



UNIVERSIDAD DE PIURA

FACULTAD DE INGENIERÍA

Modelos matemáticos para la predicción de trips de la mancha roja en plantaciones de banano orgánico a partir de variables atmosféricas - Buenos Aires, Morropón

Tesis para optar el Título de
Ingeniero Mecánico - Eléctrico

Carlos Alberto Estrada Macalupú

Asesor:
Mgtr. Ing. José José Manrique Silupú

Piura, junio de 2022



Dedicatoria

El presente trabajo está dedicado primeramente a Dios, por permitirme culminar esta meta, a mis padres por su apoyo incondicional en todo momento, al Dr. William Ipanaqué Alama, al Mgtr. José Manrique Silupú y al Ing. Ítalo Chinchay Ulloa que fueron motores importantes a lo largo de mi carrera profesional. Y finalmente a mis abuelitos Cruz y Manuela quienes no lograron ver la culminación de este objetivo, pero donde sea que estén, sé que se encuentran muy orgullosos.





Agradecimientos

El presente trabajo de investigación fue ejecutado en el marco del proyecto “Transformación Digital del sector Agro-Industrial aplicado al banano orgánico”, financiado por ProCiencia y el Banco Mundial a través de su unidad ejecutora FONDECYT, bajo el contrato N° 165-2018-FONDECYT-BM-IADTAV, en colaboración con la Universidad de Piura y la asociación de agricultores ASPROBO.





Resumen

La presente tesis tiene como objetivo la obtención de modelos matemáticos que describan el comportamiento del crecimiento poblacional de los trips de la mancha roja en plantaciones de banano orgánico. Dicho estudio parte con el desarrollo de un modelo implementando el denominado “modelo de Campbell”, que es una expresión lineal que describe el crecimiento poblacional de los insectos respecto a la temperatura. Posteriormente se presenta una mejora de dicho modelo con la implementación de otros parámetros meteorológicos, como la humedad, la velocidad del viento y la lluvia.

Luego del desarrollo de los modelos se procede a realizar las simulaciones con los datos reales para la obtención de los coeficientes desconocidos del modelo, para eso se ha desarrollado un algoritmo en Python que estima los coeficientes, de tal forma se llegan a modelar dos ecuaciones diferenciales de primer orden que describen el comportamiento de la cantidad poblacional de trips de la mancha roja. Dichos modelos se validan y se también se analiza su posterior uso como modelos de predicción.

Finalmente se comparan las métricas o resultados de ambos modelos donde se verifica si los resultados del modelo propuesto son mejores que los resultados obtenidos del modelo de Campbell.



Tabla de contenido

Introducción	17
Capítulo 1 Generalidades	19
1.1 Antecedentes	19
1.2 Banano.....	20
1.2.1 Conceptos generales	20
1.2.2 Producción de banano orgánico en el mundo	23
1.2.3 Producción de banano orgánico en Piura-Perú	25
1.3 Plagas presentes en el banano orgánico.....	28
1.3.1 Principales tipos de plagas presentes en el valle del Chira.....	29
1.4 Agricultura inteligente (Smart Farming) en la producción de banano orgánico	34
1.4.1 Vehículos aéreos no tripulados (UAVs).....	34
1.4.2 Big data.....	35
1.4.3 Internet de las cosas (IoT)	35
Capítulo 2 Adquisición de datos de entrada y salida	37
2.1 Lugar de investigación.....	37
2.2 Equipos	37
2.2.1 Variables medidas por la red de sensores IoT	40
2.3 Metodología	41
2.4 Datos de entrada	42
2.4.1 Temperatura.....	42

2.4.2 Humedad relativa	42
2.4.3 Lluvia.....	42
2.4.4 Velocidad del viento.....	43
2.4.5 Fumigaciones.....	43
2.4.6 Limpieza de la parcