1956) afirman que el trips se halla hasta altitudes subalpinas (1 500 – 2 500 m s. n. m.), lo que concuerda con el rango altitudinal con mayor frecuencia en Imbabura. En Colombia, Ebratt R. et al. (2013) identificaron una presencia constante de *F. occidentalis* en cultivos de tomate y arvenses en varias regiones de Cundinamarca, con altitudes de presencia que variaron entre 1 624 m s. n. m. y 2 572 m s. n. m. De manera similar, se evidencia presencia del trips en el cantón Bolívar provincia del Carchi a una altitud de 1 792 y 2 400 m s. n. m. en el cultivo de fréjol arbustivo y en *Rosa sp.*, respectivamente (Benavides, 2021; Ojeda,



2003). Por tal motivo, el rango de altitud con mayor frecuencia de ocurrencia se estableció como altitud óptima de desarrollo (Tabla 20).



**Figura 14.** Histograma (a) y cajas y bigotes (b) de la variable altitud

Por otro lado, la altitud mínima de presencia registrada es 1 033 m s. n. m., mientras que la máxima es 3 284 m s. n. m (Figura 14b). En virtud de esto, se definió que la altitud mínima en la que se registra la presencia de *F. occidentalis* es 1 000 m s. n. m., hasta una altitud de 3 300 m s. n. m. A esta última altitud, la temperatura media según el gradiente ambiental vertical es de 11.63 °C, muy cerca del umbral mínimo de temperatura (10°C) en el que la plaga puede sobrevivir (Lacasa & Martinez, 2018), lo que explica la ausencia de registros a mayores altitudes. Solano-rojas et al. (2018) obtuvieron registros de *F. occidentalis* en las principales zonas productoras de Venezuela, en un rango de 1 200 a 2 800 m s. n. m., altitudes similares a las observadas en Imbabura. Considerando los umbrales y el rango altitudinal óptimo de la Tabla 20, se observa que Imbabura cuenta con un 43.79% de su superficie como óptima, un 32.36% como apta y un 23.85% no apta para *F. occidentalis*, como se visualiza en la Figura 13B.

**Tabla 20.** Umbral de desarrollo de elevación para *F. occidentalis*

Detalle de umbral	Valor de umbral
Altitud mínima	1 000 m s. n. m
Altitud máxima	3 300 m s. n. m
Altitud óptima de desarrollo	1 575 – 2 725 m s. n. m

El trips *F. occidentalis* ataca diversas especies vegetales, entre las que destacan el aguacate y el fréjol. La altitud en la que se ubican estos cultivos en la Sierra ecuatoriana se relaciona con la presencia del trips, pues son sus hospederos. En los valles interandinos, el aguacate se cultiva en un rango altitudinal que va desde los 1 800 hasta los 2 500 m s.

n. m. (Villavicencio & Vásquez, 2008), siendo uno de los principales hospederos del trips. Además, este rango altitudinal del cultivo de aguacate se encuentra dentro del rango óptimo de altitud establecido. Por otro lado, el fréjol puede desarrollarse en los valles de la Sierra a altitudes que oscilan entre 1 200 y 2 500 m s. n. m., y entre 1 000 y 2 200 m s. n. m. en las estribaciones de la cordillera (Peralta et al., 2014). Del mismo modo, estos rangos altitudinales en los que prosperan estas especies vegetales concuerdan con lo establecido para este estudio, lo que demuestra la relación entre los rangos altitudinales establecidos con los cultivos hospedantes del trip más importantes en Imbabura.

## **4.2 Modelo de proyección del umbral y condiciones de desarrollo**

### **4.2.1 Entrenamiento y evaluación de modelos individuales**

Los *datasets* etiquetados con umbrales y rangos óptimos de elevación y temperatura por cada especie se entrenaron con 33 tipos de algoritmos de clasificación preempaquetados en la aplicación *Clasificattion Learner*. A continuación, se detallan los resultados del entrenamiento, las métricas de validación y la evaluación del mejor algoritmo de clasificación para los *datasets*.

#### **4.2.1.1 Clasificadores automáticos individuales para los umbrales de especies**

- **Clasificadores para los umbrales de temperatura**

Los clasificadores automáticos con mayor precisión para temperatura en los conjuntos de datos entrenados fueron Redes neuronales, específicamente los “Medium Neural Network” y “Wide Neural Network”, con una precisión o tasa de acierto del 99.9915% (Tabla 21). Los Árboles de Decisión (DT), incluyendo “Fine Tree”, “Medium Tree” y “Coarse Tree”, alcanzaron el 99.9901% de precisión. De manera similar, K vecinos más cercanos (KNN), con “Fine KNN” y su conjunto con “Subspace KNN” demostraron una precisión del 99.9901%.

**Tabla 21.** Precisión y tiempo de entrenamiento de los mejores clasificadores para datos de temperatura

Clasificador	Algoritmo de clasificación	t (seg)	Acc (%)
Árboles de Decisión (DT)	Fine Tree	10.6302	99.9901
	Medium Tree	8.1144	99.9901
	Coarse Tree	8.9078	99.9901
Análisis Discriminante (DA)	Quadratic Discriminant	6.8046	98.4206
Clasificadores Lineales Eficientes	Efficient Linear SVM	7.3975	99.0265
Naive Bayes	Kernel Naive Bayes	31.1667	99.7602
Máquinas de vectores de soporte (SVM)	Fine Gaussian SVM	44.2328	99.9390
K vecinos más cercanos (KNN)	Fine KNN	57.4337	99.9901
Clasificadores de conjunto (Ensemble Classifiers)	Subspace KNN	102.9657	99.9901
Redes Neuronales	Medium Neural Network	116.6087	99.9915
	Wide Neural Network	149.0198	99.9915
Clasificadores con aproximación de kernel	SVM Kernel	226.0859	76.0295

El algoritmo de clasificación con mayor tasa de aciertos no siempre es el más adecuado. Al seleccionar un algoritmo, es fundamental considerar el coste computacional en los procesos de aprendizaje y validación de cada modelo predictivo (González, 2021). Debido a ello, es importante considerar la eficiencia en términos de tiempo de entrenamiento al seleccionar un modelo. En este estudio, aunque todos los modelos lograron una precisión consistente para clasificar los rangos de umbrales de *B. cockerelli* *S.*, *F. occidentalis* y su interacción conjunta (*B. cockerelli* *S.* y *F. occidentalis*), el modelo del Árbol de decisión “Medium Tree” se destaca como el mejor modelo predictivo para clasificar datos de temperatura debido a su menor tiempo de entrenamiento, pues este modelo obtuvo un tiempo de 8.11 segundos y una precisión de 99.9901%.

- **Clasificadores para los umbrales de elevación**

De los 33 clasificadores automáticos entrenados para datos de elevación con los diferentes umbrales de *B. cockerelli* *S.*, *F. occidentalis* y su interacción conjunta, destaca la red neuronal “Bilayered Neural Network” con una precisión de 99.98%. Le siguen los

clasificadores que obtuvieron una precisión de 99.98%, los cuales pertenecen a los diferentes tipos de clasificadores de los árboles de decisión, KNN, clasificadores de conjunto (Ensamble Classifiers) y redes neuronales, como se detalla en la Tabla 22. En general, la mayoría de los modelos demostraron consistentemente su efectividad en la clasificación de datos de elevación, a excepción de los clasificadores con aproximación de Kernel que tienen una precisión por debajo del 70%.

Al considerar el tiempo de entrenamiento promedio para ambas especies e interacción conjunta, el modelo Árbol de Decisión “Medium Tree” destacó nuevamente con un tiempo de entrenamiento de 2.89 segundos y 99.98% de precisión, lo que lo posiciona como el mejor clasificador para datos de elevación. Aguirre & Gallegos (2019) mencionan que los DT son rápidos en cuanto a la predicción. Además, los modelos que se basan en DT favorecen la agilidad en el proceso de evaluación de estos y son más intuitivos (González, 2021). Lo anterior justifica el tiempo de entrenamiento eficiente del Árbol de Decisión “Medium Tree” en la predicción de estas clases.

**Tabla 22.** Precisión y tiempo de entrenamiento de los mejores clasificadores para datos de elevación

Clasificador	Algoritmo de clasificación	t (seg)	Acc (%)
Árboles de Decisión (DT)	Fine Tree	3194827.1536	99.9749
	Medium Tree	2.8880	99.9749
	Coarse Tree	3.6166	99.9749
Análisis Discriminante (DA)	Quadratic Discriminant	2.7820	92.5930
Clasificadores Lineales Eficientes	Efficient Linear SVM	3.9305	61.1410
Naive Bayes	Kernel Naive Bayes	5.3446	98.6392
Máquinas de vectores de soporte (SVM)	Fine Gaussian SVM	10.1458	99.9210
K vecinos más cercanos (KNN)	Fine KNN	3.3628	99.9713
	Weighted KNN	3.6759	99.9713
Clasificadores de conjunto (Ensemble Classifiers)	Bagged Trees	9.7413	99.9749
	Subspace KNN	15.4669	99.9713
Redes Neuronales	Bilayered Neural Network	16.5745	99.9892
	Trilayered Neural Network	25.9102	99.9677
Clasificadores con aproximación de kernel	SVM Kernel	13.3091	55.7913
	Logistic Regression Kernel	14.3190	55.7913

#### 4.2.1.2 Evaluación de clasificadores con mayor rendimiento

- **Valores de área bajo la curva (ROC) para los modelos**

La capacidad del clasificador Árbol de Decisión con profundidad media “Medium Tree” para distinguir clases según los rangos de umbrales con datos de temperatura y elevación se refleja en los valores del Área bajo la Curva (AUC) presentados en la Tabla 23. Los resultados muestran valores AUC superiores a 0.9988 para todas las clases de *B. cockerelli S.*, *F. occidentalis* y su conjunción, lo que indica una excelente capacidad para clasificar las categorías. Las curvas ROC obtenidos para los diferentes *datasets* entrenados con “Medium Tree” se adjuntan en los Anexos 18-23.

**Tabla 23.** Valores de AUC del mejor clasificador para temperatura y elevación

<b>Rendimiento para temperatura</b>				
<b>Clasificador</b>	<b>Especie(s)</b>	<b>Clase 0</b>	<b>Clase 1</b>	<b>Clase 2</b>
<b>Medium Tree</b>	<i>B. cockerelli S.</i>	0.9998	0.9999	1
	<i>F. occidentalis</i>	0.9999	0.9999	0.9999
	<i>B. cockerelli S.</i> y <i>F. occidentalis</i>	0.9998	0.9997	0.9999
<b>Rendimiento para elevación</b>				
<b>Clasificador</b>	<b>Especie(s)</b>	<b>Clase 0</b>	<b>Clase 1</b>	<b>Clase 2</b>
<b>Medium Tree</b>	<i>B. cockerelli S.</i>	0.9997	0.9995	0.9994
	<i>F. occidentalis</i>	0.9998	0.9999	1
	<i>B. cockerelli S.</i> y <i>F. occidentalis</i>	0.9997	0.9988	0.9998

Lee & Yun (2023) obtuvieron un valor de validación similar al del presente estudio, con un promedio de AUROC de 0.92 al evaluar su modelo de predicción de riesgo de enfermedades mediante la curva ROC, con lo cual afirman que el modelo tiene un desempeño sobresaliente. De manera similar, Furtado (2021) utiliza la curva ROC para evaluar y comparar técnicas de aprendizaje automático en problemas de clasificación binaria. Al aplicar el clasificador Árbol de Decisión, obtiene un valor de AUC de 0.84 y 0.83 para las técnicas 1 y 2, respectivamente. Estos últimos valores de AUC son inferiores a los obtenidos en este estudio, lo que sugiere que el desempeño demostrado por el clasificador “Medium Tree” es sobresaliente. No obstante, es fundamental complementar

esta evaluación con otros métodos, ya que la curva ROC tiende a sobreestimar el desempeño de los algoritmos (Davis & Goadrich, 2016).

- **Tasa de error por clase para los modelos**

Para mejorar la evaluación se analizó la matriz de confusión, el cual evalúa la tasa de aciertos y desaciertos de modelos de clasificación automática para cada una de las clases. En la Tabla 24 se muestra la tasa de error por cada clase para cada variable y especie. El modelo "Medium Tree" con datos de temperatura muestra porcentajes de error inferiores al 0.0474% para todas las clases: Clase 0, Clase 1 y Clase 2, correspondientes a las especies *B. cockerelli* S., *F. occidentalis* y su conjunción, lo que indica una clasificación precisa de las clases, además, la Clase 2 tiene un error del 0%. En cuanto a la clasificación basada en la elevación, el clasificador también presenta una predicción precisa con errores mínimos por debajo del 0.2321% para las tres clases. Además, el modelo de elevación para los umbrales de *F. occidentalis* es el más confiable, con una tasa de error del 0% para las clases 1 y 2, y del 0.0369% para la Clase 0.

**Tabla 24.** Tasa de error por clase según la matriz de confusión del mejor clasificador para temperatura y elevación

<b>Tasas de error para temperatura</b>				
<b>Clasificador</b>	<b>Especie(s)</b>	<b>Clase 0</b>	<b>Clase 1</b>	<b>Clase 2</b>
<b>Medium Tree</b>	<i>B. cockerelli</i> S.	0.0305%	0.0062%	0.0000%
	<i>F. occidentalis</i>	0.0185%	0.0174%	0.0000%
	<i>B. cockerelli</i> S. y <i>F. occidentalis</i>	0.0305%	0.0474%	0.0000%
<b>Tasas de error para elevación</b>				
<b>Clasificador</b>	<b>Especie(s)</b>	<b>Clase 0</b>	<b>Clase 1</b>	<b>Clase 2</b>
<b>Medium Tree</b>	<i>B. cockerelli</i> S.	0.0438%	0.0186%	0.1233%
	<i>F. occidentalis</i>	0.0369%	0.0000%	0.0000%
	<i>B. cockerelli</i> S. y <i>F. occidentalis</i>	0.0438%	0.2331%	0.0000%

La tasa de error muy baja (<0.23%) obtenido para todas las clases en todos los *datasets*, corrobora la precisión del modelo “Medium Tree” en las clasificaciones individuales para elevación (99.97%) y temperatura (99.99%). Los desaciertos mínimos para cada clase se atribuyen a las reglas de clasificación simples obtenidas al definir clases con los umbrales

y rangos óptimos, lo que se contrasta con otros procedimientos que integran variables predictoras continuas y categóricas más complejas, que requieren reglas predictivas más avanzadas (Fernández, 2022).

Los gráficos de las matrices de confusión que muestran los aciertos y desaciertos de las clases para cada *dataset* entrenado se incluyen en los Anexos 18 – 23. Del mismo modo, las clases predichas de este modelo se pueden visualizar en los Anexos 24, 25 y 26 para *B. cockerelli* S., *F. occidentalis* y su conjunción, respectivamente.

#### **4.2.1.3 Clasificadores finales para elevación y temperatura**

En la búsqueda del clasificador automático requerido para la predicción de riesgo de presencia a partir de criterios de umbrales y rangos óptimos con temperatura y elevación, el modelo de Árbol de decisión “Medium Tree” es el que mejor se adaptó para este fin. En la Tabla 25 se observa los modelos finales de clasificadores entrenados, en el que continúan destacando los clasificadores Árboles de Decisión y K Vecinos Más Cercanos (KNN) con más del 98.45% de precisión, a excepción de los clasificadores “Cosine KNN”, “Efficient Logistic Regression” y “Efficient Linear SVM”, que son inferiores al 72.78%.

El modelo Árbol de Decisión “Medium Tree” destaca con una tasa de acierto de 99.97% de precisión y 30.16 segundos de entrenamiento, lo que lo posiciona como el más exacto y eficiente. Esto concuerda con los clasificadores individuales de las Tablas 21 y 22, en las que se resalta que los mejores clasificadores son los Árboles de Decisión “Medium Tree”. La precisión obtenida por este modelo es similar a los resultados de Sung et al. (2021), quienes aplican esta técnica con éxito en la clasificación de la intensidad de fenómenos climáticos, demostrando una alta precisión del 90% y 80.50% en los períodos de entrenamiento y prueba, respectivamente. Esto resalta la eficacia de los árboles de decisión y su utilidad en la predicción y gestión de desastres naturales.

**Tabla 25.** Precisión y tiempo promedio de entrenamiento de los clasificadores finales para *B. cockerelli* S., *F. occidentalis* y su interacción conjunta.

Algoritmos de clasificación automático	Acc (%)	t (seg)
Fine Tree	99.9647	31.28
Medium Tree	99.9647	30.16
Coarse Tree	98.4529	29.15
Fine KNN	99.9496	43.01
Medium KNN	99.9293	63.64
Coarse KNN	99.8671	131.77
Cosine KNN	67.4091	2 277.24
Cubic KNN	99.9251	107.96
Weighted KNN	99.9556	101.22
Efficient Logistic Regression	56.2805	150.54
Efficient Linear SVM	72.7771	151.20

Furtado (2021) aplica técnicas de aprendizaje automático para predecir la intención de compra de usuarios (resolver problemas de clasificación binaria), de este modo al emplear el Árbol de Decisión obtiene una tasa de acierto de 87.62% y 87.84% con la técnica uno y la técnica dos, respectivamente. Asimismo, Padilla & Haro (2021) utilizan la técnica de Árboles de Decisión para identificar niveles de carbono edáfico, determinando que el algoritmo de clasificación CART es el más preciso con 63.41% de precisión. Por otro lado, Serra (2020) comparan cuatro clasificadores basados en Árboles de Decisión para determinar que algoritmo se comporta mejor, obteniendo una precisión de 86.78%, 85.97%, 83.82% y 80.92% para Random Forest, DT Bagging, DT simple y AdaBoost, respectivamente. La precisión de los algoritmos de DT detallados en los trabajos anteriores, aplicados en diferentes campos, es significativamente más baja que la obtenida con el modelo “Medium Tree” en este estudio. Esto sugiere que el algoritmo de clasificación desarrollado es muy robusto y eficaz.

Los DT se han aplicado en diversos contextos de estudio. En el ámbito de la seguridad informática, Singh et al. (2022) demuestran cómo esta técnica se utiliza para evaluar la importancia de los predictores en la detección de intrusiones y optimizar la eficiencia del sistema. Además, en aplicaciones espaciales y de observación terrestre, los DT se utilizan para la detección de nubes en imágenes satelitales. Yu & Tan (2019) proponen un algoritmo basado en Árboles de Decisión con una precisión superior al 85% en la detección de nubes, destacando su efectividad en entornos donde la detección precisa de nubes es esencial para la planificación y la toma de decisiones. Por otro lado, en el



mantenimiento y diagnóstico de sistemas energéticos, Jordán (2023) desarrolló una aplicación con algoritmos de aprendizaje automático para detectar de manera temprana posibles fallos en paneles solares. Entre los algoritmos evaluados, el Árbol de Decisión optimizado destacó como uno de los mejores, con una precisión del 99.2% y 97.1% para los métodos de seguimiento de puntos de potencia 1 y 2, respectivamente.

A diferencia de las redes neuronales, el Árbol de Decisión destaca por su habilidad para manejar datos nominales y categóricos, lo que lo convierte en una opción viable en modelos prescriptivos. Samadianfard et al. (2022) emplearon esta capacidad en su estudio para la predicción de precipitaciones, utilizando datos diarios como precipitación, humedad relativa media y extremas, temperaturas mínimas y máximas, horas de sol y velocidad del viento. A través del algoritmo de DT, se explicó la predicción de manera clara y comprensible mediante reglas lógicas. Como resultado de este enfoque, se logró predecir precipitaciones hasta con 4 días de antelación con una precisión superior al 78%. Esto muestran la eficacia y utilidad de los árboles de decisión en la predicción meteorológica, proporcionando una comprensión práctica y precisa de los resultados obtenidos.

Los Árboles de Decisión son una técnica versátil que permite segmentar, estratificar, predecir y filtrar variables, facilitando la comprensión de los fenómenos estudiados. Esta versatilidad los convierte en una herramienta valiosa en la toma de decisiones (Berlanga et al., 2013). No obstante, en el campo de la predicción del riesgo de presencia de plagas las investigaciones que emplean clasificadores automáticos son escasos. Lee & Yun (2023) propone un método para predecir infestaciones de plagas y enfermedades en cultivos en función del entorno de crecimiento mediante aprendizaje profundo, es decir, a través de datos ambientales que influyen en el crecimiento de cultivos. Este modelo permite predecir la condición del cultivo ingresando datos ambientales de los últimos dos días de variables como temperatura, humedad relativa, el punto de rocío y concentración de CO<sub>2</sub>, que se puede aplicar a cultivos y otras plagas y enfermedades individuales. Sin embargo, esta predicción se realiza únicamente para el entorno de una instalación cerrada o de granja interior donde reunir las condiciones ambientales no tiene dificultad ya que las variables son controladas artificialmente. Además, para el entrenamiento el modelo requiere un conjunto de datos a gran escala sobre la infestación con plagas y

enfermedades de cultivos durante el crecimiento y durante el registro de información ambiental.

En India, Singh et al. (2016) desarrollaron un modelo genérico de pronóstico del tizón tardío “INDO-BLIGHTCAST”, utilizando datos meteorológicos y registro de las fechas de aparición. Este modelo implica estimar el índice de idoneidad térmica (calculando el efecto de la temperatura sobre la tasa de desarrollo) e idoneidad de humedad relativa durante un periodo de tiempo (días P). Y, finalmente, calcular el índice de severidad del tizón al comparar los acumulados de temperatura y humedad relativa de los días P, y acumulando los valores de severidad durante un periodo tiempo, para clasificar como propicio la aparición en el día donde el índice de idoneidad tanto para temperatura como para humedad es idóneo. De este modo, con el ingreso de fechas de aparición observadas y los datos meteorológicos de determinados lugares de interés, se predice las apariciones de la enfermedad con una alta precisión, ya que el modelo muestra un valor de 0.84 en el índice Willmott D. Esto sugiere su aplicabilidad en otras regiones y con otras especies y enfermedades. Sin embargo, una desventaja de este modelo es que, al aplicar la metodología con otras especies, no se puede predecir la aparición de estas sin conocer previamente el tiempo en que aparecen en determinados lugares. Esto significa que, si se desea determinar el riesgo de aparición en un lugar específico donde no hay registro de observaciones, es imposible la predicción.

En virtud de lo anterior, el modelo de aprendizaje automático construido con “Medium Tree” es una de las pioneras en aplicarse en el contexto de la predicción del riesgo de presencia geográfica de especies. El enfoque metodológico propuesto que utiliza el árbol de decisión para clasificar los umbrales y rangos óptimos de desarrollo de especies según la temperatura y la elevación es adaptable y aplicable en diversos contextos de estudio. La proyección automática empleando este sistema permite ingresar datos de elevación y temperatura sin la necesidad de una programación y entrenamiento por parte del usuario, y generar la predicción del riesgo de presencia automáticamente. A diferencia de otras metodologías, el modelo puede volverse a entrenar para incluir otras variables ambientales influyentes en el ciclo de vida de las especies. Por ejemplo, ILCYM es un software diseñado para modelar el ciclo de vida y fenología de insectos únicamente en

función de la temperatura (Sporleder et al., 2020). No obstante, no tiene la capacidad de predecir los resultados de manera automática al proveer datos.

En el modelado de insectos, se han construido modelos de distribución de especies (SDM) para describir patrones de propagación y evaluar el riesgo de invasión de plagas. Los SDM adoptan enfoques inductivos y deductivos. El enfoque inductivo necesita la presencia de una especie para llevar a cabo el análisis de las relaciones entre la ocurrencia registrada con las variables ambientales prevalecientes y de este modo predecir la distribución y/o abundancia en otras áreas. Mientras que, el enfoque deductivo modela la respuesta de la especie a las variables ambientales para predecir su idoneidad ambiental, es decir, se lleva a cabo mediciones directas de las relaciones entre los parámetros de la tabla de vida (desarrollo, supervivencia, etc.) y las variables individuales para identificar zonas donde puede prevalecer una especie (Tonnang et al., 2017).

El método de modelado Genetic Algorithm for Rule-Set Prediction (GARP) utiliza el enfoque inductivo. El GARP estima la distribución potencial relacionando las características ecológicas de los puntos de ocurrencia de una especie con puntos muestreados aleatoriamente del resto de la región en estudio. De este modo genera una serie de reglas de decisión que resuman mejor los factores asociados con la presencia (Stockwell, 1999). Este método presenta una desventaja ante la ausencia de registros de presencia y en situaciones donde el muestreo aleatorio de puntos en el área de estudio de interés es complicado o no es posible.

Otro método que utiliza el enfoque inductivo es el algoritmo de máxima entropía (MaxEnt). Este algoritmo se basa en la estimación de la consideración de que los individuos ocurren en proporción a su densidad poblacional (Cao et al., 2013). Por ende, necesita una lista de ubicaciones de presencia de una especie y un conjunto de variables ambientales predictoras (precipitación, temperatura, etc.) a través de un área dividido en celdas de cuadrícula, del cual extrae una muestra de ubicaciones de fondo (lugares que no registran la presencia de la especie) que se comparan con las ubicaciones de la presencia (Tonnang et al., 2017). MaxEnt también tiene la misma desventaja del GARP, pues si los datos de presencia son escasos, incompletos o sesgados geográficamente, el modelo puede tener dificultades para capturar adecuadamente la relación entre la especie y las variables ambientales. Por tal motivo, surge la necesidad de optar por otras

metodologías en el cual no se requiere estrictamente puntos de ocurrencia como el modelo propuesto en este estudio.

Dentro del enfoque deductivo, el software ILCYM desarrolla modelos fenológicos, realiza análisis de población y mapeo de riesgos. Este método estima las tasas de desarrollo, supervivencia y reproducción de cada etapa de una especie, lo que permite derivar índices de riesgo específicos (Fand et al., 2014). A través de los factores climáticos, se establece el vínculo entre los índices y el paisaje, generando predicciones de la distribución potencial y abundancia de plagas en regiones de interés (Tonnang et al., 2017). Por otro lado, existen modelos basados en los enfoques inductivos y deductivos. CLIMEX es un modelo que se basa en la respuesta estimada de la especie a la temperatura y humedad. El modelo define la idoneidad del hábitat de una especie en un lugar mediante un índice ecoclimático (EI) (Sutherst & Maywald, 1985). Una ventaja de CLIMEX es que puede simular los efectos de las temperaturas extremas, examinar los umbrales existentes y los cambios en las relaciones.


Sin embargo, los modelos inductivos y deductivos descritos tienen una desventaja al evaluar el efecto del cambio climático en la distribución de una especie: la ambigüedad de utilizar un modelo desarrollado para la distribución actual y luego extrapolarlo en el espacio y el tiempo para anticipar las distribuciones de plagas bajo el cambio climático. Al proyectar el riesgo con escenarios de cambio climático, estos enfoques desarrollan el modelado basándose en condiciones climáticas actuales, los cuales no están diseñados para manejar cambios climáticos extremos o inesperados (Tonnang et al., 2017). Esto motiva la implementación de alternativas que solucionen esta problemática. El modelo propuesto evita este tipo de ambigüedades, pues el sistema no se ve afectado al proyectar el riesgo con datos que incluyen extremos climáticos inesperados.

#### ***4.2.2 Proyección de riesgo de presencia***

A continuación, se presenta cartográficamente el riesgo de presencia de especies proyectadas en diferentes periodos de tiempo en función a la temperatura y elevación empleando las funciones de predicción del modelo Árbol de Decisión “Medium Tree”.

#### 4.2.2.1 Probabilidad de riesgo de presencia de *B. cockerelli* S.

La especie *B. cockerelli* S. presenta un riesgo de presencia que varía desde la categoría "Nula" hasta "Alta" en la provincia de Imbabura (Figura 15). El riesgo determinado no implica necesariamente que la especie esté presente en todos los lugares identificados, sino que las condiciones ambientales como la temperatura y la elevación son favorables para su establecimiento y propagación. En cuanto a la extensión de las diferentes clases de riesgo proyectadas para los periodos de tiempo de 1990-2020 y 2020-2060 bajo los escenarios SSP245 (optimista) y SSP585 (pesimista), indican que varias zonas con riesgo de presencia "Nula" y "Baja" serán reducidas bajo ambos escenarios climáticos, mientras que, las áreas con riesgo "Media" y "Alta" aumentarán. Para 1990, solo el 0.63% del área de Imbabura presentó un alto riesgo de presencia de *B. cockerelli* S. Sin embargo, para el año 2020, este riesgo experimentó un notable aumento, alcanzando el 2.71% del área total. Las proyecciones para 2060, bajo los escenarios climáticos SSP245 y SSP585, revelan una tendencia aún más preocupante. Se estima que el riesgo alto podría ascender a un 3.41% y un 5.62% del área total en el escenario optimista y pesimista, respectivamente.



**Figura 15.** Riesgo de presencia de *B. cockerelli* S. en el pasado, presente y futuro en función de la temperatura y elevación.

Las superficies con riesgo de presencia de *B. cockerelli* S. (Tabla 26) entre 1990 y las proyecciones para el año 2060, revela una serie de pérdidas y ganancias en las distintas categorías de riesgo. En ambos escenarios, se observa una disminución en las categorías

"Nula" y "Baja". Bajo el escenario SSP245, las reducciones son de 1 094.51 ha para la categoría "Nula" y 16 118.34 ha para la categoría "Baja". En el escenario SSP585, las disminuciones son de 1 094.47 y 27 572.57 ha para las categorías "Nula" y "Baja", respectivamente. Por otro lado, las categorías "Media" y "Alta" muestran un aumento del área de riesgo. En el escenario SSP245, los incrementos son de 3 874.81 y 13 336.93 ha para las categorías "Media" y "Alta", respectivamente. Mientras que, bajo el escenario SSP585, los aumentos son de 4 714.69 ha para la categoría "Media" y 23 951.31 ha para la categoría "Alta". Estos cambios sustanciales en las categorías de riesgo de presencia de la especie a lo largo del período estudiado, indica una dinámica compleja en respuesta a los diferentes escenarios de cambio climático proyectados.

**Tabla 26.** Área en hectáreas de la interacción de *B. cockerelli* S. en el pasado, presente y futuro con el modelo MPI-ESM1-2-HR

<b>Categoría</b>	<b>1990</b>	<b>2020</b>	<b>2060-SSP245</b>	<b>2060-SSP585</b>
Nula	95 709.88	94 615.88	94 615.37	94 615.41
Baja	289 848.49	277 324.80	273 730.15	262 275.92
Media	91 467.82	95 068.14	95 342.63	96 182.51
Alta	3 014.57	13 032.22	16 351.50	26 965.88

El área considerada como de riesgo "Nula" en 1990 para *B. cockerelli* S. experimenta una disminución promedio del 0.23% del área total de Imbabura bajo ambos escenarios proyectados hasta 2060. Asimismo, la categoría de riesgo "Baja" disminuye en promedio 4.55%. Por otro lado, se registra un aumento en la extensión del área de riesgo "Alta", con un incremento promedio de 3.88%. De manera similar, la categoría "Media" tiene un incremento del 0.89% del área total de Imbabura. Los cambios descritos evidencian que el cambio climático aumentará la vulnerabilidad de las áreas agrícolas ante el riesgo de presencia de *B. cockerelli* S., ya que las zonas con condiciones no adecuadas y poco favorables pasarán a ser zonas aptas y óptimas para el desarrollo de esta especie. Esto generará desafíos significativos para su manejo y control, así como implicaciones importantes para la producción agrícola y la conservación ambiental en las zonas afectadas.


Los resultados de esta investigación se alinean con el trabajo realizado por Toapanta (2020), quien llevó a cabo un modelamiento de *B. cockerelli* S. en toda la Sierra Ecuatoriana utilizando el algoritmo MaxEnt y considerando los modelos climáticos BCC\_CSM1\_1 (escenarios 2.6 y 8.5) y MOHC-HADGEM2-ES (escenarios 2.6 y 8.5)

para el período de 2050 a 2080. El análisis de distribución potencial reveló que la probabilidad de presencia muy alta de *B. cockerelli* S. es del 0.98%, abarcando un área total de 596.53 ha, y una probabilidad alta del 8.92% en las provincias de Carchi, Imbabura, Pichincha, Cotopaxi, Chimborazo y Azuay. Estas zonas centrales del país se caracterizan por climas fríos y semihúmedos, con elevaciones que oscilan entre 3 000 y 4 000 m s. n. m.

Calderón (2022) en su estudio demuestra que *B. cockerelli* S. tiene una adaptación significativa a diferentes altitudes, aunque no exhibe una adaptabilidad notable a las variaciones climáticas. Esto indica la susceptibilidad de la provincia de Imbabura a la presencia de *B. cockerelli* S, pues determinó que aproximadamente el 0.72% del área total de la provincia cumple con estas condiciones, indicando una alta probabilidad de presencia de la plaga analizada. Esto explica el aumento de las zonas con riesgo medio y alto donde la especie puede establecerse, ya que tiene la capacidad de adaptarse a ciertas altitudes y condiciones en presencia de sus hospederos. Además, el cambio de temperatura aumenta su rango de presencia. Los resultados de este estudio con relación a la expansión de áreas de riesgo sugieren un monitoreo continuo de esta especie y adaptar las estrategias de control de plagas para prevenir y mitigar los posibles impactos en la agricultura y el medio ambiente.

#### **4.2.2.2 Probabilidad de riesgo *F. occidentalis***

La provincia de Imbabura presenta condiciones de temperatura y elevación favorables para el desarrollo de *F. occidentalis*. La especie exhibe un riesgo de presencia que tiene cambios significativos en los periodos de tiempo de 1990-2020 y 2020-2060 bajo los escenarios SSP245 y SSP585 (Figura 16). Las categorías de riesgo "Nula", "Baja" y "Media" presentan una disminución de las superficies en las proyecciones para 2060 bajo ambos escenarios. Mientras que, la categoría "Alta" evidencia un aumento de las zonas con condiciones favorables para la especie. Para 1990, el riesgo de presencia de *F. occidentalis* en la categoría "Alta" representa el 10.21% del área de Imbabura, aumentando a un 14.54% en 2020. Las proyecciones para 2060 indican una tendencia al alza, con un riesgo alto que podría llegar a un 16.30% y un 19.12% del área total de Imbabura bajo los escenarios SSP245 y SSP585, respectivamente.



**Figura 16.** Riesgo de presencia de *F. occidentalis* en el pasado, presente y futuro en función de la temperatura y elevación.

Las superficies con riesgo de presencia de *F. occidentalis* (Tabla 27) entre el pasado (1990) y futuro (2060), experimentan una disminución en las categorías "Nula", "Baja" y "Media". En el escenario SSP245, las reducciones son de 1 651.76, 7 514.16 y 20 057.76 ha para las categorías "Nula", "Baja" y "Media", respectivamente. En el escenario SSP585, las reducciones son de 1 747.83, 8 070.79 y 32 957.71 ha para las categorías "Nula", "Baja" y "Media", respectivamente. En contraste, la categoría "Alta" exhibe un aumento significativo en ambas proyecciones para 2060. Bajo el escenario SSP245, la categoría "Alta" aumenta en 29 225.06 ha, mientras que bajo el escenario SSP585, este aumento es aún más pronunciado, ascendiendo en 42 778.11 ha.

**Tabla 27.** Área en hectáreas de la interacción de *F. occidentalis* en el pasado, presente y futuro con el modelo MPI-ESM1-2-HR

<b>Categoría</b>	<b>1990</b>	<b>2020</b>	<b>2060-SSP245</b>	<b>2060-SSP585</b>
<b>Nula</b>	126 249.99	124 516.72	124 598.23	124 502.16
<b>Baja</b>	110 447.32	103 521.44	102 933.16	102 376.53
<b>Media</b>	194 342.97	182 190.04	174 285.21	161 385.26
<b>Alta</b>	49 000.55	69 813.21	78 225.61	91 778.66

La reducción de las superficies con condiciones desfavorables (riesgo "Nula") para *F. occidentalis* es considerable, disminuyendo en promedio 0.35% del área total de Imbabura bajo ambos escenarios proyectados hasta 2060. En contraste, se registra un incremento promedio de 7.50% en la categoría de riesgo "Alta" para ambos escenarios. La categoría de riesgo "Media" también experimenta un incremento considerable, con un




promedio de 5.52% del área total de Imbabura. Este fenómeno indica el efecto del aumento de temperatura en el rango geográfico de desarrollo de *F. occidentalis*, con áreas que antes se consideraban inadecuadas ahora formando parte del rango de la superficie apta y óptima para su desarrollo y expansión. Estos hallazgos se asemejan con los resultados obtenidos por Sanchez et al. (1998), quienes han documentado la dispersión global de *F. occidentalis* en los últimos 30 años, abarcando una variedad de climas, con las temperaturas extremadamente altas ejerciendo un mayor impacto en la supervivencia. Esta expansión sugiere la adaptabilidad de esta especie a las condiciones ambientales de muchas zonas geográficas.

Lacasa & Martinez (2018), afirman que *F. occidentalis* tiene la capacidad para adaptarse a entornos y cultivos nuevos, lo que la categoriza como una especie cosmopolita y polífaga con una amplia gama de más de 600 especies vegetales como hospedantes. Esta habilidad para adaptarse se fundamenta en su capacidad innata de dispersarse y colonizar, permitiéndole establecerse en lugares inexplorados y aprovechar las oportunidades de crecimiento y reproducción. Por otro lado, los hallazgos de Capdevila et al. (2011), sugieren que *F. occidentalis* podría beneficiarse de las transformaciones climáticas y cambios en la humedad anticipados como consecuencia del calentamiento global. Asimismo, el aumento en la frecuencia y gravedad de fenómenos climáticos extremos como sequías y tormentas, potencialmente facilitarían la dispersión y establecimiento de esta especie en nuevos territorios. Lo anterior justifica el aumento de las superficies con riesgo de presencia alta en Imbabura a lo largo del tiempo bajo los escenarios proyectados a 2060.

#### **4.2.2.3 Probabilidad de distribución de *B. cockerelli* S. y *F. occidentalis***

Las condiciones de temperatura y elevación presentes en Imbabura son propicias para el desarrollo de ambas especies en estudio. *B. cockerelli* S. y *F. occidentalis* comparten superficies aptas para su establecimiento a lo largo de los periodos de tiempo analizados. Como se observa en la Figura 17, la extensión dónde ambas especies pueden estar presentes abarca casi todo Imbabura. Esto se atribuye al rango amplio de los umbrales de temperatura y elevación en la que ambas especies se pueden desarrollar.



**Figura 17.** Riesgo de presencia compartida de *B. cockerelli S.* y *F. occidentalis* en el pasado, presente y futuro en función a la temperatura y elevación.

Los cambios en la extensión del hábitat adecuado para la presencia de *B. cockerelli S.* y *F. occidentalis*, observados a través de los periodos de tiempo proyectados revelan fluctuaciones (Tabla 28). En 1990, las zonas con condiciones aptas para el establecimiento de ambas especies corresponden al 72.78% del área de Imbabura. En 2020 asciende al 73.14% y sin cambios significativos para 2060 bajo ambos escenarios climáticos. Las zonas con riesgo apto para *B. cockerelli S.* en 1990 representan el 7.38% del área de Imbabura, lo que se reduce a un 7.06% en 2020. En el escenario optimista, se prevé una reducción adicional a un 7.04%, mientras que en el escenario pesimista se reduce a un 7.02% para el año 2060.

**Tabla 28.** Área en hectáreas de la interacción de *B. cockerelli S.* y *F. occidentalis* en el pasado, presente y futuro con el modelo MPI-ESM1-2-HR

Interacción	1990	2020	2060-SSP245	2060-SSP585
<i>Ninguna</i>	95 266.43	95 067.71	95 224.32	95 210.26
<i>B. cockerelli S.</i>	35 410.53	33 876.06	33 801.59	33 719.49
<i>B. cockerelli S.</i> y <i>F. occidentalis</i>	349 365.36	351 098.7	351 017.24	351 113.26

Estos cambios reflejan la interacción de las especies en un mismo espacio geográfico y la influencia del cambio climático en su distribución. Los resultados obtenidos tras la aplicación en un caso particular con la temperatura y elevación y los criterios de umbrales

de desarrollo de *B. cockerelli* S. y *F. occidentalis* justifican la validez de la propuesta metodológica.

### **4.3 Estrategias de Manejo Integrado de Plagas**

#### ***4.3.1 Análisis de información relacionada con los cultivos y plagas***

Durante los últimos tres años, los cultivos más destacados fueron el aguacate, con un porcentaje de cultivo del 30.30%, seguido del fréjol con un 39.39%, y la papa con un 43.93%. Además, se observa que el 53.03% de la población en estos predios se dedica al cultivo de otros productos. En el ámbito del espacio el 89.40% de la muestra registran menos de 5 hectáreas cultivadas y en términos económicos, solamente el 27.27% de los encuestados genera más de \$10 000 anuales.

El análisis de problemas comunes en el cultivo reveló que la presencia de plagas y enfermedades afecta al 87.87% de los casos, seguido por la escasez de riego con 60.60%, la baja calidad del suelo con 36.36%, y la variación del clima con 18.18%. Además, en los últimos tres años, *B. cockerelli* S. estuvo presente en el 45.45% de los cultivos y *F. occidentalis* en el 63.63%, mientras que un 19.69% de entrevistados reportaron ambas plagas presentes en sus cultivos durante ese periodo.

Debido a la presencia de especies invasoras en estudio, se observó que el 48.48% de la población informó que estas especies actúan como vectores de otras enfermedades. El 46.96% mencionó que generan estrés en las plantas, mientras que el 80.30% destacó que ocasionan pérdida de rendimiento en las plantas. Además, el 56.06% ha observado daño estético, y principalmente el 87.87% señaló que generan una pérdida económica. En cuanto a las etapas de las plantas más vulnerables de los cultivos, se encontró que el 53.03% de los casos ocurrieron durante la floración, el 45.45% durante el crecimiento vegetativo, y el 43.93% durante el desarrollo de frutos, vainas a partir de flores fecundadas, y la formación de tubérculos.

Dentro del ámbito de control de *B. cockerelli* S. y *F. occidentalis* es notable que solo el 3.03% utilice un control biológico y un manejo integrado de plagas, mientras que un alto porcentaje del 89.39% utiliza un control químico. Este hecho es relevante ya que el 75.75% de los entrevistados indica haber observado resistencia de las plagas hacia estas

formas de control. El 83.33% de los encuestados mencionan no haber recibido ayuda por parte de instituciones estatales y el 92.42% considera que el cambio climático influye en la propagación y afección de las plagas hacia los cultivos.

La validez de la encuesta se confirmó mediante el coeficiente alfa de Cronbach, que se calculó utilizando 20 elementos. El valor obtenido fue de 0.75, lo cual indica que el instrumento es confiable o muy bueno para medir las variables consideradas en la encuesta.

#### ***4.3.2 Identificación de problemas y matriz de Vester***

De acuerdo con la información recolectada mediante la encuesta, los cultivos en general enfrentan una serie de problemas que incluyen el drenaje inadecuado, la escasez de agua, la baja calidad del suelo, la variabilidad climática, la presencia de plagas y enfermedades, la contaminación del suelo por productos químicos aplicados y prácticas agrícolas inadecuadas. En Imbabura, según el INEC (2022) el cultivo del fréjol tiene 3 634 has plantadas y 3 503 has cosechadas, el cultivo del aguacate tiene 1 468 has plantadas y 992 has cosechadas, mientras que el cultivo de papa tiene 406 has plantadas y 350 has cosechadas. Posicionándolos como cultivos de mayor importancia por hectárea plantada y cosechada.


La presencia de *B. cockerelli* S. en cultivos de papa conlleva una serie de problemas específicos que comprometen tanto la salud de las plantas como la calidad y rendimiento de la cosecha. De acuerdo con Calderón (2022), estos problemas incluyen la transmisión de enfermedades, la coloración púrpura y amarillamiento de las hojas, así como la pérdida de follaje y la formación de tubérculos aéreos, lo que conlleva un crecimiento retardado y, como resultado, una pérdida de valor en la cosecha y una disminución en la calidad del producto final. Además, la presencia de esta plaga se traduce en un aumento significativo de los costos de producción, lo que representa un desafío adicional para los agricultores que dependen de este cultivo como fuente de ingresos.

Los problemas que afectan al cultivo de la papa detallados anteriormente fueron codificados como P(#). (Tabla 29).

**Tabla 29.** Problemas identificados en los cultivos de papa.

Problemas generales en los cultivos
<b>P1.</b> Problemas de drenaje
<b>P2.</b> Escasez de agua
<b>P3.</b> La baja calidad de suelo
<b>P4.</b> La variación del clima
<b>P5.</b> Plagas y enfermedades
<b>P6.</b> Contaminación por productos químicos aplicados
<b>P7.</b> Prácticas agrícolas inadecuadas
Problemas específicos causados por <i>B. cockerelli</i> S.
<b>P8.</b> Transmisión de enfermedades
<b>P9.</b> Coloración púrpura y amarillamiento de hojas
<b>P10.</b> Pérdida de follaje
<b>P11.</b> Presencia de tubérculos aéreos
<b>P12.</b> Crecimiento retardado
<b>P13.</b> Pérdida de valor en la cosecha
<b>P14.</b> Disminución de la calidad del producto
<b>P15.</b> Aumento de costos de producción

Se identificaron tres problemas críticos: coloración púrpura y amarillamiento de hojas, pérdida de follaje y presencia de tubérculos aéreos (Figura 18). Además, seis problemas activos, cinco problemas pasivos y un problema indiferente.



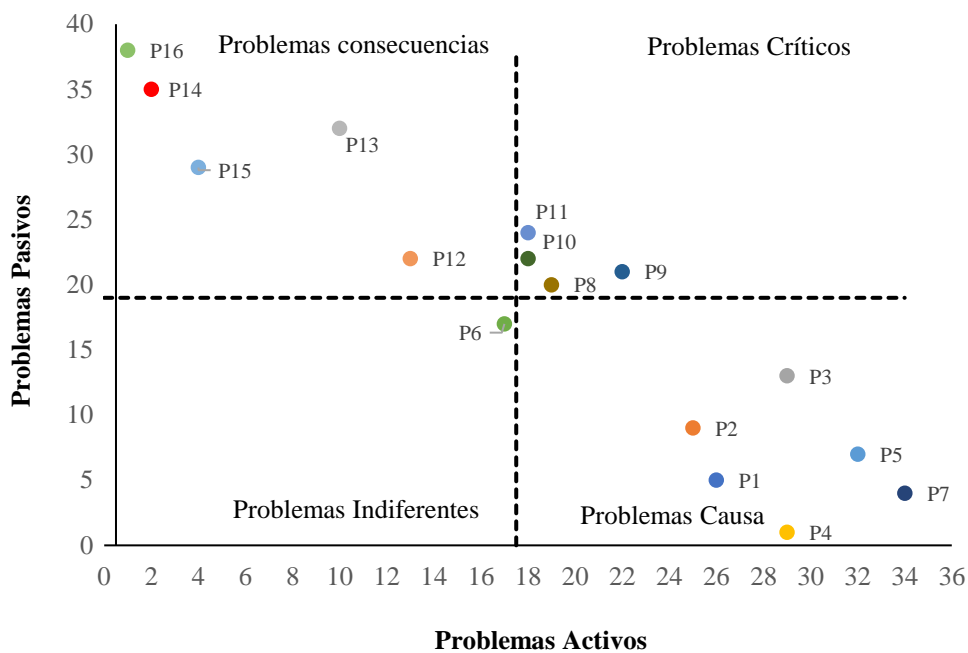
**Figura 18.** Plano cartesiano de activos y pasivos de *B. cockerelli* S.

La especie *F. occidentalis* genera una serie de desafíos adicionales en los cultivos de fréjol y aguacate. Estos incluyen la falta de apertura de las yemas florales, la deformación de brotes y flores, así como de vainas y frutos, la aparición de frutos jóvenes con coloración castaño oscuro, manchas plateadas o bronceadas en las hojas, crecimiento retardado, pérdida de valor en la cosecha, disminución de la calidad nutricional, y un aumento en los costos de producción. Estos problemas específicos (Tabla 30) pueden comprometer seriamente la producción y calidad de los cultivos de fréjol y aguacate. (Koppert, 2019, 2021; Palacios et al., 1994).

**Tabla 30.** Problemas identificados en los cultivos de fréjol y aguacate.

<b>Problemas generales en los cultivos</b>
<b>P1.</b> Problemas de drenaje
<b>P2.</b> Escasez de agua
<b>P3.</b> La baja calidad de suelo
<b>P4.</b> La variación del clima
<b>P5.</b> Plagas y enfermedades
<b>P6.</b> Contaminación por productos químicos aplicados
<b>P7.</b> Prácticas agrícolas inadecuadas
<b>Problemas específicos causados por <i>F. occidentalis</i>.</b>
<b>P8.</b> Falta de apertura de yemas florales
<b>P9.</b> Deformación de estructuras foliares y florales
<b>P10.</b> Deformación de las vainas y frutos
<b>P11.</b> Frutos y vainas con cicatrices castaño oscuro
<b>P12.</b> Manchas plateadas o bronceadas en las hojas
<b>P13.</b> Crecimiento retardado
<b>P14.</b> Pérdida de valor en la cosecha
<b>P15.</b> Disminución de la calidad del producto
<b>P16.</b> Aumento de costos de producción

Se identificaron cuatro problemas críticos: falta de apertura de yemas florales, deformación de estructuras foliares y florales, deformación de vainas, frutos y tubérculos, así como frutos y vainas con cicatrices castaño oscuro (Figura 19). Además, seis problemas activos, cinco problemas pasivos y un problema indiferente.



**Figura 19.** Plano cartesiano de activos y pasivos de *F. occidentalis*

#### 4.3.3 Estrategias de prevención y mitigación de *F. occidentalis* y *B. cockerelli* S. en los cultivos de fréjol, aguacate y papa

Para abordar los problemas causales, consecuencias y especialmente los problemas críticos mencionados en el anterior capítulo, se construyeron programas mediante el modelo Presión – Estado – Respuesta (PER). Estos programas contemplan estrategias viables que contribuyan a los agricultores a reducir las poblaciones de *B. cockerelli* S. y *F. occidentalis* y mitigar sus efectos adversos. Además, se centran en la resiliencia y adaptación al cambio climático.

##### 4.3.3.1 Programa de control biológico en el cultivo de aguacate, fréjol y papa.

Chirinos et al. (2020) analizaron el uso de insecticidas en cultivos de ciertas provincias ecuatorianas, encontrando una dependencia considerable de productos químicos para el control de plagas. Este hallazgo enfatiza la necesidad de promover alternativas de manejo, como el control biológico, para reducir los impactos ambientales y de salud asociados con el uso elevado de insecticidas.

Este programa de control biológico (Tabla 31) se enfoca en controlar las poblaciones de *B. cockerelli* S. y *F. occidentalis* en cultivos de fréjol, aguacate y papa mediante estrategias biológicas que priorizan el cuidado del medio ambiente y la salud de los agricultores. De esta forma, se busca mitigar los efectos adversos como la deformación de estructuras foliares y florales, presencia de tubérculos aéreos, etc., causados por plagas y enfermedades, así como por malas prácticas agrícolas.

### **Objetivo general**

- Crear un registro de controladores biológicos en el cultivo de papa, fréjol y aguacate para reducir de manera efectiva y sostenible la población de *B. cockerelli* S. y *F. occidentalis*.

Para ello, se consideran tres estrategias principales: el uso de hongos entomopatógenos, el uso de depredadores y el uso de parasitoides. Estas estrategias se detallan a continuación.

#### **• Hongos entomopatógenos**

*Beauveria bassiana* se multiplica y se propaga dentro del mismo cultivo, ayuda a controlar la población de insectos-plaga. Permanece en insectos vivos durante el invierno, en sus restos o en el suelo. El entomopatógeno no contamina el medio ambiente, no daña a los humanos ni a otros animales y mantiene la población de la plaga por debajo de los niveles de daño económico (Chiriboga et al., 2015). Es necesario que prevalezcan las condiciones ambientales adecuadas (temperatura y humedad) y la presencia de hospederos. Las formas más comunes de aplicación son: a través de aplicaciones foliares, se utilizan formulaciones líquidas o sólidas con un pH de 6 o 7; uso de trampas con organismos inoculados con hongos, que incluyen feromonas como atrayente; y riego en "drench". Para que *B. bassiana* actúe, debe interactuar con el insecto; de lo contrario, no hará nada (Intagri, 2021).

*Metarhizium anisopliae* provoca muerte de los insectos por su ataque y pueden infectar a otros insectos sanos a través del contacto, y si el ambiente es adecuado para el desarrollo de hongos, la enfermedad puede propagarse rápidamente a toda la población, provocando una epizotia (Ríos et al., 2020). El proceso comienza con la unión de esporas o conidios a la epidermis del insecto, que luego crea tubos germinales y apresorios, fijándolos así a



la epidermis y pasando a través de los tubos germinales o haustorios (hifas penetrantes) del interior del insecto, intervienen mecanismos físicos y químicos. La presión de las hifas, que destruye las regiones escleróticas y membranosas de la cutícula es una medida de control directo, son afectados por el sol. Debe usarse junto con otras medidas y llevar a cabo un programa integral de manejo de plagas o vectores por parte de personal capacitado (Pucheta et al., 2006).

- **Depredadores**

Esta estrategia emerge como la opción más aconsejable debido a su naturaleza no perjudicial para el medio ambiente ni para la salud de los agricultores. Además, no deja residuos tóxicos en los cultivos y contribuye significativamente a la reducción de las plagas. Para el manejo de plagas se ha documentado el uso eficaz de varias opciones, entre las cuales se destaca el depredador *Orius insidiosus* que ha demostrado ser efectivo en el control de las poblaciones de trips (Viera et al., 2020). Adicionalmente, se ha observado que la especie *Neoseiulus californicus* McGregor, conocida como depredadora de larvas de primer y segundo estadio del trips de las flores, puede ser una alternativa efectiva en el control biológico de esta plaga (Sazo et al., 2006).

Los *coccinelidos* (mariquitas) se alimentan de pulgones, moscas blancas, cochinillas de escama y algunas larvas de escarabajos y mariposas, lo que los convierte en depredadores naturales altamente efectivos. Su eficacia radica en su capacidad para controlar las poblaciones de plagas sin causar daño al medio ambiente ni a los cultivos (Mendoza, 2020). *Hippodamia convergens*, también conocida como la mariquita convergente, y *Nabis ferus*, una chinche damisela, son depredadores naturales de *B. cockerelli* S. y según investigaciones han demostrado su efectividad en la regulación de las poblaciones de *B. cockerelli* S. mediante la depredación de sus huevos y ninfas en diferentes etapas de desarrollo. En situaciones de alta densidad poblacional del psílido de la papa, la especie *H. convergens* muestra una notable capacidad reproductiva, lo que aumenta su impacto en el control de la plaga y contribuye a mantenerla por debajo del umbral de daño económico en los cultivos de solanáceas, como la papa, el tomate y el ají (Luna, 2010; Maygualema, 2022; Medina, 2007).

Por otro lado, las *crisopas* son insectos depredadores autóctonos que se alimentan de pulgones, moscas blancas, arañas rojas, trips y huevos de noctúidos (polillas). La liberación de crisopas se ha mostrado como un método eficaz en la lucha biológica contra las plagas, aprovechando su presencia natural en muchos sistemas agrícolas para controlar las poblaciones de plagas sin necesidad de tratamientos químicos (Reascos, 2021). Además, han demostrado que las larvas de *crisopa* son capaces de ingerir hasta 200 ninfas de *B. cockerelli* S. en un solo día y se muestran activas en el consumo de las formas juveniles de *F. occidentalis* (Ail et al., 2012).

- **Parasitoides**

La avispa *Tamarixia triozae* destaca como el principal parasitoide de las ninfas del pulgón saltador, demostrando una presencia significativa y altos niveles de parasitismo en poblaciones nativas en varias regiones de México. Su efectividad la consolida como un elemento fundamental en el control biológico natural de esta especie (Cerón et al., 2014). Por otro lado, *Ceranisus menes* se distingue como un parasitoide que ataca a las ninfas de *F. occidentalis*, al depositar sus huevos dentro de ellas y consumirlas durante su desarrollo larval provocando su muerte en este proceso (Sánchez & Toledo, 2017; Sanchez et al., 1998)

**Tabla 31.** Matriz PER para el programa de control biológico en el cultivo de aguacate, fréjol y papa.

Presión	Estado	Respuesta/Activades	Estrategia
Presencia de plagas y enfermedades	Falta de apertura de yemas florales	<ul style="list-style-type: none"> <li>• Emplear productos comerciales de <i>B. bassiana</i> y <i>M. anisopliae</i>, y preparar una solución, generalmente diluyendo en agua según la dosificación recomendada.</li> </ul>	Hongos entomopatógenos
	Deformación de ucturas foliares y florales	<ul style="list-style-type: none"> <li>• Aplicar la solución utilizando equipos de pulverización adecuados sobre las plantas afectadas de manera uniforme y constante.</li> </ul>	
	Deformación de vainas y frutos	<ul style="list-style-type: none"> <li>• Evitar aplicar los hongos entomopatógenos durante períodos de lluvia o viento fuerte que puedan reducir la efectividad de la aplicación.</li> <li>• Monitorear regularmente la actividad de los hongos entomopatógenos y la población de plagas para evaluar la efectividad del control biológico y realizar ajustes según sea necesario.</li> </ul>	
Prácticas agrícolas inadecuadas	Frutos y vainas con icatrices castaño oscuro	<ul style="list-style-type: none"> <li>• Capturar <i>A. triozae</i> y <i>C. menes</i> para su reproducción y mantenimiento, estableciendo instalaciones adecuadas para su cría y desarrollo.</li> </ul>	Parasitoides
	Coloración púrpura y marillamiento de hojas	<ul style="list-style-type: none"> <li>• Seleccionar el momento idóneo para la liberación de estos parasitoides, prefiriendo horas tempranas por la mañana o al atardecer cuando las condiciones climáticas son más favorables.</li> </ul>	
	Pérdida de follaje	<ul style="list-style-type: none"> <li>• Distribuir de manera uniforme los parasitoides en el cultivo, dando prioridad a áreas con alta concentración de plagas como <i>B. cockerelli</i> S. y <i>F. occidentalis</i> para una disminución efectiva de su población.</li> </ul>	
	Presencia de tubérculos aéreos	<ul style="list-style-type: none"> <li>• Después de la liberación, llevar a cabo un monitoreo regular de la población de parasitoides y la presencia de las plagas objetivo.</li> </ul>	

Presión	Estado	Respuesta/Activades	Estrategia
Presencia de plagas y enfermedades	Falta de apertura de yemas florales	<ul style="list-style-type: none"> <li>Capturar insectos como <i>O. insidiosus</i>, <i>N. californicus</i>, <i>H. convergens</i>, <i>N. ferus</i>, <i>coccinelidos</i> y <i>crisopas</i> para su reproducción y mantenimiento, para lo cual se deberá diseñar criaderos.</li> </ul>	Depredadores
	Deformación de estructuras foliares y florales		
	Deformación de vainas y frutos	<ul style="list-style-type: none"> <li>Elegir un momento adecuado para la liberación, preferiblemente al atardecer o temprano en la mañana cuando las temperaturas son más suaves. Evitar liberar bajo condiciones climáticas extremas o lluviosas que puedan afectar la supervivencia de los depredadores.</li> </ul>	
	Frutos y vainas con atrices castaño oscuro	<ul style="list-style-type: none"> <li>Distribuir los individuos de manera uniforme en el cultivo, especialmente en áreas con alta presencia de <i>B. cockerelli</i> S. y <i>F. occidentalis</i>.</li> </ul>	
	Coloración púrpura y arillamiento de hojas	<ul style="list-style-type: none"> <li>Después de la liberación, monitorear regularmente la población de depredadores y la presencia de plagas. Evaluar la efectividad del control biológico y la salud de las plantas para realizar ajustes si es necesario.</li> </ul>	
Prácticas agrícolas inadecuadas	Pérdida de follaje		
	Presencia de tubérculos aéreos		

#### **4.3.3.2 Programa de control cultural y físico en el cultivo de aguacate, fréjol y papa.**

Las malas prácticas agrícolas generan problemas como la baja calidad del suelo, estrés a las plantas entre otras. De acuerdo con las encuestas realizadas, se determinó que solo el 3.03% de los encuestados llevan a cabo un manejo integrado de plagas empleando prácticas agrícolas sostenibles. Lo anterior evidencia la vulnerabilidad de los cultivos frente a las plagas *B. cockerelli* S. y *F. occidentalis*. Esto enfatiza la necesidad de plantear medidas para el correcto uso del suelo y la implementación de sistemas de cultivos sostenibles frente al cambio climático.

Por tal motivo, el programa de control cultural y físico (Tabla 32) está dirigido a los agricultores con el objetivo de promover un buen uso de los predios de cultivos mediante el empleo de estrategias culturales y físicas. De esta manera, se busca reducir el riesgo de infestación de plagas y garantizar la sostenibilidad de los cultivos en el futuro.

##### **Objetivo general**

- Establecer prácticas de control cultural y físico para gestionar de manera efectiva las poblaciones de *B. cockerelli* S. y *F. occidentalis* en los cultivos de papa, fréjol y aguacate.

Para ello, se consideran estrategias como la diversificación de cultivos, la preparación y remoción adecuada del suelo, el uso de extractos y aceites vegetales, el uso de coberturas de suelo y la implementación de sistemas agroforestales. Estas estrategias se detallan a continuación.

##### **• Cultivos mixtos y diversificación**

El cultivo de una única planta o la repetición continua de la misma especie propicia la proliferación rápida de ciertas plagas especializadas en ese tipo de planta. Sin embargo, al diversificar los cultivos y combinar diferentes especies vegetales, se disminuye significativamente el riesgo de infestación por plagas. Además, implementar márgenes multifuncionales con plantas nativas y cultivos perennes, como árboles frutales o palmeras, es aún más beneficioso (Pérez & Jiménez, 2016).

Una técnica que puede contribuir a disminuir la presencia de malezas es la práctica de la siembra intercalada con especies leguminosas que tienen una mayor capacidad competitiva, o con cereales reconocidos por sus características particulares, como el maíz o el sorgo. Esta estrategia no solo puede ayudar a controlar las malezas, sino que también diversifica la composición del cultivo. Las leguminosas tienen la capacidad única de fijar nitrógeno atmosférico en el suelo a través de la simbiosis con bacterias, reduciendo la necesidad de fertilizantes nitrogenados y mejorando la salud del suelo. (Garcés et al., 2008). El control de insectos plaga comienza con medidas culturales, que incluyen la elección adecuada del sitio y su preparación mediante la eliminación de plantas hospederas de insectos, con el fin de prevenir el crecimiento de poblaciones perjudiciales para el cultivo (Guamán et al., 2003). Se ha observado que el uso de coberturas del suelo, como plástico azul o amarillo, cascarilla o paja de arroz, ejerce un efecto repelente sobre los insectos. Esto se debe a que el color y la reflexión de la luz en el entorno de la planta afectan el comportamiento de insectos adultos (Romero, 2022).

- **Preparación del suelo**

Preparar adecuadamente el suelo es una medida efectiva para combatir las plagas cuyas etapas larvales o pupales se desarrollan en el suelo o en los residuos orgánicos dejados tras la cosecha. El arado influye de dos maneras: puede enterrar los huevos, larvas y pupas a profundidades donde no pueden alcanzar la superficie, o bien llevarlos a la superficie donde son expuestos a la desecación por el sol o son consumidos por aves u otros animales. Sin embargo, en regiones cálidas, cualquier tipo de arado puede tener efectos negativos y causar desequilibrios en el suelo, como la destrucción del humus y la aceleración de la erosión. Por lo tanto, la decisión de realizar este tipo de trabajo debe basarse en la infestación del suelo, las condiciones locales y debe ser tomada con precaución (Pérez & Jiménez, 2016).

- **Extractos y aceites**

*Pongamia pinnata* (L.) pertenece al género de leguminosas monotípicas, produce flavonoides con una potente actividad biológica. Esto ha llevado al desarrollo de un aceite derivado de las semillas de *P. pinnata* que muestra efectos antialimentarios, repelentes y tóxicos contra una amplia variedad de artrópodos, y también es capaz de suprimir la

ovoposición de estos insectos. En el estudio de Stepanycheva et al. (2020) se ha demostrado que este aceite posee propiedades insecticidas y moduladoras contra *F. occidentalis* en sus estados larvario y adulto, logrando reducir la población en más del 90% en ambos estados. Además, se ha observado que reduce significativamente la cantidad de huevos depositados en plantas de fréjol cuando se aplica a una concentración del 1,5%. Posteriormente, a una concentración del 3,0% después de la eclosión, las larvas mueren de manera inmediata.

- **Sistemas agroforestales**

Los sistemas agroforestales en plantaciones de aguacate son más eficientes y rentables que los monocultivos, lo que promueve el desarrollo de tecnologías agroforestales para mejorar la productividad, reducir el riesgo económico y ambiental al diversificar las especies. Además, estos sistemas benefician al medio ambiente al reducir la erosión, capturar carbono, promover la biodiversidad, conservar el agua y mejoran los microclimas (Montiel et al. 2007). De acuerdo con Paredes et al. (2018) menciona que los sistemas agroforestales de árboles con cultivos de ciclo corto y perennes para la provincia de Imbabura que se manejan con asociación, ají (*Capsicum maximun*), alfalfa (*Mendicago sativa*), fréjol (*P. vulgaris*), limón (*Citrus limón*) y las especies forestales que se recomienda son aguacate (*P. americana*), mango (*Mangifera sp.*), naranja (*Citrus sp.*) y mandarina (*Citrus nobilis*). En cuanto al diseño de plantación se recomienda un marco real con un distanciamiento de 5 x 5, 4 x 5 metros, 3,7 x 4,5 metros y se recomienda plantar entre 400, 500 y máximo 600 árboles por hectárea.

**Tabla 32.** Matriz PER para el programa de control cultural y físico en el cultivo de aguacate, fréjol y papa.

Presión	Estado	Respuesta/Activades	Estrategia
Prácticas agrícolas inadecuadas	Manchas amarillas, plateadas o bronceadas en las hojas	<ul style="list-style-type: none"> <li>Plantar cereales y leguminosas entre las filas de los cultivos principales para diversificar el sistema agrícola y mejorar la salud del suelo.</li> <li>Monitorear regularmente la presencia de insectos beneficiosos como abejas y avispas parasitoides, promoviendo su actividad en el cultivo.</li> <li>Observar la competencia entre las leguminosas y las malezas, ajustando la densidad de siembra para maximizar la supresión de malezas y minimizar la competencia con los cultivos principales.</li> </ul>	Cultivos mixtos y diversificación
	Coloración púrpura y amarillamiento de hojas	<ul style="list-style-type: none"> <li>Evaluar los beneficios de la diversificación de cultivos con varias leguminosas en términos de reducción de plagas, control de malezas y mejora en la calidad del suelo.</li> </ul>	
La baja calidad de suelo	Crecimiento retardado de las plantas	<ul style="list-style-type: none"> <li>Realizar un análisis completo del suelo para conocer su pH, nutrientes disponibles y textura.</li> </ul>	Preparación del suelo
Plagas y enfermedades	Pérdida de valor en la cosecha	<ul style="list-style-type: none"> <li>Realizar una limpieza del suelo eliminando vegetación no deseada.</li> <li>Labrar el suelo superficialmente para mejorar la aireación y aplicar enmiendas según necesidades detectadas en el análisis del suelo.</li> </ul>	
Variación del clima	Disminución de la calidad del producto	<ul style="list-style-type: none"> <li>Adquirir el aceite de <i>P. pinnata</i> y diluir en agua, siguiendo las indicaciones del fabricante.</li> </ul>	
	Aumento de costos de producción	<ul style="list-style-type: none"> <li>Aplicar la solución preparada sobre la planta, se lo puede realizar vía foliar, en el suelo o a través de un sistema de riego por goteo.</li> <li>Utilizar una dosis de 1-2 ml por litro de agua para la pulverización foliar y 2 L/ha cada 2-3 semanas para el riego.</li> <li>Evitar aplicar el insecticida natural en horas de máxima insolación y tener en cuenta que no tiene plazo de seguridad, por lo que puede usarse poco tiempo antes de la cosecha.</li> </ul>	Extractos y aceites



Presión	Estado	Respuesta/Activades	Estrategia
Prácticas agrícolas inadecuadas	Manchas amarillas, plateadas o bronceadas en las hojas	<ul style="list-style-type: none"> <li>Preparar mulch orgánico como cascarilla de arroz, paja u hojarrasca.</li> <li>Revisar el mulch que esté limpio y libre de semillas de malezas u otros contaminantes.</li> <li>Aplicar una capa uniforme alrededor de los cultivos afectados por trips.</li> <li>Monitorear regularmente y reemplazar el mulch para mantener una barrera efectiva contra los trips.</li> </ul>	Uso de coberturas de suelo
	Coloración púrpura y amarillamiento de hojas	<ul style="list-style-type: none"> <li>Definir objetivos y analizar el sitio para comprender las condiciones del lugar donde implementará el sistema agroforestal.</li> <li>Elegir especies compatibles y beneficiosas que se complementen entre sí y sean adecuadas para el sitio, considerando su capacidad para mejorar la fertilidad del suelo, atraer polinizadores y proporcionar otros servicios ecosistémicos.</li> </ul>	
La baja calidad de suelo	Crecimiento retardado de las plantas	<ul style="list-style-type: none"> <li>Preparar el suelo con materia orgánica y corrección de pH para favorecer el crecimiento de las plantas.</li> <li>Plantar siguiendo el diseño planificado y aplicar un manejo integrado que incluya prácticas sostenibles de control de plagas, riego eficiente y cuidado de la biodiversidad.</li> <li>Evaluar regularmente el rendimiento del sistema y realizar ajustes según sea necesario para mejorar su funcionamiento a lo largo del tiempo, teniendo en cuenta el crecimiento de las plantas, la presencia de plagas y enfermedades, y otros indicadores clave.</li> </ul>	Sistemas agroforestales
Plagas y enfermedades	Pérdida de valor en la cosecha		
Variación del clima	Disminución de la calidad del producto		
	Aumento de costos de producción		

#### **4.3.3.3 Programa de capacitación y sensibilización**

Los programas de educación ambiental son fundamentales para promover alternativas sostenibles en el control de plagas y enfermedades, destacando la importancia del manejo integrado que combina tácticas biológicas, culturales y químicas para reducir impactos ambientales y económicos. Sin embargo, el desconocimiento de estas prácticas representa un desafío significativo para la agricultura y la conservación ambiental (Tokuhama & Bramwell, 2010). A esto se suma que un 83% de los encuestados afirma no haber recibido ayuda por parte de instituciones estatales de la provincia en áreas como charlas técnicas, insumos agrícolas, entre otros.

Por ende, este programa de capacitación y sensibilización (Tabla 33) se enfoca en promover estrategias de control biológico, cultural y físico, mediante alianzas con instituciones educativas, para llevar a cabo programas de educación ambiental que fomenten la diversidad de cultivos y la salud de los sistemas agrícolas.

#### **Objetivo general**

- Realizar talleres y charlas informativas dirigidas a agricultores y técnicos agrícolas sobre el manejo integrado de plagas, con énfasis en el control biológico y cultural de *B. cockerelli* S. y *F. occidentalis*.

**Tabla 33.** Matriz PER para el programa de capacitación y sensibilización

Presión	Estado	Respuesta/Activades	Estrategia
Malas prácticas agrícolas	Desconocimiento de alternativas sostenibles para el control de plagas	<ul style="list-style-type: none"> <li>• Promocionar un programa de vinculación en la Universidad Técnica del Norte sobre criaderos de enemigos naturales que incluya una variedad de actividades que abarquen desde la formación y capacitación de estudiantes y profesionales en técnicas de identificación y manejo de enemigos naturales, hasta la investigación y desarrollo de métodos efectivos de cría. Además, contemplar la instalación de criaderos piloto y la asistencia técnica directa a agricultores locales para la implementación de estos criaderos en sus fincas. El programa deberá incluir un monitoreo continuo del impacto de la liberación de enemigos naturales al reducir la plaga.</li> <li>• Colaborar con instituciones como la Universidad Técnica del Norte mediante programas de vinculación sobre criaderos de enemigos naturales y las Asociaciones de Productores Agrícolas para organizar talleres y charlas informativas.</li> <li>• Diseñar el contenido de los talleres y charlas con énfasis en el manejo integrado de plagas, especialmente el control biológico y cultural de <i>B. cockerelli</i> S. y <i>F. occidentalis</i>.</li> <li>• Invitar a expertos en manejo de plagas y especialistas en control biológico y cultural para impartir los talleres y charlas.</li> </ul>	Educación ambiental/participación ciudadana
Presencia de plagas y enfermedades			
Abandono de instituciones estatales			

- 
- Promover la participación de agricultores y técnicos agrícolas en los eventos informativos para compartir conocimientos y mejores prácticas.
  - Recolectar retroalimentación y evaluar la efectividad de los talleres y charlas para realizar ajustes y mejoras en futuras actividades de educación agrícola.
  - Utilizar medios de comunicación para promocionar los eventos y difundir información sobre manejo de plagas y prácticas agrícolas sostenibles.
  - Establecer indicadores de éxito y realizar seguimiento para evaluar el impacto de las actividades y ajustar estrategias según sea necesario.
-

## CAPÍTULO V

### CONCLUSIONES Y RECOMENDACIONES

#### *5.1 Conclusiones*

El ciclo de desarrollo de las especies *B. cockerelli* S. y *F. occidentalis* son determinadas por la elevación y temperatura. Los umbrales de desarrollo y los rangos óptimos obtenidos a través de la caracterización indican que *B. cockerelli* S. presenta un umbral de desarrollo a partir de los 8 °C hasta los 32 °C, con condiciones óptimas en el rango de 21 a 27 °C, y muestra una preferencia por elevaciones que oscilan entre los 1 000 y 3 500 m s. n. m. Mientras que, *F. occidentalis* exhibe un umbral de desarrollo a partir de los 10 °C hasta los 35 °C, con condiciones óptimas alrededor de los 19-28 °C, y también muestra una preferencia por elevaciones con un rango de 1 000 a 3 300 m s. n. m. Por otra parte, la temperatura de la base de datos de TerraClimate presenta una buena concordancia con los datos de las estaciones meteorológicas evaluadas.

El modelo de proyección desarrollado bajo el enfoque de aprendizaje automático supervisado muestra que la perspectiva que mejor se adaptó para clasificar umbrales y rangos óptimos en función de la elevación y temperatura son los Árboles de Decisión “Medium Tree”. El modelo obtuvo una precisión del 99.97%, 0.99 en la curva AUC y una tasa de error inferior a 0.23%, como métricas de validación. Además, es el de mayor eficiencia con 30.16 segundos de entrenamiento. Esto destaca la eficacia del modelo y del clasificador tipo “Medium Tree” en la predicción del riesgo de presencia de especies de plagas agrícolas, basándose en las variables determinantes para su ciclo de vida.

La superficie con riesgo de presencia actual (2020) y futura (2060) para *B. cockerelli* S. en Imbabura muestra cambios en distintas categorías. En 2020, las áreas con riesgo de presencia se distribuyen de la siguiente manera: 94 615.88 ha en la categoría "Nula", 277 324.8 ha en la categoría "Baja", 95 068.14 ha en la categoría "Media" y 13 032.22 ha en la categoría "Alta". Para el año 2060, bajo el escenario SSP245, las superficies son: 94 615.37 ha en la categoría "Nula", 273 730.15 ha en la categoría "Baja", 95 342.63 ha en la categoría "Media" y 16 351.50 ha en la categoría "Alta". En el escenario SSP585 para 2060, las áreas de riesgo se distribuyen en: 94 615.41 ha en la categoría "Nula", 262 275.92 ha en la categoría "Baja", 96 182.51 ha en la categoría "Media" y 26 965.88 ha en la categoría "Alta".

La superficie con riesgo de presencia en 2020 y las proyecciones para 2060 de *F. occidentalis* en Imbabura muestran cambios significativos en varias categorías. En 2020, las áreas con riesgo se distribuyen así: 124 516.72 ha en la categoría "Nula", 103 521.44 ha en la categoría "Baja", 182 190.04 ha en la categoría "Media" y 69 813.21 ha en la categoría "Alta". Para el año 2060, bajo el escenario SSP245, las áreas correspondientes son: 124 598.23 ha en la categoría "Nula", 102 933.16 ha en la categoría "Baja", 174 285.21 ha en la categoría "Media" y 78 225.61 ha en la categoría "Alta". En el escenario SSP585 para 2060, la distribución de las superficies es: 124 502.16 ha en la categoría "Nula", 102 376.53 ha en la categoría "Baja", 161 385.26 ha en la categoría "Media" y 91 778.66 ha en la categoría "Alta".

Las estrategias propuestas en este estudio para abordar los desafíos asociados con la presencia de *B. cockerelli* S. y *F. occidentalis* en los cultivos de fréjol, aguacate y papa se centran en enfoques de control biológico y cultural. Destacan, entre estas estrategias, el empleo de hongos entomopatógenos como *B. bassiana* y *M. anisopliae*. Otro aspecto relevante es la utilización de organismos beneficiosos como *O. insidiosus*, *N. californicus*, *H. convergens*, *N. ferus*, *A. triozae* y *C. menes* en estos cultivos como enemigos naturales de las plagas. Además, se sugiere la integración de insecticidas naturales, como el aceite de *P. pinnata*. También se propone la diversificación de cultivos, la implementación de sistemas agroforestales y un programa de educación ambiental como medidas complementarias para fortalecer la gestión integral de plagas en estos sistemas agrícolas.

## **5.2 Recomendaciones**

Para mejorar el modelo de proyección, se recomienda realizar experimentos en laboratorio y en campo para determinar los umbrales mínimos y máximos, así como los rangos óptimos de diferentes variables que influyen en el ciclo de vida de ambas especies. De este modo, se podrán incorporar variables meteorológicas importantes como humedad relativa, heliofanía, radiación solar y velocidad del viento. Esto permitirá una predicción más precisa del riesgo de presencia a través del tiempo.

Para futuras modelizaciones de *B. cockerelli* S. y *F. occidentalis*, es necesario realizar un análisis diferenciado del desarrollo y comportamiento en cada etapa del ciclo de vida de estas especies. Cada fase tiene sus propios umbrales y requiere condiciones ambientales específicas, por lo que es fundamental incluir la fenología en función a estas

variables ambientales. Este enfoque aumentará la confiabilidad de la predicción y contribuirá significativamente a plantear estrategias de prevención y manejo integrado más efectivas para las especies, según las diferentes etapas de los insectos.

Para predecir el riesgo de presencia de otras especies de importancia económica o ecológica considerando más variables. Se sugiere la posibilidad de ajustar las consideraciones para establecer las clases de riesgo en el modelo. Es decir, en lugar de centrarse exclusivamente en criterios de umbrales y rangos óptimos de desarrollo, se podría considerar la alternativa de establecer un rango de probabilidad de presencia determinada con anterioridad a partir de otras metodologías. No obstante, este enfoque puede implicar una menor confiabilidad en la predicción del riesgo.

Se sugiere replicar el modelo empleando algoritmos de redes neuronales, dada su capacidad para generar métricas sobresalientes y alcanzar una eficiencia cercana al 100% en la clasificación de datos desordenados. No obstante, es importante destacar que estos modelos requieren un costo computacional más elevado en comparación con otras técnicas de *machine learning*.

Se recomienda implementar las estrategias propuestas en este estudio con el objetivo de reducir los efectos adversos ocasionados por *F. occidentalis* y *B. cockerelli* S. De esta manera, se evitarán pérdidas económicas en los campos agrícolas, al mismo tiempo que se preservará el entorno, se fortalecerá la sustentabilidad y se fomentará la adaptación al cambio climático.

## REFERENCIAS

- Abatzoglou, J. T., Dobrowski, S. Z., Parks, S. A., & Hegewisch, K. C. (2018). TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. *Scientific Data* 2018 5:1, 5(1), 1–12. <https://doi.org/10.1038/sdata.2017.191>
- Abdi, O. (2019). Climate-Triggered Insect Defoliators and Forest Fires Using Multitemporal Landsat and TerraClimate Data in NE Iran: An Application of GEOBIA TreeNet and Panel Data Analysis. *Sensors* 2019, Vol. 19, Page 3965, 19(18), 3965. <https://doi.org/10.3390/S19183965>
- Abdullah, N. (2008). Life history of the Potato Psyllid *Bactericera cockerelli* (Homoptera: Psyllidae) in Controlled Environment agriculture in Arizona. *African Journal of Agricultural Research*, 3(1), 60–067. <http://www.academicjournals.org/AJAR>
- Agencia de Cooperación Internacional del Japón [JICA]. (2010). Guía del Manejo Integrado de Plagas (MIP) para técnicos y productores. In *Corporación Biológica*. [https://www.jica.go.jp/project/panama/0603268/materials/pdf/04\\_manual/manual\\_04.pdf](https://www.jica.go.jp/project/panama/0603268/materials/pdf/04_manual/manual_04.pdf)
- Agencia de Regulación y Control Fito y Zoosanitario [AGROCALIDAD]. (2022). *Reporte General de Monitoreo de Vigilancia*.
- Aguado-Rodríguez, G. J., Quevedo-Nolasco, A., Castro-Popoca, M., Arteaga-Ramírez, R., Vázquez-Peña, M. A., & Zamora-Morales, B. P. (2016). Predicción de variables meteorológicas por medio de modelos ARIMA. *Agrociencia*, 50(1), 1–13. <https://www.redalyc.org/pdf/302/30243765001.pdf>
- Aguilar, E. (2018). *Determinación del estado sanitario de las plantas, suelo e instalaciones y elección de los métodos de control* (IC Editorial, Ed.; 2nd ed.). <https://elibro.net/es/lc/utnorte/titulos/59178>
- Aguilar-Barojas, S. (2005). Fórmulas para el cálculo de la muestra en investigaciones de salud. *Salud En Tabasco*, 11(1–2), 333–338. <https://www.redalyc.org/pdf/487/48711206.pdf>
- Aguirre, H., & Gallegos, S. (2019). Desarrollo y análisis de sistemas de estimación y detección de objetivos de radar mediante algoritmos de machine y deep learning [Universidad de las Fuerzas Armadas ESPE]. In *Repositorio.Espe.Edu.Ec*. <http://repositorio.espe.edu.ec/bitstream/21000/15813/1/T-ESPE-040692.pdf>
- Ail, C., Cerna, H., Landeros, G., Aguirre, A., Flores, M., Mohammad, B., & Ochoa, Y. (2012). Respuesta funcional de diferentes instares larvales de *Chrysoperla carnea*



- (Stephens) (Neuroptera: Chrysopidae) sobre ninfas de *Bactericera cockerelli* (Sulc) (Homoptera: Psyllidae). *FCA UNCUYO*, 44(2), 279–288.
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). *Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56*.
- Altieri, M., & Nicholls, C. (1994). *Biodiversity and Pest Management in Agroecosystems* (S. a. Icaria editorial, Ed.).
- Álvarez, R. (1995). *Estadística multivariante y no paramétrica con SPSS* (Díaz, Ed.; 3rd ed.).
- Araghi, A., Martinez, C. J., & Adamowski, J. F. (2023). Evaluation of TerraClimate gridded data across diverse climates in Iran. *Earth Science Informatics*, 16(2), 1347–1358. <https://doi.org/10.1007/s12145-023-00967-z>
- Araúz, J. (2023). *Análisis de cambio climático en la disponibilidad de agua en la subcuenca del Río Chiriquí*.
- Asamblea Nacional de la República del Ecuador. (2008). *Constitución de la República del Ecuador*. Registro Oficial N° 449.
- Attri, I., Awasthi, L. K., & Sharma, T. P. (2023). Machine learning in agriculture: a review of crop management applications. *Multimedia Tools and Applications*, 1–41. <https://doi.org/10.1007/S11042-023-16105-2/TABLES/5>
- Bajaj, Y., & Sopory, S. (1986). Biotechnology of Potato Improvement. *Biotechnology in Agriculture and Forestry*, 2. [https://doi.org/10.1007/978-3-642-61625-9\\_24](https://doi.org/10.1007/978-3-642-61625-9_24)
- Banco Central del Ecuador. (2022). *Información Económica - Banco Central del Ecuador*. <https://www.bce.fin.ec/informacioneconomica>
- Barros, J., & Troncoso, A. (2010). Atlas climatológico del Ecuador [Tesis de pregrado, Escuela Politécnica Nacional]. In *Repositorio Digital Institucional de la Escuela Politécnica Nacional*. <https://bibdigital.epn.edu.ec/bitstream/15000/1720/1/CD-2755.pdf>
- Benavides Pinchao, N. Eliana. (2021). *Evaluación de la eficiencia de plaguicidas para el control de Trips (Frankliniella occidentalis) en el cultivo de rosas (Rosa sp) en el cantón Bolívar* [Universidad Politécnica Estatal del Carchi]. <http://181.198.77.137:8080/jspui/handle/123456789/1015>
- Benchekroun, M., Chevallier, B., Zalc, V., Istrate, D., Lenne, D., & Vera, N. (2023). The Impact of Missing Data on Heart Rate Variability Features: A Comparative Study of Interpolation Methods for Ambulatory Health Monitoring. *IRBM*, 44(4), 100776. <https://doi.org/10.1016/J.IRBM.2023.100776>

- Berlanga, V., Rubio, M., & Vila, R. (2013). Cómo aplicar árboles de decisión en SPSS. *Reire*, 6(1), 65–79.
- Bisquerra, R. (1987). La Prueba Levene para la Homogeneidad de Varianzas en el BMDP. *Investigación Educativa*, 5(9), 79–85.
- Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2016). Time Series Analysis, Forecasting and Control. In G. Reinsel & G. Ljung (Eds.), *Revista Brasileira de Linguística Aplicada* (Fifth edit, Vol. 5, Issue 1). <https://revistas.ufrj.br/index.php/rce/article/download/1659/1508%0Ahttp://hipatiapress.com/hp/journals/index.php/qre/article/view/1348%5Cnhttp://www.tandfonline.com/doi/abs/10.1080/09500799708666915%5Cnhttps://mckinseysociety.com/downloads/reports/Educa>
- Brown, M. B., & Forsythe, A. B. (1974). Robust tests for the equality of variances. *Journal of the American Statistical Association*, 69(346), 364–367. <https://doi.org/10.1080/01621459.1974.10482955>
- Bryan, D., & Smith, R. (1956). *The Frankliniella occidentalis (Pergande) complex in California (Thysanoptera, Thripidae)* (Berkeley, Ed.; Primera). University of California Press. <https://search.worldcat.org/es/title/frankliniella-occidentalis-pergande-complex-in-california-thysanoptera-thripidae/oclc/845674>
- Burbano, B., & Flores, A. (2022). *Evaluación del cambio climático en la producción del café (Coffea arabica L.) al 2040 en Cotacachi – Ecuador* (Issue 8.5.2017) [Tesis de pregrado, Universidad Técnica del Norte]. <http://repositorio.utn.edu.ec/handle/123456789/13277>
- Calderón, N. (2022). *Análisis de factores ambientales determinantes en la distribución de Bactericera Cockerelli (Sulc.) en cultivos de Solanum Tuberosum en Imbabura* [Universidad Técnica del Norte]. <http://repositorio.utn.edu.ec/handle/123456789/13308>
- Candia, R., & Caiozzi, G. (2005). Intervalos de confianza. *Revista Médica Chile*, 133, 1111–1115.
- Cao, Y., DeWalt, R. E., Robinson, J. L., Tweddale, T., Hinz, L., & Pessino, M. (2013). Using Maxent to model the historic distributions of stonefly species in Illinois streams: The effects of regularization and threshold selections. *Ecological Modelling*, 259, 30–39. <https://doi.org/10.1016/J.ECOLMODEL.2013.03.012>
- Capdevila, L., Bernardo, Z., & Suárez, V. (2011). *Cambio climático y especies exóticas invasoras en España*.

- Capinera, J. (2021). *Handbook of Vegetable Pests* (Academic Press). Department of Entomology & Nematology.
- Cardenas, E., & Corredor, D. (1989). Biología del Trips *Frankliniella occidentalis* (Pegande) (Thysanoptera: Thripidae) sobre crisantemo *Chrysanthemum moridolium* L. Bajo Condiciones de Laboratorio. *Agronomía Colombiana*, 7, 71–77.
- Cardona, C., & Mesa, N. (2015). *Entomología económica y manejo de plagas* (Editorial Universidad Nacional de Colombia, Ed.). Editorial Universidad Nacional de Colombia. <https://doi.org/10.0/CSS/ALL.MIN.D74D1A5D029B.CSS>
- Castillo, C. (2019). Punta morada de papa en Ecuador, actualidad. *En Libro de Memorias: VIII Congreso Ecuatoriano de La Papa: Artículos Del Evento (Pp. 21-22)*.
- Castillo, C., Paltrinieri, S., Bustamante, J. B., & Bertaccini, A. (2018). Detection and molecular characterization of a 16SrI-F phytoplasma in potato showing purple top disease in Ecuador. *Australasian Plant Pathology*, 47(3), 311–315. <https://doi.org/10.1007/s13313-018-0557-9>
- Castresana, J., Gagliano, E., Puhl, L., Bado, S., Vianna, L., & Castresana, M. (2008). Atracción del Trips *Frankliniella Occidentalis* (Pergande) (Thysanoptera: Thripidae) con trampas de luz en un cultivo de *Gerbera Jamesonii* (G.) (HRIPIDAE) CON TRAMPAS DE LUZ EN UN CULTIVO DE GERBERA JAMESONII (G.). *Idesia (Arica)*, 26(3), 51–56. <https://doi.org/10.4067/S0718-34292008000300006>
- Castro, J., Castillo, G., & Salazar, J. (2016). Influencia de la temperatura sobre el ciclo de vida de la especie necrófaga *Comptosmyiops arequipensis* Mello, 1968 (Díptera: Calliphoridae). *Revista de La Asociación Colombiana de Ciencias Biológicas*, 28, 105–116.
- Centro Panamericano de Ingeniería Sanitaria y Ciencias del Ambiente [CEPIS]. (2005). *Conceptos básicos de la meteorología de la contaminación del aire*.
- Cerón, C., Flores, R., Rodríguez, E., & Torres, A. (2014). Fecundidad y alimentación de *Tamarixia triozae* (Hymenoptera: Eulophidae) sobre el psílido de la papa *Bactericera cockerelli*. *Revista Mexicana de Ciencias Agrícolas*, 5(5), 893–899.
- Cevallos, D., Santana, J., & Chirinos, D. T. (2021). Predators and the management of some agricultural pests in Ecuador. *Manglar*, 18(1), 51–59. <https://doi.org/10.17268/manglar.2021.007>
- Chango, S. (2022). *Diagnóstico del manejo sustentable de plagas agrícolas por los agricultores de la comunidad Manguihua Cochapamba Katitawa de la parroquia Salasaka*. Universidad Técnica de Ambato.

- Childs, R. E., Chuah, D. G. S., Lee, S. L., & Tan, K. C. (1984). Analysis of solar radiation data using cubic splines. *Solar Energy*, 32(5), 643–653. [https://doi.org/10.1016/0038-092X\(84\)90141-5](https://doi.org/10.1016/0038-092X(84)90141-5)
- Chiriboga, H., Gómez, G., & Garcés, K. (2015). *Control de Trips (Frankliniella occidentalis Pergande) en el cultivo de fréjol arbustivo (Phaseolus vulgaris L.) San Vicente de Pusir-Carchi, 2000*.
- Chirinos, D. T., Castro, R., Cun, J., Castro, J., Bravo, S. P., Solis, L., & Geraud-Pouey, F. (2020). Insecticides and agricultural pest control: The magnitude of its use in crops in some provinces of Ecuador. *Ciencia Tecnología Agropecuaria*, 21(1). [https://doi.org/10.21930/RCTA.VOL21\\_NUM1\\_ART:1276](https://doi.org/10.21930/RCTA.VOL21_NUM1_ART:1276)
- CMNUCC. (1992). *Convención Marco de las Naciones Unidas sobre el Cambio Climático (FCCC/INFOR)*.
- Corrales, R., & Lobato, Á. (2023). *Análisis de la distribución biogeográfica de melíferas (Himenóptera: Apidae) en el cantón Cotacachi, Imbabura*. Universidad Técnica del Norte.
- Cronbach, L. J. (1951). Coefficient Alpha and the internal structure of tests. *Psychometrika*, 16(3), 297–334.
- Davis, J., & Goadrich, M. (2016). *The Relationship Between Precision-Recall and ROC Curves*. <https://doi.org/https://doi.org/10.1145/1143844.1143874>
- Dillon, M., Frazier, M., & Dudley, R. (2006). Into thin air: Physiology and evolution of alpine insects. *Integrative and Comparative Biology*, 46(1), 49–61. <https://doi.org/10.1093/ICB/ICJ007>
- Duan, S. B., & Li, Z. L. (2016). Spatial Downscaling of MODIS Land Surface Temperatures Using Geographically Weighted Regression: Case Study in Northern China. *IEEE Transactions on Geoscience and Remote Sensing*, 54(11), 6458–6469. <https://doi.org/10.1109/TGRS.2016.2585198>
- Dwivedi, D., Kapur, P. N., & Kapur, N. N. (2023). Machine learning time series models for tea pest looper infestation in Assam, India. *Convergence of Cloud Computing, AI, and Agricultural Science*, 280–289. <https://doi.org/10.4018/979-8-3693-0200-2.CH014>
- Ebratt R., E. E., Acosta A., R., Martínez B., O. Y., Guerrero G., O., & Turizo A., W. (2013). Tomato spotted wilt virus (TSWV), malezas y vectores de trips en el tomate (*Solanum lycopersicum L.*) en la región andina de Cundinamarca (Colombia). *Agronomía Colombiana*, 31(1), 58–67.
- Escoto, A., Sánchez, L., & Gachuz, S. (2017). Trayectorias Socioeconómicas Compartidas ( SSP ): nuevas maneras de comprender el cambio climático y social. *Estudios*

- Demográficos y Urbanos*, 32(96), 669–693.  
<https://doi.org/http://dx.doi.org/10.24201/edu.v32i3.1684>
- ESRI. (2022). *Cómo funciona Regresión ponderada geográficamente (GWR)*. Environmental Systems Research Institute [ESRI]. [https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-statistics/how-geographicallyweightedregression-works.htm#:~:text=Regresi%C3%B3n%20ponderada%20geogr%C3%A1ficamente%20\(GWR\)%20es,todas%20las%20entidades%20del%20dataset](https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-statistics/how-geographicallyweightedregression-works.htm#:~:text=Regresi%C3%B3n%20ponderada%20geogr%C3%A1ficamente%20(GWR)%20es,todas%20las%20entidades%20del%20dataset).
- ESRI. (2023). *Usar la validación cruzada para evaluar los resultados de interpolación*. Usar La Validación Cruzada Para Evaluar Los Resultados de Interpolación. <https://pro.arcgis.com/es/pro-app/latest/help/analysis/geostatistical-analyst/performing-cross-validation-and-validation.htm>
- Falconez, J. (2020). *Ciclo biológico de (Bactericera cockerelli) bajo condiciones controladas en tres localidades Salache, Cotopaxi 2020*. Universidad Técnica de Cotopaxi.
- Fand, B. B., Tonnang, H. E. Z., Kumar, M., Kamble, A. L., & Bal, S. K. (2014). A temperature-based phenology model for predicting development, survival and population growth potential of the mealybug, *Phenacoccus solenopsis* Tinsley (Hemiptera: Pseudococcidae). *Crop Protection*, 55, 98–108.  
<https://doi.org/10.1016/J.CROPRO.2013.10.020>
- Fand, B., Tonnang, H., Kumar, M., Bal, S. K., Singh, N. P., Rao, D. V. K. N., Kamble, A. L., Nangare, D. D., & Minhas, P. S. (2014). Predicting the impact of climate change on regional and seasonal abundance of the mealybug *Phenacoccus solenopsis* Tinsley (Hemiptera: Pseudococcidae) using temperature-driven phenology model linked to GIS. *Ecological Modelling*, 288, 62–78.  
<https://doi.org/10.1016/J.ECOLMODEL.2014.05.018>
- Fernández, G., & Johnston, M. (2006). Crecimiento y Temperatura. *Fisiología Vegetal*, 20(20), 1–28.
- Fernández, S. (2022). *Métodos de regresión y clasificación basados en árboles* [Tesis de pregrado, Universidad de Valladolid]. <https://uvadoc.uva.es/bitstream/handle/10324/53822/TFG-I-2181.pdf?sequence=1>
- Filgueiras, R., Venancio, L. P., Aleman, C. C., & Cunha, F. F. da. (2022). Comparison and calibration of terraclimate climatological variables over the Brazilian territory. *Journal of South American Earth Sciences*, 117(May), 103882.  
<https://doi.org/10.1016/j.jsames.2022.103882>

- Furtado, P. (2021). Prediction of Online Shoppers' Purchasing Intention Using Support Vector Machines(SVM) [Tesis de Maestría, University of Huelva & International University of Andalusia]. In *University of Huelva & International University of Andalusia*.  
[https://www.uhu.es/mecofin/documents/docencia/tfm/20202021/MECOFIN\\_20202021\\_tfm\\_20202021-FRP\\_POOS.pdf](https://www.uhu.es/mecofin/documents/docencia/tfm/20202021/MECOFIN_20202021_tfm_20202021-FRP_POOS.pdf)
- Gamarra, H. (2019). Modelo fenológico de *Bactericera cockerelli* para evaluar el riesgo de su propagación utilizando la herramienta "Insect life cycle modelling"(ILCYM). *Centro Internacional de La Papa-CIP y Programa de Investigación Del CGIAR En Raíces Tubérculos y Bananas*.  
<https://cgspace.cgiar.org/server/api/core/bitstreams/ce18ba72-367a-4a1b-b14b-7898faafb34a/content>
- Garcés, S., Lomas, L., & Peralta, E. (2008). *Manejo de Trips en el cultivo de fréjol*. INIAP - Estación Experimental Santa Catalina.
- García, C., & Durán-Ballén, S. (2023). Climatic Variability in the hydrographic basin of the Chalpi Grande river in Napo-Ecuador. *Enfoque UTE*, 14(1).  
<https://doi.org/https://doi.org/10.29019/enfoqueute.872>
- Gaum, W. G., Giliomee, J. H., & Pringle, K. L. (1994). Life history and life tables of western flower thrips, *Frankliniella occidentalis* (Thysanoptera: Thripidae), on English cucumbers. *Bulletin of Entomological Research*, 84(2), 219–224.  
<https://doi.org/10.1017/S0007485300039729>
- Gobierno Autónomo Descentralizado de San Miguel de Ibarra. (2021). *Actualización del Plan de Desarrollo y Ordenamiento Territorial del Cantón Ibarra*.
- Gobierno Autónomo Descentralizado del Cantón Otavalo. (2020). *Actualización del Plan de Desarrollo y Ordenamiento Territorial del Cantón Otavalo, Provincia de Imbabura. 2019 - 2023*.
- Gobierno Autónomo Descentralizado Municipal Antonio Ante. (2012). *Actualización Plan de Desarrollo y Ordenamiento Territorial del cantón Antonio Ante*.
- Gobierno Autónomo Descentralizado Municipal Antonio Ante. (2020). *Plan de Desarrollo y Ordenamiento Territorial PDOT 2020 Gobierno Autónomo Descentralizado Municipal Antonio Ante*.
- Gobierno Autónomo Descentralizado Municipal San Pedro de Pimampiro. (2014). *Actualización del Plan de Desarrollo y Ordenamiento Territorial del Cantón San Pedro de Pimampiro*.

- Gobierno Autónomo Descentralizado Municipal Santa Ana de Cotacachi. (2015). *Actualización Plan de Desarrollo y Ordenamiento Territorial del Cantón Santa Ana de Cotacachi 2015 - 2035*.
- Gobierno Autonomo Descentralizado Provincial de Imbabura [GADP-I]. (2015). Plan de desarrollo y ordenamiento territorial de la provincia de Imbabura 2015 - 2035. In *Prefectura de Imbabura*. [https://www.imbabura.gob.ec/phocadownloadpap/K-Planes-programas/PDOT/PDOT IMBABURA 2015-2035.pdf](https://www.imbabura.gob.ec/phocadownloadpap/K-Planes-programas/PDOT/PDOT%20IMBABURA%202015-2035.pdf)
- Gobierno Autónomo Descentralizado San Miguel de Urcuquí. (2014). *Actualización del Plan de Desarrollo y Ordenamiento Territorial San Miguel de Urcuquí*.
- Godoy, S. (2014). *Determinación de especies de insectos de la familia Thysanoptera:Thripidae que afectan al cultivo de rosas en dos zonas florícolas de Pichincha-Ecuador* [Tesis pregrado, Universidad de las Fuerzas Armadas (ESPE)]. <http://repositorio.espe.edu.ec/handle/21000/8920>
- Gómez, P. (2020). *Caracterización geográfica de la familia Thripidae en ornamentales de exportación en la provincia de Cotopaxi* [Tesis de maestría, Universidad Técnica de Cotopaxi (UTC)]. <http://repositorio.utc.edu.ec/handle/27000/9834>
- González, J. (2021). Desarrollo de una propuesta metodológica para el diseño de un clasificador automático de taxonomía del ambiente sonoro mediante técnicas de aprendizaje automático. In *Universidad Politécnica de Madrid*. <https://oa.upm.es/69560/>
- Gonzales, L. (2019). *K Vecinos más cercanos - Teoría*. <https://aprendeia.com/algorithmo-k-vecinos-mas-cercanos-teoria-machine-learning/>
- Guamán, R., Andrade, C., & Alava, J. (2003). *Varietades mejoradas de fréjol arbustivo para el Litoral Ecuatoriano*.
- Guerra, J. (2022). *Fundamentos y variantes de los modelos ARIMA para el análisis de series temporales. Aplicación a la estadística universitaria* [Tesis de pregrado, Universidad de La Laguna]. <https://acortar.link/glhrM1>
- Guevara, M. (2019). Desarrollo de un sistema de clasificación automática de tipos de terrenos empleando técnicas de machine learning [Universidad de las Fuerzas Armadas ESPE]. In *Repositorio.Espe.Edu.Ec*. <http://repositorio.espe.edu.ec/bitstream/21000/15813/1/T-ESPE-040692.pdf>
- Hamarash, H., Hamad, R., & Rasul, A. (2022). Meteorological drought in semi-arid regions: A case study of Iran. *Journal of Arid Land*, 14(11), 1212–1233. <https://doi.org/10.1007/s40333-022-0106-9>

- Hannah, L., Roehrdanz, P. R., Marquet, P. A., Enquist, B. J., Midgley, G., Foden, W., Lovett, J. C., Corlett, R. T., Corcoran, D., Butchart, S. H. M., Boyle, B., Feng, X., Maitner, B., Fajardo, J., McGill, B. J., Merow, C., Morueta-Holme, N., Newman, E. A., Park, D. S., ... Svenning, J. C. (2020). 30% land conservation and climate action reduces tropical extinction risk by more than 50%. *Ecography*, *43*(7), 943–953. <https://doi.org/10.1111/ECOG.05166>
- Haro, D. M. L., Almeida, L. A. A., Mesías, J. P. M., & Chávez, M. A. M. (2022). El impacto de las crisis en el desempeño del sector agropecuario del Ecuador. *Revista Finanzas y Política Económica*, *14*(1), 167–186. <https://doi.org/10.14718/REVFINANZPOLITECON.V14.N1.2022.7>
- Haro-Rivera, S., & Escudero-Villa, A. (2017). Interpolación de datos faltantes mediante spline cúbico y mínimos cuadrados. *Grupo de Energías Alternativas y Ambiente*. <https://perfiles.esPOCH.edu.ec/public/arthtml/Perfiles17/Perfiles17Art7/Perfiles17Art7.html>
- He, Q., Wang, M., Liu, K., Li, K., & Jiang, Z. (2022). GPRChinaTemp1km: A high-resolution monthly air temperature data set for China (1951-2020) based on machine learning. *Earth System Science Data*, *14*(7), 3273–3292. <https://doi.org/10.5194/essd-14-3273-2022>
- Hedong, W. (2007). El efecto de la temperatura sobre el desarrollo de *Frankliniella occidentalis*. *Ciencias Agrícolas de Guizhou*. <https://www.semanticscholar.org/paper/The-Effect-of-Temperature-on-the-Development-of-Hedong/143c756cc1d71884d9b1a1bc8685e1727799de6d#citing-papers>
- Hijmans, R. J., & Spooner, D. M. (2001). Geographic distribution of wild potato species. *American Journal of Botany*, *88*(11), 2101–2112. <https://doi.org/10.2307/3558435>
- Hodkinson, I. (2005). Terrestrial insects along elevation gradients: species and community responses to altitude. *Biological Reviews*, *80*(3), 489–513. <https://doi.org/10.1017/S1464793105006767>
- Hodkinson, I. D. (2009). Life cycle variation and adaptation in jumping plant lice (Insecta: Hemiptera: Psylloidea): A global synthesis. In *Journal of Natural History* (Vol. 43, Issues 1–2, pp. 65–179). <https://doi.org/10.1080/00222930802354167>
- Hong, J., Lee, G. S., Park, J. J., Mo, H. H., & Cho, K. (2019). Risk map for the range expansion of *Thrips palmi* in Korea under climate change: Combining species distribution models with land-use change. *Journal of Asia-Pacific Entomology*, *22*(3), 666–674. <https://doi.org/10.1016/J.ASPEN.2019.04.013>



- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning For Dummies*, IBM Limited Edition. In C. A. Burchfield (Ed.), *Journal of the American Society for Information Science* (Vol. 35, Issue 5). John Wiley & Sons, Inc. <https://doi.org/10.1002/asi.4630350509>
- Instituto Nacional de Estadística y Censos (INEC). (2022). *Cifras Agroproductivas*. <http://sipa.agricultura.gob.ec/index.php/cifras-agroproductivas>
- Instituto Nacional de Investigaciones Agropecuarias [INIAP]. (2014a). *Fruticultura - Aguacate*. <http://tecnologia.iniap.gob.ec/index.php/explore-2/mfruti/raguacate>
- Instituto Nacional de Investigaciones Agropecuarias [INIAP]. (2014b). *Leguminosas - Fréjol voluble*. <http://tecnologia.iniap.gob.ec/index.php/explore-2/mlegum/rfrejol>
- Instituto Nacional de Investigaciones Agropecuarias [INIAP]. (2014c). *Raíces y Tubérculos - Papa*. <http://tecnologia.iniap.gob.ec/index.php/explore-2/mraiz/rpapa>
- Instituto Nacional de Investigaciones Agropecuarias [INIAP]. (2009). *Manual Nro. 78 Programa Nacional de Raíces y Tubérculos-papa Manual del cultivo de papa para pequeños productores: Vol. Instituto* (M. Racines, X. Cuesta, & C. Castillo, Eds.; Imprenta IdeaZ).
- Instituto Nacional de Meteorología e Hidrología. (2013). *Introducción a la Meteorología y a la Climatología*.
- Instituto Nacional de Meteorología e Hidrología [INAMHI]. (2023). *Valores / Misión / Visión*. Instituto Nacional de Meteorología e Hidrología. <https://www.inamhi.gob.ec/>
- Intagri. (2021). *Beauveria bassiana en el Control Biológico de Patógenos* .
- Jacas, J., Caballero, P., & Ávila, J. (2005). *El control biológico de plagas y enfermedades la sostenibilidad de la agricultura mediterránea* (Universitat Jaume I, Ed.). Universitat Jaume I. [https://www.e-buc.com/portades/9788480217750\\_L33\\_23.pdf](https://www.e-buc.com/portades/9788480217750_L33_23.pdf)
- Jácome, E., Auz, D., Marín, K., Mogro, Y., & Jimenez, C. (2022). Ciclo biológico de *Bactericera cockerelli*, vector de la enfermedad de punta morada (*Candidatus liberobacter*) en solanáceas, en los andes centrales ecuatorianos. *Revista Investigación Agraria*, 4(1), 26–37. <https://doi.org/10.47840/reina.4.1.1386>
- Jácome, G. (2018). *Spatial and temporal dynamic patterns of dengue fever in Ecuador based on the maximum entropy model, GIS, and PLS regressions* [Tesis de maestría]. Kyung Hee University.
- James, G., Hastie, T., Witten, D., & Tibshirani, R. (2013). An Introduction to Statistical Learning with Applications in R. In *Springer Texts*.
- Jarosik, V., Koliâs, M., Lapchin, L., Rochat, J., & Dixon, A. F. G. (1997). Seasonal trends in the rate of population increase of *Frankliniella occidentalis* (Thysanoptera:

- Thripidae) on cucumber. *Bulletin of Entomological Research*, 87(5), 487–495. <https://doi.org/10.1017/S0007485300041353>
- Jiménez, E. (2016). *Plagas de cultivos*. Universidad Nacional Agraria.
- Jordán, T. (2023). *Diseño de un método usando técnicas de inteligencia artificial y machine learning con Matlab para el mantenimiento y diagnóstico de fallos en paneles solares* [Tesis de pregrado, UNIVERSITAT POLITÈCNICA DE VALÈNCIA Escuela]. <https://riunet.upv.es/handle/10251/197009>
- Khadioli, N., Tonnang, Z. E. H., Ong'amo, G., Achia, T., Kipchirchir, I., Kroschel, J., & Le Ru, B. (2014). Effect of temperature on the life history parameters of noctuid lepidopteran stem borers, *Busseola fusca* and *Sesamia calamistis*. *Annals of Applied Biology*, 165(3), 373–386. <https://doi.org/10.1111/AAB.12157>
- Khokhar, T., & Kashiwase, H. (2015). *La población mundial en el futuro en cuatro gráficos*. <https://blogs.worldbank.org/es/opendata/la-poblacion-mundial-en-el-futuro-en-cuatro-graficos>
- Kim, Y. H., Yoo, S. J., Gu, Y. H., Lim, J. H., Han, D., & Baik, S. W. (2014). Crop Pests Prediction Method Using Regression and Machine Learning Technology: Survey. *IERI Procedia*, 6, 52–56. <https://doi.org/10.1016/J.IERI.2014.03.009>
- Kirk, W. D. J., & Terry, L. I. (2003). The spread of the western flower thrips *Frankliniella occidentalis* (Pergande). *Agricultural and Forest Entomology*, 5(4), 301–310. <https://doi.org/10.1046/J.1461-9563.2003.00192.X>
- Kocmánková, E., Trnka, Miroslav, Juroch, J., Dubrovský, Martin, Semerádová, D., Možný, Martin, & Žalud, Z. (2009). Impact of Climate Change on the Occurrence and Activity of Harmful Organisms. *Plant Prot. Sci.*, 45. <https://pps.agriculturejournals.cz/pdfs/pps/2009/10/09.pdf>
- Koppert. (2019). *Trips: una pequeña plaga con grandes consecuencias*. <https://www.koppert.mx/noticias-item/trips-una-pequena-plaga-con-grandes-consecuencias/>
- Koppert. (2021). *Trips occidental de las flores*. <https://www.koppert.ec/plagas-en-plantas/trips/trips-occidental-de-las-flores/>
- Lacasa, A., & Martínez, M. (2018). *Los trips en los cultivos de nectarina y melocotón de la Región de Murcia II: treinta años con Frankliniella occidentalis* (Vol. 303).
- Ławrynowicz, A., & Tresp, V. (2014). Introducing machine learning. *Perspectives on Ontology Learning*, 18(November), 35–50. [https://doi.org/10.1007/978-3-030-67626-1\\_8](https://doi.org/10.1007/978-3-030-67626-1_8)

- Lee, S., & Yun, C. M. (2023). A deep learning model for predicting risks of crop pests and diseases from sequential environmental data. *Plant Methods*, 19(1), 1–8. <https://doi.org/10.1186/S13007-023-01122-X/FIGURES/4>
- Lemenkova, P. (2022). Mapping Climate Parameters over the Territory of Botswana Using GMT and Gridded Surface Data from TerraClimate. *ISPRS International Journal of Geo-Information* 2022, Vol. 11, Page 473, 11(9), 473. <https://doi.org/10.3390/IJGI11090473>
- Li, L. (2008). Effect of temperatures on the development and survival rate of western flower thrips, *Frankliniella occidentalis* (Pergande). *Acta Ecologica Sinica*. <https://www.semanticscholar.org/paper/Effect-of-temperatures-on-the-development-and-rate-Li/f19921a1396a4a27360d3620e1f7a7c5ba73a244#citing-papers>
- Lobo, J., & Kamp, U. (2006). Modelos de elevación digital (MED) a partir de sistemas satelitales. Una introducción y análisis comparativo en la cordillera de Mérida-Venezuela. *Revista Geográfica Venezolana*, 49(1), 11–42.
- Luna, A. (2010). *Toxicidad de cuatro insecticidas sobre Tamarixia triozae (Burks) (Hymenoptera) y su hospedero Bactericera cockerelli (Sulc) (Hemiptera: Psyllidae)*. Institución de Enseñanza e Investigación en Ciencias Agrícolas.
- Lyu, Z., Yu, Y., Samali, B., Rashidi, M., Mohammadi, M., Nguyen, T. N., & Nguyen, A. (2022). Back-Propagation Neural Network Optimized by K-Fold Cross-Validation for Prediction of Torsional Strength of Reinforced Concrete Beam. *Materials* 2022, Vol. 15, Page 1477, 15(4), 1477. <https://doi.org/10.3390/MA15041477>
- Maldonado, F., Ramírez, J., Arriaga, M., Némiga, X., & Lara, A. (2016). Distribución espacial de trips en aguacate en Coatepec Harinas, Estado de México. *Revista Mexicana de Ciencias Agrícolas*, 7(4), 845–856.
- Manobanda, A. (2020). *Bioecología de Bactericera cockerelli (Sulc.) en el cultivo de papa (Solanum tuberosum L.) en las provincias de Tungurahua*. Universidad Técnica de Ambato.
- Marcot, B. G., & Hanea, A. M. (2021). What is an optimal value of k in k-fold cross-validation in discrete Bayesian network analysis? *Computational Statistics*, 36(3), 2009–2031. <https://doi.org/10.1007/S00180-020-00999-9/METRICS>
- Mariño, R. (2021). *Predicción de la temperatura ambiental mediante modelos estadísticos funcionales de las estaciones monitoreadas por el GEAA en la provincia de Chimborazo (2014-2019)* [Tesis de pregrado, Escuela Superior Politécnica de Chimborazo]. <http://dspace.epoch.edu.ec/handle/123456789/14822>

- Marozzi, M. (2012). A modified Cucconi Test for Location and Scale Change Alternatives. *Revista Colombiana de Estadística*, 35(3), 371–384.
- Martínez, L. (2013). *La agricultura familiar en el Ecuador*.
- Martínez, N. (2010). Manejo integrado de plagas: Una solución a la contaminación ambiental. *Comunidad y Salud*, 8(1). [http://ve.scielo.org/scielo.php?script=sci\\_arttext&pid=S1690-32932010000100010&lng=es&tlng=es](http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S1690-32932010000100010&lng=es&tlng=es)
- MathWorks. (2023). *Classification Learner*. <https://la.mathworks.com/help/stats/classificationlearner-app.html>
- Maygualema, Lady. (2022). *Fluctuación de la población de la paratrioza (Bactericera cockerelli Sulc.) en cultivos establecidos de tomate de árbol (Solanum betaceum Cav.) en dos zonas altitudinales del cantón Penipe, Provincia de Chimborazo*. Escuela Superior Politécnica de Chimborazo.
- McHugh, M. L. (2011). Multiple comparison analysis testing in ANOVA. *Biochemia Medica*, 21(3), 203–209. <https://doi.org/10.11613/bm.2011.029>
- Medina, M. (2007). *Evaluación de la efectividad biológica de insecticidas para el control de Bactericera cockerelli en Tomate de cáscara (Physalis ixocarpa)*. Universidad de Guadalajara.
- Mendoza, E. (2020). *Cría y reproducción de coccinélidos con la utilización de distintas fuentes de alimentación en la granja experimental la Pradera*. Universidad Técnica del Norte.
- Ministerio de Agricultura, Ganadería, A. y P. [MAGAP]. (2016). *La Política Agropecuaria Ecuatoriana: hacia el desarrollo territorial rural sostenible: 2015- 2025 I parte*. <http://www2.competencias.gob.ec/wp-content/uploads/2021/03/02-06PPP2015-POLITICA02-1.pdf>
- Ministerio de Agricultura y Ganadería. (2021). *Manual para reconocer e identificar el psílido de la papa (Bactericera cockerelli Šulc) en campo y laboratorio*. 121, 40.
- Ministerio de Agricultura y Ganadería [MAG]. (2019). *Agricultura, la base de la economía y la alimentación*. <https://www.agricultura.gob.ec/agricultura-la-base-de-la-economia-y-la-alimentacion/>
- Ministerio para la Transición Ecológica y el Reto Demográfico. (2012). *La Convención Marco de Naciones Unidas sobre el Cambio Climático (CMNUCC)*. El Proceso Internacional de Lucha Contra El Cambio Climático. <https://www.miteco.gob.es/es/cambio-climatico/temas/el-proceso-internacional-de-lucha-contr-el-cambio-climatico/naciones-unidas/#:~:text=en%20la%20materia.->

,La%20Convenci%C3%B3n%20Marco%20de%20Naciones%20Unidas%20sobre%20el%20Cambio%20Clim%C3%A1tico,de%20Lucha%20contra%20la%20Desertificaci%C3%B3n).

- Miranda, C. (2021). *Modelización de Series Temporales modelos clásicos y SARIMA* [Tesis de maestría, Universidad de Granada]. [https://masteres.ugr.es/estadistica-aplicada/sites/master/moea/public/inline-files/TFM\\_MIRANDA\\_CHINLLI\\_CARLOS.pdf](https://masteres.ugr.es/estadistica-aplicada/sites/master/moea/public/inline-files/TFM_MIRANDA_CHINLLI_CARLOS.pdf)
- Montalba, M. (2018). *Integración de la teoría del pensamiento poderoso OTSM – TRIZ con la herramienta de análisis de escenarios futuros Wheel y la Matriz de Vester. Caso de estudio: Monitoreo de incendios forestales en el Territorio Nacional utilizando sistemas de drones de s* [Tesis de pregrado, Universidad Técnica Federico Santa María]. <http://hdl.handle.net/11673/24615>
- Montiel, G., Krishnamurthy, L., Vázquez, A., & Uribe, M. (2007). Opciones Agroforestales para productores de Aguacate. *Terra Latinoamericana*, 1(26), 85–90.
- Morán, J., & Novillo, M. (2022). *Selección de los Modelos de Proyección para el Cambio Climático del CMIP6 con mejor desempeño para el territorio ecuatoriano*. Escuela Superior Politécnica del Litoral.
- Moreno, J. (2012). *Método de detección temprana de outliers* [Tesis de pregrado]. Pontificia Universidad Javeriana.
- Muñoz, C., Suárez, F., & Benavides, M. (2008). Caracterización taxonómica de la especie *Frankliniella occidentalis*(Thysanoptera: Thripidae), plaga del cultivo de rosa para exportación. *Revista Inventum*, 4, 89–93. <https://revistas.uniminuto.edu/index.php/Inventum/article/view/81/79>
- Muthoni, F. (2020). Spatial-temporal trends of rainfall, maximum and minimum temperatures over West Africa. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 2960–2973. <https://doi.org/10.1109/JSTARS.2020.2997075>
- Nicholls, C. (2008). *Control biológico de insectos: un enfoque agroecológico* (Editorial Universidad de Antioquia, Ed.). Ciencia y Tecnología. <https://archive.foodfirst.org/wp-content/uploads/2016/01/Control-biologico-de-insectos-un-enfoque-agroecologico.pdf>
- Nondillo, A., Redaelli, L. R., Botton, M., Pinent, S. M. J., & Gitz, R. (2008). [Thermal requirements and estimate of the annual number of generations of *Frankliniella occidentalis* (Pergande) (Thysanoptera: Thripidae) on strawberry crop]. *Neotropical Entomology*, 37(6), 646–650. <https://doi.org/10.1590/S1519-566X2008000600004>

- Nono, J. (2023). *Generación de superficies de interpolación de la variable temperatura en la provincia de Chimborazo en periodo (2010- 2020)*. [Tesis de pregrado, Escuela Superior Politécnica De Chimborazo]. <http://dspace.esPOCH.edu.ec/handle/123456789/19634>
- Oerke, E. C., & Dehne, H. W. (2004). Safeguarding production—losses in major crops and the role of crop protection. *Crop Protection*, 23(4), 275–285. <https://doi.org/10.1016/J.CROPRO.2003.10.001>
- Ojeda, S. (2003). *Control de Trips (Frankliniella occidentalis Pergande) en el cultivo de fréjol arbustivo (Phaseolus vulgaris L.) San Vicente de Pusir-Carchi, 2000* [Tesis Pregrado, Universidad Central del Ecuador]. <https://repositorio.iniap.gob.ec/handle/41000/2533>
- O'Neill, B. C., Kriegler, E., Ebi, K. L., Kemp-Benedict, E., Riahi, K., Rothman, D. S., van Ruijven, B. J., van Vuuren, D. P., Birkmann, J., Kok, K., Levy, M., & Solecki, W. (2017). The roads ahead: Narratives for shared socioeconomic pathways describing world futures in the 21st century. *Global Environmental Change*, 42, 169–180. <https://doi.org/10.1016/J.GLOENVCHA.2015.01.004>
- O'Neill, B. C., Tebaldi, C., Van Vuuren, D. P., Eyring, V., Friedlingstein, P., Hurtt, G., Knutti, R., Kriegler, E., Lamarque, J. F., Lowe, J., Meehl, G. A., Moss, R., Riahi, K., & Sanderson, B. M. (2016). The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. *Geoscientific Model Development*, 9(9), 3461–3482. <https://doi.org/10.5194/gmd-9-3461-2016>
- Organización de las Naciones Unidas (ONU). (2021). *El cambio climático aumentará el riesgo de propagación de plagas, que ya destruyen un 40% de la producción de cultivos* | Noticias ONU. <https://news.un.org/es/story/2021/06/1492762>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO]. (2008). *Climate-Related Transboundary Pests and Diseases*. <https://www.fao.org/3/ai785e/ai785e.pdf>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO]. (2018). *Glosario de términos fitosanitarios NIMF 5* (Secretaría de la Convención & Internacional de Protección Fitosanitaria, Eds.). [https://www.ippc.int/static/media/files/publication/es/2018/07/ISPM\\_05\\_2018\\_Es\\_2018-07-10\\_PostCPM13.pdf](https://www.ippc.int/static/media/files/publication/es/2018/07/ISPM_05_2018_Es_2018-07-10_PostCPM13.pdf)
- Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO]. (2020). *Plantas: les debes la vida* | Historias de la FAO | Organización de las Naciones

- Unidas para la Alimentación y la Agricultura*. <https://www.fao.org/fao-stories/article/es/c/1276796/>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO]. (2022a). World Food and Agriculture – Statistical Yearbook 2022. In *World Food and Agriculture – Statistical Yearbook 2022*. <https://doi.org/10.4060/cc2211en>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO]. (2022b, May 12). *Cinco formas en las que el cambio climático intensifica las amenazas para la salud de las plantas* | Historias de la FAO | Organización de las Naciones Unidas para la Alimentación y la Agricultura. <https://www.fao.org/fao-stories/article/es/c/1507930/>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura: Ecuador en una mirada | FAO en Ecuador | Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2011). *Ecuador en una mirada*. <https://www.fao.org/ecuador/fao-en-ecuador/ecuador-en-una-mirada/es/>
- Organización Europea y Mediterránea de Protección Vegetal [EPPO]. (2023, February 24). *Frankliniella occidentalis (FRANOC)*. Base de Datos Mundial de La EPPO. <https://gd.eppo.int/taxon/FRANOC/distribution>
- Organización Meteorológica Mundial [OMM]. (2017). *Directrices de la Organización Meteorológica Mundial sobre el Cálculo de las Normales Climáticas*. OMM-N°1203. [https://library.wmo.int/viewer/60338?medianame=1203\\_es\\_#page=4&viewer=picture&o=bookmark&n=0&q=](https://library.wmo.int/viewer/60338?medianame=1203_es_#page=4&viewer=picture&o=bookmark&n=0&q=)
- Organization for Economic Co-operation and Development [OCDE]. (1993). *Core set of indicators for environmental performance reviews: A synthesis report by the group on the state of the environment*. Organización para la Cooperación y el Desarrollo Económico.
- Otzen, T., & Manterola, C. (2017). Técnicas de Muestreo sobre una Población a Estudio. In *Int. J. Morphol* (Vol. 35, Issue 1).
- Padilla, Ó., & Haro, S. (2021). Aplicación de algoritmos de clasificación para la estimación de carbono orgánico del suelo en la provincia de Chimborazo, Ecuador. *Revista Figempa*, 12(2). <https://dialnet.unirioja.es/servlet/articulo?codigo=8529828>
- Palacios, F., Díaz, L., Zuluga, J., & Escobar, J. (1994). Identificación y ciclo de vida de *Frankliniella occidentalis* (Pergande) (Thysanoptera: Thripidae) en crisantemo (*Chrysanthemum morifolium* Ramat) en el municipio de Piendamó, departamento del Cauca. *Revista Colombiana de Entomología*, 20(1), 27–32. <https://doi.org/10.25100/socolen.v20i1.9999>

- Pallmall, A. O. (2021). El cambio climático, una amenaza global. In *El cambio climático, una amenaza global* (Vol. 0). Ediciones Alfar S.A. <https://elibro.net/es/lc/epoch/titulos/183865>
- Palomino-Parra, J., Torres-Cruz, O., & Angulo-Méndez, Y. (2020). Dispositivo basado en modelo arima para predicción de variables ambientales (temperatura, humedad, velocidad del aire) en el área agrícola del departamento del Meta. *Revista GEON (Gestión, Organizaciones y Negocios)*, 7(2), 1–12. <https://doi.org/10.22579/23463910.193>
- Panel Intergubernamental del Cambio Climático. (2014). Climate Change 2014: Synthesis Report. In R. Pachauri & L. Meyer (Eds.), *Kristin Seyboth (USA)* (Core Writi). Core Writing Team. <http://www.ipcc.ch>.
- Paredes, H., Chagna, E., Carvajal, J., & Yépez, R. (2018). *Sistemas Agroforestales en la Provincia de Imbabura* (Vol. 1). Universidad Técnica del Norte.
- Parra, C., & Muñoz, J. (2014). Dinámica ambiental y económica en la localidad de Puente Aranda en Bogotá. *Revista Latinoamericana de Bioética*, 14(27–2), 28–37. <https://doi.org/10.18359/RLBI.505>
- Peralta, E., Murillo, Á., Mazón, N., & Rodríguez, D. (2014). *Catálogo de variedades mejoradas de frejol arbustivo (Phaseolus vulgaris L.) para los valles y estribaciones de la Sierra Ecuatorina: Incluye huella digital y razas*. (3a edición, Issue 146). INIAP. <https://repositorio.iniap.gob.ec/bitstream/41000/2712/1/iniapscpm146.pdf>
- Pérez, M. (2021). *Plagas: modelos predictivos*. Avance Agroindustrial. <https://www.avance.eeaoc.gob.ar/?articulo=plagas-modelos-predictivos#:~:text=Cuando hablo de modelización me,afectan a un determinado cultivo>.
- Perugachi-Salamea, C., González-Narváez, M., Pambabay-Calero, J., García-Arévalo, I., Vargas-Ayala, F., Shigla-Cuji, G., & Nath-Nieto, J. (2014). Caracterización oceanográfica del perfil costero ecuatoriano a través de métodos estadísticos aplicados a las estaciones fijas de monitoreo del INOCAR, seria a partir de 1981. *Acta Oceanográfica Del Pacífico*, 19(2), 7–21. <http://www.inocar.mil.ec/web/index.php/publicaciones/file/299-caracterizacion-oceanografica-del-perfil-costero-ecuadoriano-a-traves-de-metodos-estadisticos-aplicados-a-las-estaciones-fijas-de-monitoreo-del-inocar>
- Pörtner, H.-O., Scholes, R. J., Agard, J., Archer, E., Arneth, A., Bai, X., Barnes, D., Burrows, M., Chan, L., Cheung, W. L. (William), Diamond, S., Donatti, C., Duarte, C., Eisenhauer, N., Foden, W., Gasalla, M. A., Handa, C., Hickler, T., Hoegh-



- Guldberg, O., ... Ngo, H. (2021). *Scientific outcome of the IPBES-IPCC co-sponsored workshop on biodiversity and climate change*. IPBES secretariat. <https://doi.org/10.5281/ZENODO.5101125>
- Prager, S. M., & Trumble, J. T. (2018). Psyllids: Biology, Ecology, and Management. In *Sustainable Management of Arthropod Pests of Tomato* (Academic P, pp. 163–181). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-802441-6.00007-3>
- Prakash, A. (Anand), Rao, J., Mukherjee, A. K., Berliner, J., Pokhare, S. S., Adak, T., Munda, S., Shashank, P. R., Applied Zoologists Research Association, & Central Rice Research Institute (India). (2014). *Climate change: impact on crop pests*. [https://www.researchgate.net/publication/275347570\\_Climate\\_Change\\_Impact\\_on\\_Crop\\_Pests](https://www.researchgate.net/publication/275347570_Climate_Change_Impact_on_Crop_Pests)
- Programa de las Naciones Unidas para el Desarrollo [PNUD]. (2023). *Objetivos de Desarrollo Sostenible*. Programa de Las Naciones Unidas Para El Desarrollo. <https://www.undp.org/sustainable-development-goals>
- Pucheta, M., Flores, A., Rodríguez, S., & Torre, M. (2006). Mecanismo de Acción de los hongos entomopatógenos. *Interciencia*, 31(12).
- Pujota, A. G. (2013). *Sistematización del manejo integrado de Frankliniella occidentalis, en el cultivo de rosas bajo invernadero en el sector de Tabacundo, Cantón Pedro Moncayo Provincia de Pichincha* [Tesis Posgrado, Universidad Politécnica Salesiana]. <http://dspace.ups.edu.ec/handle/123456789/5076>
- Ramírez, J., Porcayo-Camargo, E., & Sánchez, J. (2013). Modelización de la distribución espacial de *Bactericera cockerelli* Sulc. (Hemiptera: Triozidae) en *Solanum tuberosum* L. (Solanales: Solanaceae). *Revista de La Facultad de Ciencias Agrarias. Universidad Nacional de Cuyo*, 45(2), 11–20. [http://www.scielo.org.ar/scielo.php?script=sci\\_arttext&pid=S1853-86652013000200002&lng=es&nrm=iso&tlng=es](http://www.scielo.org.ar/scielo.php?script=sci_arttext&pid=S1853-86652013000200002&lng=es&nrm=iso&tlng=es)
- Reascos, C. (2021). *Revisión bibliográfica de los protocolos de manejo de biocontroladores (Chrysopidae) en su captura, aislamiento y propagación, Salache - Ceypsa, Latacunga. 2020 - 2021*.
- Refaeilzadeh, P., Tang, L., & Liu, H. (2008). Cross Validation. In *Cross-Validation*. Arizona State University. [https://doi.org/10.1007/978-1-84800-217-3\\_1](https://doi.org/10.1007/978-1-84800-217-3_1)
- Riahi, K., van Vuuren, D. P., Kriegler, E., Edmonds, J., O'Neill, B. C., Fujimori, S., Bauer, N., Calvin, K., Dellink, R., Fricko, O., Lutz, W., Popp, A., Cuaresma, J. C., KC, S., Leimbach, M., Jiang, L., Kram, T., Rao, S., Emmerling, J., ... Tavoni, M. (2017). The Shared Socioeconomic Pathways and their energy, land use, and greenhouse gas

- emissions implications: An overview. *Global Environmental Change*, 42, 153–168.  
<https://doi.org/10.1016/J.GLOENVCHA.2016.05.009>
- Ríos, R., Vargas, J., Sánchez, J., Oliva, R., Alarcón, T., & Villegas, P. (2020). Beauveria bassiana and Metarhizium anisopliae as compatible and efficient controllers of plague insects in aquaponic crops. *Scientia Agropecuaria*, 11(3), 419–426.  
<https://doi.org/10.17268/sci.agropecu.2020.03.14>
- Rivera, C. G., Funes, K. T., Villalta, J., & Sánchez, A. (2021). Guía para el modelo de distribución de especies por Máxima Entropía, estudio de caso de la “lora nuca amarilla” Amazona auropalliata en El Salvador. *Minerva*, 4(2), 125–142.  
<https://minerva.sic.ues.edu.sv>
- Rivera, P., Herrera, E., & Ochoa, W. (2022). Comparación de series mensuales de precipitación y temperaturas de los Modelos CMIP6 para Guatemala. *Ciencia, Tecnología y Salud*, 9(2), 130–149.
- Romero, S. (2022). “Control orgánico de Lorito verde (*Empoasca fabae* L.), en el cultivo del fréjol (*Phaseolus vulgaris* L.).” Universidad Técnica de Babahoyo.
- Rosenberg, G. (2004). *Análisis geoestadístico de la distribución de plagas en el cultivo de mango*. Escuela Superior Politécnica del Litoral.
- Rubio, O., Humberto, I., Cadena, M., & Sánchez, R. (2011). Relación entre Bactericera cockerelli y presencia de Candidatus Liberibacter psyllaerous en lotes comerciales de papa. *Revista Mexicana de Ciencias Agrícolas*, 2(1), 17–28.
- Samadianfard, S., Mikaeili, F., & Prasad, R. (2022). Evaluation of classification and decision trees in predicting daily precipitation occurrences. *Water Supply*, 22(4), 3879–3895. <https://doi.org/10.2166/ws.2022.017>
- Samaniego, I., Espin, S., Cuesta, X., Arias, V., Rubio, A., Llerena, W., Angós, I., & Carrillo, W. (2020). Analysis of Environmental Conditions Effect in the Phytochemical Composition of Potato (*Solanum tuberosum*) Cultivars. *Plants*, 9(7).  
<https://doi.org/10.3390/plants9070815>
- Sánchez, A., & Toledo, C. (2017). *Dinámica poblacional de trips (Insecta: Thysanoptera), sus parasitoides y depredadores asociados al cultivo del ejote francés en Chimaltenango*. Univesidad de San Carlos de Guatemala.
- Sanchez, J., Lacasa, A., & Contreras, J. (1998). *Influencia de las temperaturas extremas en el desarrollo de Frankliniella occidentalis (Pergande) (Thysanoptera: Thripidae)*.
- Santillán, K., & Zamora, B. (2021). *Análisis Climático y de Cambio Climático en el Distrito Metropolitano de Quito* [Tesis de pregrado, Universidad Politécnica Salesiana Sede Quito]. <http://dspace.ups.edu.ec/bitstream/123456789/5081/1/UPS-CYT00109.pdf>

- Sazo, L., Soto, N., & Araya, J. E. (2006). Capacidad depredadora de *Neoseiulus californicus* (McGregor) sobre larvas de *Frankliniella occidentalis* (Pergande) y *Heliethrips haemorrhoidalis* (Bouché). In *Boletín Sociedad Entomológica Aragonesa*.
- Scharf, I. (2016). *Estudio de la respuesta de los insectos acambios climáticos a corto plazo*. <https://cordis.europa.eu/article/id/120575-studying-insects-response-to-short-term-climate-events/es>
- Secretaría Nacional de Planificación y Desarrollo, & [SENPLADES]. (2021). *Plan de Creación de Oportunidades 2021-2025 de Ecuador | Observatorio Regional de Planificación para el Desarrollo*. <https://observatorioplanificacion.cepal.org/es/planes/plan-de-creacion-de-oportunidades-2021-2025-de-ecuador>
- Serra, A. (2020). *Comparación de algoritmos de clasificación supervisada* [Tesis de maestría]. Escola Tècnica Superior d'Enginyeria Industrial de Barcelona.
- Sevilla, R. (2019). *Identificación y análisis de problemas mediante la aplicación de la matriz Vester*. <https://docplayer.es/77607651-Identificacion-y-analisis-de-problemas-mediante-la-aplicacion-de-la-matriz-vester.html>
- Sharma, S., Kooner, R., & Arora, R. (2017). Insect pests and crop losses. In R. Arora & S. Sandhu (Eds.), *Breeding Insect Resistant Crops for Sustainable Agriculture* (pp. 45–66). Springer. [https://doi.org/DOI 10.1007/978-981-10-6056-4\\_2](https://doi.org/DOI 10.1007/978-981-10-6056-4_2)
- Siegel, S. (1995). Estadística No Paramétrica: aplicada a las ciencias de la conducta. In Trillas (Ed.), *Angewandte Chemie International Edition*, 6(11), 951–952. (4a edición).
- Singh, A., Amutha, J., Nagar, J., Sharma, S., & Lee, C. C. (2022). AutoML-ID: automated machine learning model for intrusion detection using wireless sensor network. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-13061-z>
- Singh, B. P., Govindakrishnan, P. M., Ahmad, I., Rawat, S., Sharma, S., & Sreekumar, J. (2016). INDO-BLIGHTCAST – a model for forecasting late blight across agroecologies. *International Journal of Pest Management*, 62(4), 360–367. <https://doi.org/10.1080/09670874.2016.1210839>
- Solano, Y., Giménez, A., Pérez, M., Morales, J., & Zurita, G. (2018). Nuevos registros de *Frankliniella occidentalis* (Pergande) (Thysanoptera: Thripidae) y de *Tetranychus urticae* Koch (Acari: Tetranychidae) en fresas cultivadas en Venezuela. *Revista Colombiana de Ciencias Hortícolas*, 12(1), 69–74.

- Sotomayor, A., Viera, W., Viteri, P., Posso, M., Racines, M., González, A., Cho, K., & Villavicencio, A. (2019). *Manual Técnico para la producción de plantas injertas. Aguacate (Persea americana Mill.) de alta calidad* (Manual N° 108).
- Souza, V., Araújo, L., Silva, L., & Santos, A. (2020). Análise Comparativa de Redes Neurais Convolucionais no Reconhecimento de Cenas. *An. Comput. Beach*, 419–426. <https://doi.org/10.14210/cotb.v11n1.p419-426>
- Sporleder, M., Carhuapoma, P., Juarez, H., Simon, R., Simon, R., Kroschel, J., & Kreuze, J. (2020). ILCYM – Modelado del Ciclo de Vida de los Insectos. Un paquete de software para desarrollar modelos de fenología de insectos basados en la temperatura con aplicaciones para el análisis local, regional y global de la población de insectos y mapeo. In *ILCYM – Modelado del Ciclo de Vida de los Insectos 4.0*. International Potato Center. <https://doi.org/10.4160/9789290605461>
- Stepanycheva, E. A., Pazyuk, I. M., Chermenskaya, T. D., Petrova, M. O., & Pavela, R. (2020). Comparative Evaluation of Reactions of the Western Flower Thrips *Frankliniella occidentalis* Perg. (Thysanoptera, Thripidae) and the Predatory Bug *Orius laevigatus* Fieber (Heteroptera, Miridae) to *Pongamia pinnata* (L.) Pierre Oil. *Entomological Review*, 100(4), 449–455. <https://doi.org/10.1134/S0013873820040028>
- Stockwell, D. (1999). El sistema de modelado GARP : problemas y soluciones para la predicción espacial automatizada. *Geogr. Información Ciencia*, 13, 143–158.
- Sung, H., Moon, I. J., Won, S. H., Kang, H. W., & Kang, S. K. (2021). Decision-tree-based classification of lifetime maximum intensity of tropical cyclones in the tropical western north pacific. *Atmosphere*, 12(7). <https://doi.org/10.3390/atmos12070802>
- Sutherst, R. W., & Maywald, G. F. (1985). A computerised system for matching climates in ecology. *Agriculture, Ecosystems & Environment*, 13(3–4), 281–299. [https://doi.org/10.1016/0167-8809\(85\)90016-7](https://doi.org/10.1016/0167-8809(85)90016-7)
- Szymanowski, M., & Kryza, M. (2011). Application of geographically weighted regression for modelling the spatial structure of urban heat island in the city of Wroclaw (SW Poland). *Procedia Environmental Sciences*, 3, 87–92. <https://doi.org/10.1016/J.PROENV.2011.02.016>
- Tilman, D., Balzer, C., Hill, J., & Befort, B. L. (2011). Global food demand and the sustainable intensification of agriculture. *Proceedings of the National Academy of Sciences of the United States of America*, 108(50), 20260–20264. [https://doi.org/10.1073/PNAS.1116437108/SUPPL\\_FILE/PNAS.201116437SI.PDF](https://doi.org/10.1073/PNAS.1116437108/SUPPL_FILE/PNAS.201116437SI.PDF)


- Toapanta, B. (2020). *Áreas de vulnerabilidad ambiental a la presencia actual y futura de Bactericera cockerelli (Sulc) en el cultivo de la papa en la sierra ecuatoriana en el periodo 2020* [Universidad Técnica de Cotopaxi UTC]. <http://repositorio.utc.edu.ec/handle/27000/7068>
- Tokuhama, T., & Bramwell, D. (2010). Educación Ambiental y Desarrollo Sostenible. *Polémika*, 2(5), 120–129. <https://revistas.usfq.edu.ec/index.php/polemika/article/view/379>
- Toledo, C., & Rodas, A. (2022). Comportamiento poblacional y proporción sexual de *Bactericera cockerelli* (Sulc) (Hemiptera: Triozidae) en papa (*Solanum tuberosum* L.). *Revista Científica de FAREM-Esteli Medio Ambiente, Tecnología y Desarrollo Humano*. <https://rcientificaesteli.unan.edu.ni/index.php/RCientifica/article/view/1490/1619>
- Toledo-Perdomo, C. E., & Rodas, A. (2022). Comportamiento poblacional y proporción sexual de *Bactericera cockerelli* (Sulc) (Hemiptera: Triozidae) en papa (*Solanum tuberosum* L.). *Revista Científica de FAREM-Esteli*, 42, 191–203. <https://doi.org/10.5377/farem.v11i42.14698>
- Tonnang, H. E. Z., Hervé, B. D. B., Biber-Freudenberger, L., Salifu, D., Subramanian, S., Ngowi, V. B., Guimapi, R. Y. A., Anani, B., Kakmeni, F. M. M., Affognon, H., Ndjomatchoua, F. T., Pedro, S. A., Nana, P., Johansson, T., Nedorezov, L. V., Tanga, C. M., Nana, P., Fiaboe, K. M., Mohamed, S. F., ... Borgemeister, C. (2017). Advances in crop insect modelling methods—Towards a whole system approach. *Ecological Modelling*, 354, 88–103. <https://doi.org/10.1016/J.ECOLMODEL.2017.03.015>
- Toro, M. (2012). *Las prácticas agrícolas y su relación con la certificación de productos limpios de la provincia de Tungurahua*. [Tesis de Mestría]. Universidad Técnica de Ambato.
- Torrado, E. (2019). *Evaluación de tres mallas anti-trips basadas en la morfología corporal de los trips y la abertura de los agujeros de las mallas*. Metroflor-Agro. <https://www.metroflorcolombia.com/evaluacion-de-tres-mallas-anti-trips-basadas-en-la-morfologia-corporal-de-los-trips-thysanoptera-thripidae-y-la-abertura-de-los-agujeros-de-las-mallas/>
- Tran, L. T., Worner, S. P., Hale, R. J., & Teulon, D. A. J. (2012). Estimating Development Rate and Thermal Requirements of *Bactericera cockerelli* (Hemiptera: Triozidae) Reared on Potato and Tomato By Using Linear and Nonlinear Models. *Environ. Entomol*, 41(5), 1190–1198. <https://doi.org/10.1603/EN12124>

- Tripathy, A. K., Adinarayana, J., Sudharsan, D., Merchant, S. N., Desai, U. B., Vijayalakshmi, K., Raji Reddy, D., Sreenivas, G., Ninomiya, S., Hirafuji, M., Kiura, T., & Tanaka, K. (2011). Data mining and wireless sensor network for agriculture pest/disease predictions. *Proceedings of the 2011 World Congress on Information and Communication Technologies, WICT 2011*, 1229–1234. <https://doi.org/10.1109/WICT.2011.6141424>
- Try, S., Tanaka, S., Tanaka, K., Sayama, T., Khujanazarov, T., & Oeurng, C. (2022). Comparison of CMIP5 and CMIP6 GCM performance for flood projections in the Mekong River Basin. *Journal of Hydrology: Regional Studies*, 40, 101035. <https://doi.org/10.1016/J.EJRH.2022.101035>
- Tuapanta, D., Duque, M., & Mena, R. (2017). Alfa de Cronbach para validar un cuestionario de uso TIC en docentes universitarios. *MktDescubre-ESPOCH FADE*, 10, 37–48.
- Vabalas, A., Gowen, E., Poliakoff, E., & Casson, A. J. (2019). Machine learning algorithm validation with a limited sample size. *PLOS ONE*, 14(11), e0224365. <https://doi.org/10.1371/JOURNAL.PONE.0224365>
- Vallejo, M. (2020). *Caracterización filogenética y molecular de 'Candidatus Liberibacter solanacearum' en cuatro especies de la familia Solanaceae*.
- Velásquez, L. (2006). *Aspectos Bioecológicos de las Plagas en los Cultivos Agrícolas* (2da. edici). PROMIPAC-INATEC-SICA-ZAMORANO-TAIWÁN.
- Viera, F., Tello, C., Martínez, A., Navia, D., Medina, L., Delgado, A., Perdomo, C., Pincay, A., & Baéz, F. (2020). *Control Biológico: Una herramienta para una agricultura sustentable, un punto de vista de sus beneficios en Ecuador Biological Control*.
- Villavicencio, A., & Vásquez C., W. (2008). *Guía técnica de cultivos* (A. Villavicencio & W. Vásquez C., Eds.). INIAP. <https://repositorio.iniap.gob.ec/jspui/handle/41000/851>
- Wan, J., Wang, R., Ren, Y., & McKirdy, S. (2020). Potential Distribution and the Risks of *Bactericera cockerelli* and Its Associated Plant Pathogen *Candidatus Liberibacter Solanacearum* for Global Potato Production. *Insects*, 11(5). <https://doi.org/10.3390/INSECTS11050298>
- Wilks, D. (1995). *Métodos estadísticos en las ciencias atmosféricas*. Prensa académica.
- Wilson, A. (2019). *A Brief Introduction to Supervised Learning*. Towards Data Science. <https://towardsdatascience.com/a-brief-introduction-to-supervised-learning-54a3e3932590>

- Wong, T. T. (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern Recognition*, 48(9), 2839–2846. <https://doi.org/10.1016/J.PATCOG.2015.03.009>
- Yamberla, T. R. (2022). *Evaluación de diatomitas para el control de plagas en el cultivo de rosas (Rosa SP.) Var. Freedom, Bolívar, Carchi* [Tesis de pregrado, Universidad Técnica del Norte]. <http://repositorio.utn.edu.ec/handle/123456789/13389>
- Yan, Y., Wang, Y. C., Feng, C. C., Wan, P. H. M., & Chang, K. T. T. (2017). Potential distributional changes of invasive crop pest species associated with global climate change. *Applied Geography*, 82, 83–92. <https://doi.org/10.1016/J.APGEOG.2017.03.011>
- Yang, B., & Liu, T. (2009). Historia de Vida y Tablas de Vida de *Bactericera cockerelli* (Homópteros:Psílicos) sobre Berenjena y Pimiento Morrón. *Environ. Entomol*, 38(6), 1661–1667. [www.onlinedoctranslator.com](http://www.onlinedoctranslator.com)
- Yu, Z., & Tan, Z. (2019). Decision Tree cloud detection algorithm based on FY-4A Satellite data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(3/W9), 219–226. <https://doi.org/10.5194/isprs-archives-XLII-3-W9-219-2019>
- Zalucki, M. P., & Furlong, M. J. (2008). Predicting outbreaks of a migratory pest: An analysis of DBM distribution and abundance. In Prensa de ciencia y tecnología agrícola de China (Ed.), *Management of Diamondback Moth & Other Crucifer Pests* (pp. 122–131). China Agricultural Science and Technology Press.
- Zea, J., Montealegre, J. E., Hurtado, G., González, O. C., Pabón, J. D., & León, G. (2001). *La atmósfera, el tiempo y el clima*.
- Zumbado, M., & Azofeifa, D. (2018). Insectos de Importancia Agrícola. In *Programa Nacional de Agricultura Orgánica (PNAO)*. <http://www.mag.go.cr/bibliotecavirtual/H10-10951.pdf>

# ANEXOS

Anexo 1. Mapa de ubicación del área de estudio






Anexo 2. Mapa de ubicación de estaciones meteorológicas analizadas






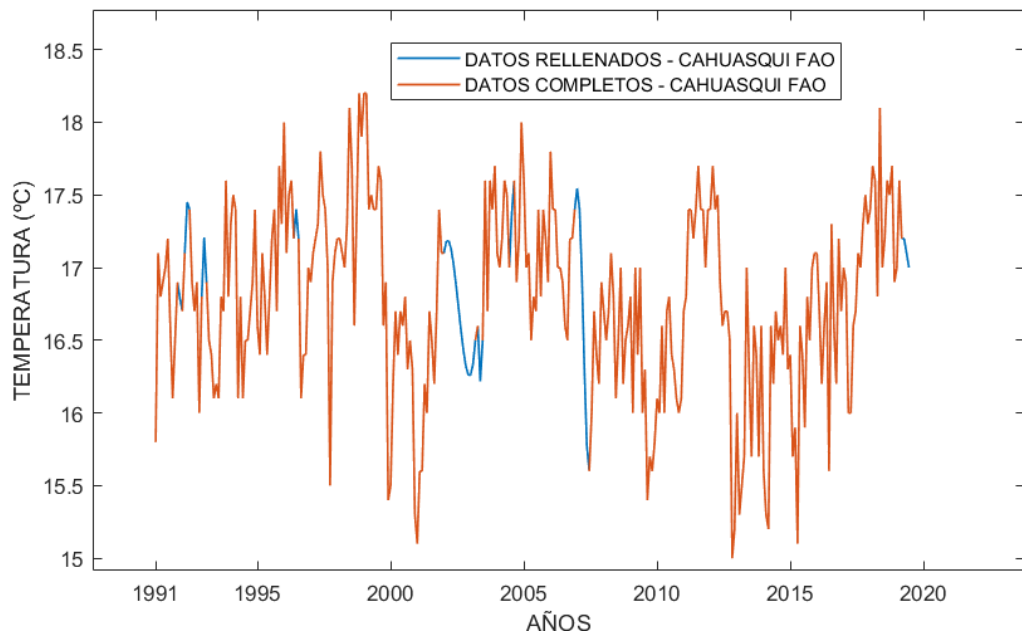
Anexo 3. Mapa de Modelo Digital de Elevación (DEM) del SRTM para Imbabura


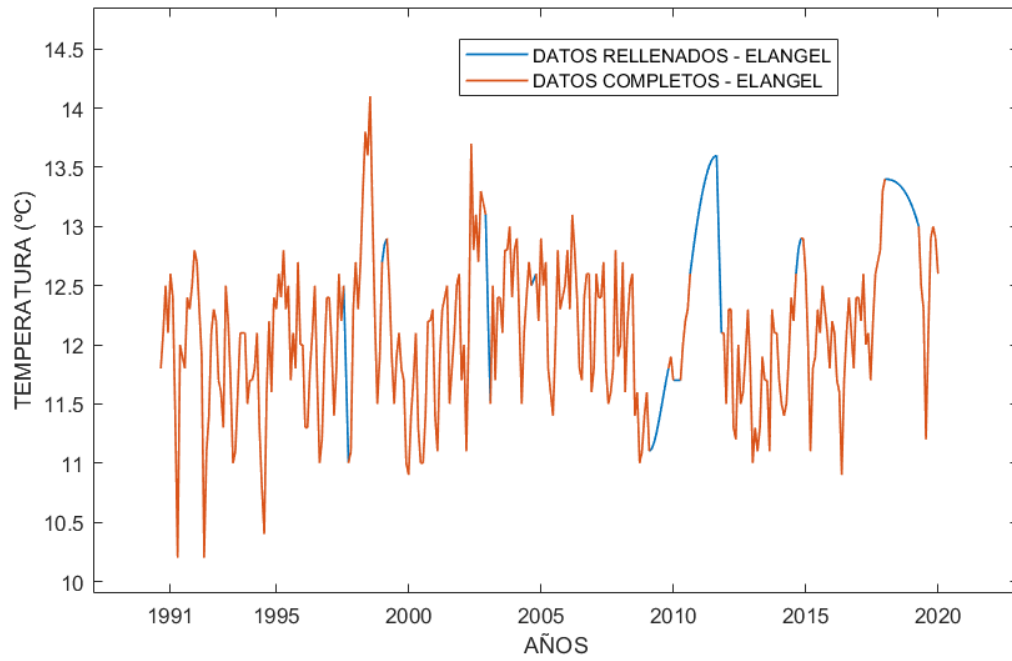


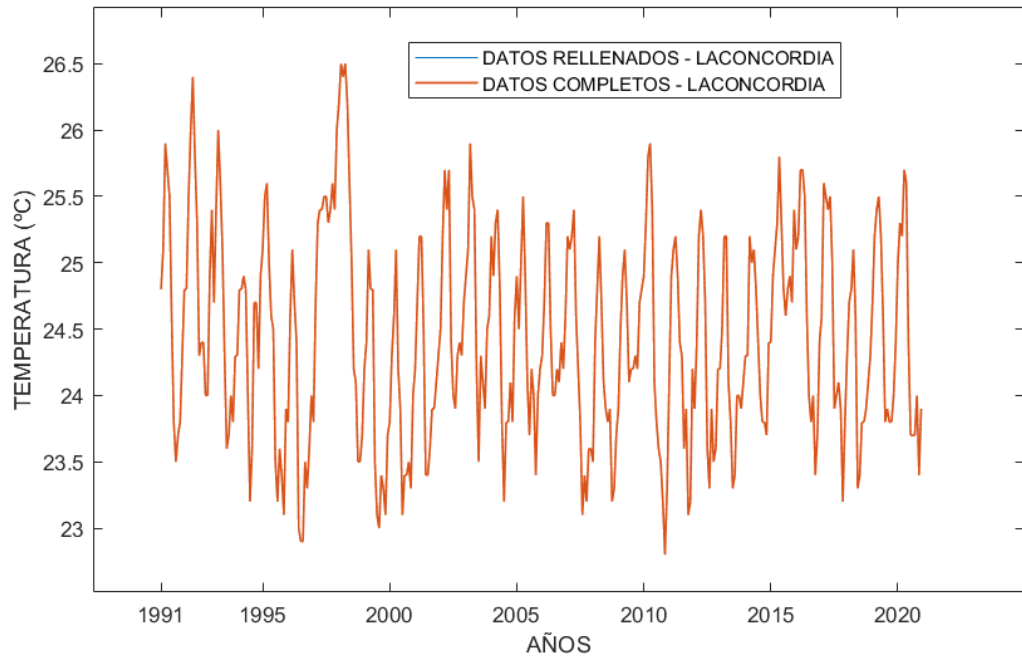
Anexo 4. Datos rellenados y completos de estaciones meteorológicas del

INAMHI


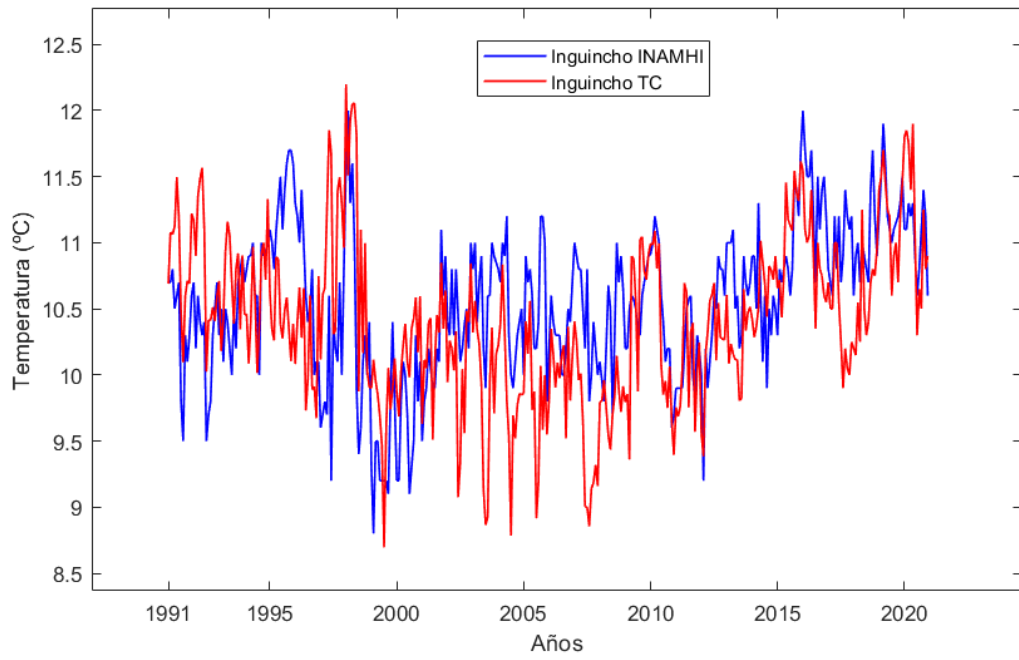













**Anexo 5.** Temperatura media de las estaciones del INAMHI y TerraClimate (TC)













**Anexo 6.** Concordancia de datos de temperatura media del INAMHI y TerraClimate para cada estación





**Anexo 7. Matriz de datos de temperatura de Gradiente Ambiental Vertical y Terraclimate**


<b>Coordenada X</b>	<b>Coordenada Y</b>	<b>Elevación</b>	<b>T (°C) Gradiente</b>	<b>T (°C) TerraClimate</b>
694930	10.036.994	205	27,02	25,54
701439	10.036.756	236	26,85	25,32
720965	10.033.502	518	25,32	23,57
729776	10.038.899	947	23,01	21,28
785576	10.093.827	1.003	22,71	23,03
738904	10.029.930	1.018	22,62	21,53
729299	10.029.771	1.081	22,28	21,58
766367	10.026.437	1.198	21,65	20,58
789704	10.085.651	1.379	20,68	20,95
781052	10.084.540	1.383	20,65	20,54
799229	10.085.492	1.411	20,5	20,09
811532	10.075.015	1.413	20,49	20
743587	10.034.454	1.532	19,85	18,21
826575	10.052.612	1.595	19,51	19,7
733982	10.034.613	1.626	19,34	19,44
808039	10.079.777	1.661	19,15	21,07
776051	10.040.010	1.666	19,13	18,34
817961	10.053.425	1.692	18,99	19,3
781628	10.072.847	1.828	18,25	18,22
818199	10.048.503	1.842	18,18	18,67
794863	10.075.729	1.910	17,81	17,12
799149	10.080.968	1.971	17,48	17,4
821613	10.048.662	2.033	17,14	17,51
775099	10.048.424	2.041	17,1	16,12
757001	10.035.327	2.083	16,87	17,65
752874	10.035.407	2.085	16,86	18,15
817644	10.062.315	2.099	16,79	17,97
831773	10.048.186	2.177	16,37	18,75
775972	10.052.552	2.284	15,79	15,03
808436	10.043.820	2.318	15,6	15,85
818120	10.034.652	2.356	15,4	15,87
822168	10.035.049	2.396	15,18	15,6
761526	10.038.899	2.551	14,35	14,07
804229	10.025.921	2.560	14,3	14,55
808278	10.066.918	2.564	14,28	13,97
785735	10.044.058	2.588	14,15	14,9
803912	10.039.296	2.622	13,96	14,61
836932	10.039.256	2.792	13,05	14,29
766209	10.043.265	2.797	13,02	12,83
845584	10.034.811	2.810	12,95	12,82
803833	10.021.079	2.933	12,28	11,94
812881	10.016.793	3.012	11,86	11,41
785179	10.034.930	3.057	11,61	11,9
794466	10.025.882	3.083	11,47	11,88
789704	10.065.569	3.188	10,91	12,67
784386	10.058.425	3.282	10,4	10,55
827010	10.030.207	3.372	9,91	10,38
794546	10.034.613	3.395	9,79	9,91
849870	10.025.842	3.446	9,51	8,88
840821	10.021.238	3.493	9,26	7,85
817882	10.025.604	3.585	8,76	10,09
831455	10.025.842	3.610	8,63	7,6
793990	10.052.710	3.689	8,2	6,77
812484	10.029.652	3.711	8,08	9,14
799467	10.057.711	3.768	7,77	7,69

**Anexo 8.** Tabla de frecuencia para altitud de los puntos de presencia de *F. occidentalis*


Clase	Límite Inferior	Límite Superior	Frecuencia	Frecuencia Acumulada	Frecuencia Relativa	Frecuencia Rel. Acum.
	menor o igual	1000	0	0	0,00	0,00
1	1000	1192	1	1	0,01	0,01
2	1192	1383	0	1	0,00	0,01
3	1383	1575	5	6	0,03	0,04
4	1575	1767	15	21	0,09	0,13
5	1767	1958	13	34	0,08	0,22
6	1958	2150	14	48	0,09	0,30
7	2150	2342	34	82	0,22	0,52
8	2342	2533	38	120	0,24	0,76
9	2533	2725	26	146	0,16	0,92
10	2725	2917	4	150	0,03	0,95
11	2917	3108	4	154	0,03	0,97
12	3108	3300	4	158	0,03	10000,00
	mayor de	3300	0	158	0,00	10000,00

**Nota:** Las estadísticas resumen de la variable elevación de 158 valores con rango desde 1033 a 3284 m s. n. m., son: media = 2271,51, desviación estándar = 389,833, sesgo estandarizado = -0.855 y curtosis estandarizada=1,20. Estos dos últimos estadísticos tienen valores que se encuentran dentro del rango de -2 a +2, esperado para datos provenientes de una distribución normal.


**Anexo 9.** Histograma (a) y cajas y bigotes (b) de la variable altitud



Anexo 10. Mapa de temperatura media de TerraClimate para Imbabura



Anexo 11. Mapa de temperatura de gradiente ambiental vertical para Imbabura





**Anexo 12.** Clasificadores entrenados para el *dataset* de *B. cockerelli* S.-  
Temperatura

<b>Tipo de Modelo</b>	<b>Accuracy % (Validación)</b>	<b>Algoritmo</b>	<b>Tiempo de entrenamiento (seg)</b>
Tree	99,9915	Fine Tree	11,10
Tree	99,9915	Medium Tree	9,14
Tree	99,9915	Coarse Tree	8,36
Discriminant	96,6624	Linear Discriminant	8,16
Discriminant	98,0119	Quadratic Discriminant	7,60
Efficient Logistic Regression	97,2754	Efficient Logistic Regression	6,95
Efficient Linear SVM	98,2077	Efficient Linear SVM	5,99
Naive Bayes	98,0119	Gaussian Naive Bayes	5,42
Naive Bayes	99,7488	Kernel Naive Bayes	34,41
SVM	98,2205	Linear SVM	1043,24
SVM	84,0868	Quadratic SVM	3773,46
SVM	79,2380	Cubic SVM	8345,63
SVM	99,9149	Fine Gaussian SVM	47,18
SVM	99,8382	Medium Gaussian SVM	61,03
SVM	99,0081	Coarse Gaussian SVM	88,70
KNN	99,9915	Fine KNN	90,28
KNN	99,9702	Medium KNN	91,40
KNN	99,9489	Coarse KNN	93,72
KNN	68,1183	Cosine KNN	100,19
KNN	99,9702	Cubic KNN	101,55
KNN	99,9915	Weighted KNN	102,44
Ensemble	68,1183	Boosted Trees	104,61
Ensemble	99,9915	Bagged Trees	113,69
Ensemble	96,6624	Subspace Discriminant	120,21
Ensemble	99,9915	Subspace KNN	135,82
Ensemble	99,9830	RUSBoosted Trees	137,69
Neural Network	99,3699	Narrow Neural Network	158,91
Neural Network	99,9915	Medium Neural Network	170,26
Neural Network	99,9957	Wide Neural Network	204,59
Neural Network	99,9915	Bilayered Neural Network	272,93
Neural Network	99,6977	Trilayered Neural Network	426,30
Kernel	81,8519	SVM Kernel	436,02
Kernel	70,4172	Logistic Regression Kernel	441,11

**Anexo 13.** Clasificadores entrenados para el *dataset* de *F. occidentalis*-  
Temperatura

<b>Tipo de Modelo</b>	<b>Accuracy % (Validación)</b>	<b>Algoritmo</b>	<b>Tiempo de entrenamiento (seg)</b>
Tree	99,9872	Fine Tree	5,23
Tree	99,9872	Medium Tree	3,56
Tree	99,9872	Coarse Tree	8,83
Discriminant	97,5053	Linear Discriminant	7,87
Discriminant	97,6203	Quadratic Discriminant	7,39
Efficient Logistic Regression	98,7058	Efficient Logistic Regression	6,40
Efficient Linear SVM	98,9102	Efficient Linear SVM	8,02
Naive Bayes	97,6203	Gaussian Naive Bayes	2,45
Naive Bayes	99,6594	Kernel Naive Bayes	18,91
SVM	98,9144	Linear SVM	1098,94
SVM	78,9357	Quadratic SVM	2549,46
SVM		Cubic SVM	4338,29
SVM	99,9447	Fine Gaussian SVM	30,74
SVM	99,9447	Medium Gaussian SVM	22,83
SVM	99,5402	Coarse Gaussian SVM	31,56
KNN	99,9872	Fine KNN	7,56
KNN	99,9617	Medium KNN	7,99
KNN	99,9659	Coarse KNN	10,16
KNN	44,5126	Cosine KNN	15,98
KNN	99,9617	Cubic KNN	15,32
KNN	99,9830	Weighted KNN	16,13
Ensemble	48,8719	Boosted Trees	18,60
Ensemble	99,9872	Bagged Trees	27,82
Ensemble	97,5053	Subspace Discriminant	24,93
Ensemble	99,9872	Subspace KNN	34,56
Ensemble	84,6403	RUSBoosted Trees	26,65
Neural Network	99,9149	Narrow Neural Network	42,98
Neural Network	99,9915	Medium Neural Network	42,27
Neural Network	99,9872	Wide Neural Network	70,73
Neural Network	99,6381	Bilayered Neural Network	119,64
Neural Network	99,9872	Trilayered Neural Network	188,25
Kernel	66,5688	SVM Kernel	56,36
Kernel	54,0868	Logistic Regression Kernel	52,38

**Anexo 14.** Clasificadores entrenados para el *dataset* de *B. cockerelli* S. y *F. occidentalis*-Temperatura

<b>Tipo de Modelo</b>	<b>Accuracy % (Validación)</b>	<b>Algoritmo</b>	<b>Tiempo de entrenamiento (seg)</b>
Tree	99,9915	Fine Tree	15,56
Tree	99,9915	Medium Tree	11,65
Tree	99,9915	Coarse Tree	9,53
Discriminant	91,0175	Linear Discriminant	16,14
Discriminant	99,6296	Quadratic Discriminant	5,42
Efficient Logistic		Efficient Logistic	
Regression	99,9617	Regression	11,36
Efficient Linear SVM	99,9617	Efficient Linear SVM	8,19
Naive Bayes	99,6296	Gaussian Naive Bayes	5,03
Naive Bayes	99,8723	Kernel Naive Bayes	40,18
SVM	99,9872	Linear SVM	27,98
SVM	75,0319	Quadratic SVM	5491,74
SVM	51,4474	Cubic SVM	9496,84
SVM	99,9574	Fine Gaussian SVM	54,78
SVM	99,9574	Medium Gaussian SVM	71,37
SVM	99,7659	Coarse Gaussian SVM	88,46
KNN	99,9915	Fine KNN	74,46
KNN	99,9787	Medium KNN	76,28
KNN	99,9702	Coarse KNN	80,21
KNN	63,7122	Cosine KNN	89,89
KNN	99,9787	Cubic KNN	92,61
KNN	99,9915	Weighted KNN	92,08
Ensemble	77,0498	Boosted Trees	95,48
Ensemble	99,9872	Bagged Trees	112,18
Ensemble	91,0175	Subspace Discriminant	107,96
Ensemble	99,9915	Subspace KNN	138,52
Ensemble	93,0949	RUSBoosted Trees	114,68
Neural Network	99,9915	Narrow Neural Network	125,85
Neural Network	99,9915	Medium Neural Network	137,30
Neural Network	99,9915	Wide Neural Network	171,74
Neural Network	99,9957	Bilayered Neural Network	157,15
Neural Network	99,9957	Trilayered Neural Network	196,43
Kernel	79,6679	SVM Kernel	185,87
Kernel	79,1997	Logistic Regression Kernel	193,06

**Anexo 15.** Clasificadores entrenados para el *dataset* de *B. cockerelli* S.-Elevación

<b>Tipo de Modelo</b>	<b>Accuracy % (Validación)</b>	<b>Algoritmo</b>	<b>Tiempo de entrenamiento (seg)</b>
Tree	99,9569	Fine Tree	4,32
Tree	99,9569	Medium Tree	2,95
Tree	99,9569	Coarse Tree	6,31
Discriminant	62,1607	Linear Discriminant	2,85
Discriminant	93,2141	Quadratic Discriminant	1,36
Efficient Logistic Regression	57,9276	Efficient Logistic Regression	2,57
Efficient Linear SVM	63,1947	Efficient Linear SVM	4,90
Naive Bayes	93,2141	Gaussian Naive Bayes	3,54
Naive Bayes	98,9660	Kernel Naive Bayes	7,04
SVM	74,1922	Linear SVM	1037,37
SVM	98,0181	Quadratic SVM	207,94
SVM	67,4063	Cubic SVM	1112,35
SVM	99,9138	Fine Gaussian SVM	9,69
SVM	99,8923	Medium Gaussian SVM	13,30
SVM	94,9591	Coarse Gaussian SVM	15,82
KNN	99,9461	Fine KNN	4,27
KNN	99,9246	Medium KNN	3,99
KNN	99,8815	Coarse KNN	4,57
KNN	57,9276	Cosine KNN	4,29
KNN	99,9246	Cubic KNN	5,18
KNN	99,9461	Weighted KNN	4,96
Ensemble	57,9276	Boosted Trees	6,80
Ensemble	99,9569	Bagged Trees	11,43
Ensemble	62,1607	Subspace Discriminant	11,19
Ensemble	99,9461	Subspace KNN	17,35
Ensemble	91,4800	RUSBoosted Trees	13,87
Neural Network	99,9354	Narrow Neural Network	14,78
Neural Network	99,9354	Medium Neural Network	14,15
Neural Network	99,9461	Wide Neural Network	19,34
Neural Network	99,9892	Bilayered Neural Network	21,62
Neural Network	99,9461	Trilayered Neural Network	31,00
Kernel	57,9276	SVM Kernel	17,92
Kernel	57,9276	Logistic Regression Kernel	19,38


**Anexo 16.** Clasificadores entrenados para el *dataset* de *F. occidentalis*-Elevación

<b>Tipo de Modelo</b>	<b>Accuracy % (Validación)</b>	<b>Algoritmo</b>	<b>Tiempo de entrenamiento (seg)</b>
Tree	99,9892	Fine Tree	5,26
Tree	99,9892	Medium Tree	4,77
Tree	99,9892	Coarse Tree	3,87
Discriminant	54,9978	Linear Discriminant	3,68
Discriminant	90,2413	Quadratic Discriminant	3,45
Efficient Logistic Regression	38,6687	Efficient Logistic Regression	5,02
Efficient Linear SVM	43,4403	Efficient Linear SVM	4,87
Naive Bayes	90,2413	Gaussian Naive Bayes	3,14
Naive Bayes	97,7057	Kernel Naive Bayes	4,71
SVM	44,0543	Linear SVM	1500,50
SVM	99,9892	Quadratic SVM	8,95
SVM	33,2723	Cubic SVM	1297,24
SVM	99,9031	Fine Gaussian SVM	9,66
SVM	99,9031	Medium Gaussian SVM	12,15
SVM	96,9948	Coarse Gaussian SVM	14,01
KNN	99,9892	Fine KNN	1,99
KNN	99,9677	Medium KNN	1,79
KNN	99,8600	Coarse KNN	2,67
KNN	37,2146	Cosine KNN	2,50
KNN	99,9677	Cubic KNN	3,23
KNN	99,9892	Weighted KNN	2,50
Ensemble	38,6687	Boosted Trees	4,04
Ensemble	99,9892	Bagged Trees	10,41
Ensemble	54,9978	Subspace Discriminant	9,68
Ensemble	99,9892	Subspace KNN	16,36
Ensemble	44,8083	RUSBoosted Trees	9,44
Neural Network	96,9625	Narrow Neural Network	13,30
Neural Network	99,9892	Medium Neural Network	12,37
Neural Network	99,9892	Wide Neural Network	14,02
Neural Network	100,0000	Bilayered Neural Network	19,39
Neural Network	99,9892	Trilayered Neural Network	33,45
Kernel	38,6687	SVM Kernel	13,61
Kernel	38,6687	Logistic Regression Kernel	13,98

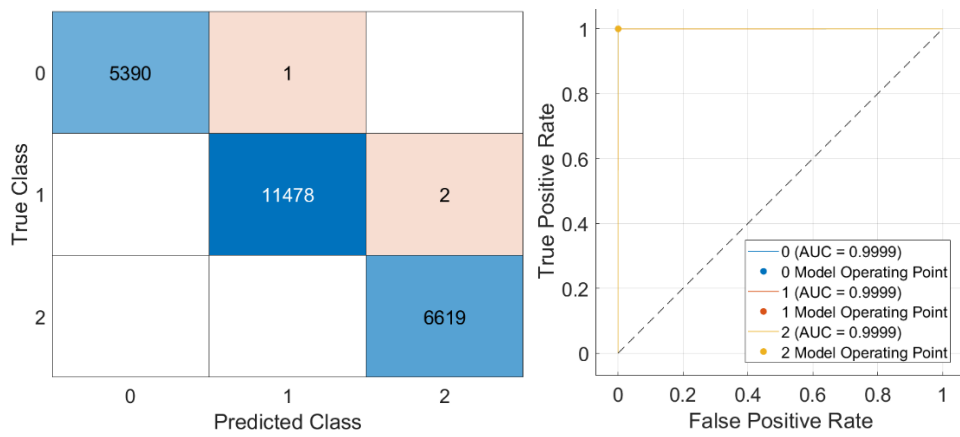
**Anexo 17.** Clasificadores entrenados para el *dataset* de *B. cockerelli* S. y *F. occidentalis*-Elevación

<b>Tipo de Modelo</b>	<b>Accuracy % (Validación)</b>	<b>Algoritmo</b>	<b>Tiempo de entrenamiento (seg)</b>
Tree	99,9785	Fine Tree	1,46
Tree	99,9785	Medium Tree	0,95
Tree	99,9785	Coarse Tree	0,67
Discriminant	76,0771	Linear Discriminant	3,65
Discriminant	94,3236	Quadratic Discriminant	3,54
Efficient Logistic		Efficient Logistic	
Regression	70,7777	Regression	6,99
Efficient Linear SVM	76,7880	Efficient Linear SVM	2,02
Naive Bayes	94,3236	Gaussian Naive Bayes	1,68
Naive Bayes	99,2460	Kernel Naive Bayes	4,28
SVM	67,8048	Linear SVM	690,84
SVM	99,6769	Quadratic SVM	379,29
SVM	53,3822	Cubic SVM	1604,25
SVM	99,9461	Fine Gaussian SVM	11,09
SVM	99,8492	Medium Gaussian SVM	10,07
SVM	94,5821	Coarse Gaussian SVM	11,47
KNN	99,9785	Fine KNN	3,83
KNN	99,9892	Medium KNN	2,04
KNN	99,8600	Coarse KNN	3,23
KNN	70,7777	Cosine KNN	3,02
KNN	99,9892	Cubic KNN	3,75
KNN	99,9785	Weighted KNN	3,57
Ensemble	70,7777	Boosted Trees	3,86
Ensemble	99,9785	Bagged Trees	7,39
Ensemble	76,0771	Subspace Discriminant	7,07
Ensemble	99,9785	Subspace KNN	12,69
Ensemble	99,9569	RUSBoosted Trees	7,35
Neural Network	99,9677	Narrow Neural Network	5,21
Neural Network	99,9785	Medium Neural Network	6,53
Neural Network	99,9785	Wide Neural Network	8,96
Neural Network	99,9785	Bilayered Neural Network	8,71
Neural Network	99,9677	Trilayered Neural Network	13,28
Kernel	70,7777	SVM Kernel	8,40
Kernel	70,7777	Logistic Regression Kernel	9,60


**Anexo 18.** Métricas de validación para el *dataset* de *B. cockerelli* S.–Temperatura



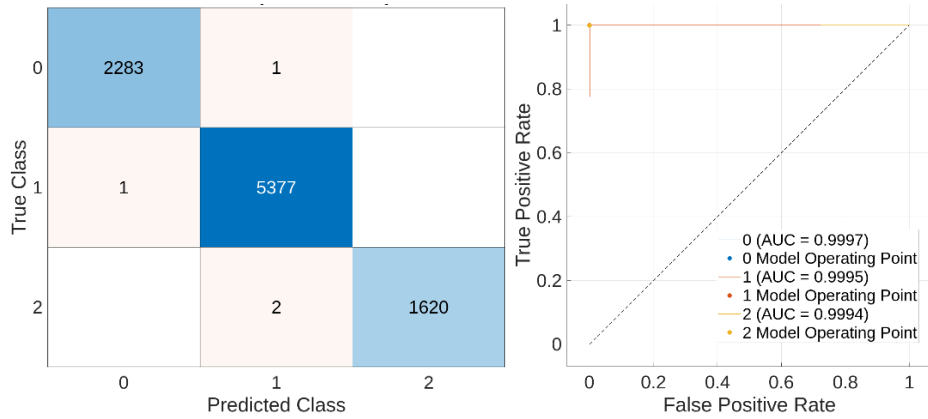
**Anexo 19.** Métricas de validación para el *dataset* de *F. occidentalis*-Temperatura




**Anexo 20.** Métricas de validación para *B. cockerelli* S. y *F. occidentalis*-Temperatura




**Anexo 21.** Métricas de validación para el *dataset* de *B. cockerelli S.*-Elevación



**Anexo 22.** Métricas de validación para el *dataset* de *F. occidentalis*-Elevación




**Anexo 23.** Métricas de validación para *B. cockerelli S.* y *F. occidentalis*-Elevación







**Anexo 24. Clases predichas con “Medium Tree” para *B. cockerelli* S.**




**Anexo 25. Clases predichas con “Medium Tree” para *F. occidentalis***




**Anexo 26. Clases predichas con “Medium Tree” para *B. cockerelli* S. y *F. occidentalis***




Anexo 27. Riesgo de presencia de *B. cockerelli* S. en 1990 en función a la temperatura y elevación.




Anexo 28. Riesgo de presencia de *B. cockerelli* S. en 2020 en función a la temperatura y elevación.




Anexo 29. Riesgo de presencia de *B. cockerelli* S. en 2060 bajo el escenario SSP245 en función a la temperatura y elevación.




Anexo 30. Riesgo de presencia de *B. cockerelli* S. en 2060 bajo el escenario SSP585 en función a la temperatura y elevación.




Anexo 31. Riesgo de presencia de *F. occidentalis* en 1990 en función a la temperatura y elevación.



Anexo 32. Riesgo de presencia de *F. occidentalis* en 2020 en función a la temperatura y elevación.




Anexo 33. Riesgo de presencia de *F. occidentalis* en 2060 bajo el escenario SSP245 en función a la temperatura y elevación.







**Anexo 34.** Riesgo de presencia de *F. occidentalis* en 2060 bajo el escenario SSP585 en función a la temperatura y elevación.




Anexo 35. Probable distribución de *B. cockerelli* S. y *F. occidentalis* en 1990 en función a la temperatura y elevación.




Anexo 36. Riesgo de presencia de *B. cockerelli* S. y *F. occidentalis* en 2020 en función a la temperatura y elevación.



**Anexo 37.** Riesgo de presencia de *B. cockerelli* S. y *F. occidentalis* en 2060 bajo el escenario SSP245 en función a la temperatura y elevación.



**Anexo 38.** Riesgo de presencia de *B. cockerelli* S. y *F. occidentalis* en 2060 bajo el escenario SSP585 en función a la temperatura y elevación.



## Anexo 39. Encuesta

### Cuestionario

Nombre y apellido:..... Edad:.....

Cédula de identidad:..... Género:.....

Sitio de encuesta:.....

1. ¿Durante los últimos tres años usted ha sembrado aguacate?  
Si  No
2. ¿Durante los últimos tres años usted ha sembrado fréjol? <sup>[00]</sup>  
Si  No
3. ¿Durante los últimos tres años usted ha sembrado papa?  
Si  No
4. ¿Durante los últimos tres años usted ha sembrado otro producto que no se haya mencionado ya?  
Si  No
5. ¿El cultivo tiene más de 5 hectáreas cultivadas?  
Si  No
6. ¿El cultivo genera menos de 10 000 \$ anuales?  
Si  No
7. ¿Usted ha tenido problemas de escasez de riego en el cultivo?  
Si  No
8. ¿Usted ha tenido problemas de baja calidad del suelo en el cultivo?  
Si  No
9. ¿Usted ha tenido problemas con la variación del clima en el cultivo?  
Si  No
10. ¿Usted ha tenido problemas de plagas y enfermedades en el cultivo?  
Si  No
11. En los últimos tres años, ¿observó usted a *Bactericera cockerelli* dentro de su lote?  
Si  No
12. En los últimos tres años, ¿observó usted a *Frankliniella occidentalis* dentro de su lote?  
Si  No
13. En los últimos tres años, ¿usted observó a ambas especies dentro de su lote?  
Si  No
14. ¿Usted ha observado un daño indirecto (vector de otras plaga y enfermedades) en el cultivo a causa de estas plagas?  
Si  No
15. ¿Usted ha observado estrés en las plantas a causa de estas plagas en el cultivo?  
Si  No
16. ¿Usted ha observado pérdida de rendimiento de su cultivo a causa de estas plagas?  
Si  No
17. ¿Usted ha observado daño estético en las plantas a causa de estas plagas en el cultivo?  
Si  No
18. ¿Usted ha sufrido pérdidas económicas a causa de estas plagas en el cultivo?  
Si  No
19. ¿La etapa en la que se presentaron las especies fue en la germinación y emergencia de las plantas?  
Si  No
20. ¿La etapa en la que se presentaron las especies fue en el crecimiento vegetativo (hojas, tallos y raíces)?  
Si  No

21. ¿La etapa en la que se presentaron las especies fue en la floración?

Si  No

23. ¿La etapa en la que se presentaron las especies fue en la maduración?

Si  No

25. ¿Usted emplea un control químico para estas plagas?

Si  No

27. Usted ha observado algún desarrollo de resistencia de dichas plagas a las estrategias y/o productos que usa para su control?

Si  No

29. ¿Usted considera que el cambio climático influye en la propagación y afección de las plagas hacia sus cultivos?

Si  No

22. ¿La etapa en la que se presentaron las especies fue en el cuajado (desarrollo de frutos y vainas a partir de flores fecundadas y formación de tubérculos)?

Si  No

24. ¿Usted emplea un control biológico para estas plagas?

Si  No

26. ¿Usted emplea un manejo integrado de plagas?

Si  No

28. ¿Ha recibido algún tipo de ayuda por parte de instituciones estatales?

Si  No

## Anexo 40. Códigos

```
1 ## DESCARGA, LECTURA Y PROCESAMIENTO DE DATOS DE TERRACLIMATE ##
2- # Cargar librerías -----
3 install.packages('pacman')
4 require(pacman)
5 pacman::p_load(terra, fs, sf, geodata, remotes, rnatulearnthdata, rnatulearnth, tidyverse, gtools, lubridate, ggspatial, glue, RColorBrewer, ggpubr, cowplot)
6
7 g <- gc(reset = TRUE)
8 rm(list = ls())
9 options(scipen = 999, warn = -1)
10 |
11- # Cargar datos - Area de estudio -----
12
13 area <- terra::vect('./shp/area_interp.shp')
14 area <- terra::project(area, 'EPSG:4326')
15
16 ecul <- gadm(country = 'ECU', level = 1, path = './tmp/')
17 ecul <- ecul[ecul$NAME_1 != 'Galápagos',]
18
19 # A simple plot
20 plot(ecul)
21 plot(area, border = 'red', add = TRUE)
22
23- # Instalar climater -----
24 remotes::install_github("mikejohnson51/climater")
25 library(climater)
26
27- # Descargar datasets -----
28
29 # Variables:
30 # Temperatura máxima
31 # Temperatura mínima
32
33 # Maximum temperature
34 tmax <- climater::getTerraClim(AOI = area,
35                               varname = 'tmax',
36                               startDate = '1991-01-01',
37                               endDate = '2020-12-31')
38 tmax <- tmax$tmax
39
40 # Minimum temperature
101 Cargar librerías | R Script 2
```

```

39
40 # Minimum temperature
41 tmin <- climateR::getTerraClim(AOI = area,
42                               varname = 'tmin',
43                               startDate = '1991-01-01',
44                               endDate = '2020-12-31')
45 tmin <- tmin$tmin
46
47 # Check the number of layers
48 map_dbl(list(tmax, tmin), nlyr)
49
50 # Generar rasters mensuales -----
51
52 # To create folders
53 dout <- './tif/terraclimate/area/5km'
54 dir_create(dout)
55
56 dirs <- paste(dout, c('tmax', 'tmin'), sep = '/')
57 dir_create(dirs)
58
59 # To write
60 map(x = 1:nlyr(tmax), .f = function(r){
61   |
62   |   cat('To write: ', r, '\t')
63   |
64   |   # Get the date
65   |   date <- tmax[[r]]
66   |   date <- time(date)
67   |   date <- as.character(date)
68   |
69   |   # To write
70   |   terra::writeRaster(x = tmax[[r]], filename = glue('{dout}/tmax/tmax_{date}.tif'), overwrite = TRUE)
71   |   terra::writeRaster(x = tmin[[r]], filename = glue('{dout}/tmin/tmin_{date}.tif'), overwrite = TRUE)
72   |
73   |   cat('Done!\n')
74   |
75 -}}
76
77 res(tmax)
78 res(tmin)
79
80 Cargar datos - Área de estudio

```

```

75 -}}
76
77 res(tmax)
78 res(tmin)
79 res.km <- 0.041*111.11
80
81 # Generación de temperatura media -----
82 dirs.bsln <- dir_ls('./tif/terraclimate/area/5km') %>% as.character()
83 tmax.bsln <- grep('tmax', dirs.bsln, value = T) %>%
84   dir_ls(., regexp = '.tifs') %>%
85   as.character() %>%
86   grep(paste0(1991:2020, collapse = '|'), .., value = T) %>%
87   rast()
88 tmin.bsln <- grep('tmin', dirs.bsln, value = T) %>%
89   dir_ls(., regexp = '.tifs') %>%
90   as.character() %>%
91   grep(paste0(1991:2020, collapse = '|'), .., value = T) %>%
92   rast()
93
94 ## To calculate the average temperature
95 tmean <- (tmax.bsln + tmin.bsln) / 2
96
97 # To write
98 map(x = 1:nlyr(tmean), .f = function(r){
99   |
100  |   cat('To write: ', r, '\t')
101  |
102  |   # Get the date
103  |   date <- tmean[[r]]
104  |   date <- time(date)
105  |   date <- as.character(date)
106  |
107  |   # To write
108  |   terra::writeRaster(x = tmean[[r]], filename = glue('{dout}/tmean/tmean_{date}.tif'), overwrite = TRUE)
109  |
110  |   cat('Done!\n')
111  |
112 -}}
113
114
1013

```



**Anexo 41.** Registro fotográfico de salidas de campo

**Anexo 41.1** Encuestas realizadas en el sector Yuracruz (cantón Ibarra)



**Anexo 41.2** Registro del uso de productos químicos agrícolas para cultivos de fréjol y papa



**Anexo 41.3** Recorrido por los predios de cultivos en la parroquia San Pablo del Lago (cantón Otavalo)



**Anexo 41.4** Consecuencias de problemas generales y de las plagas en los cultivos de aguacate y fréjol

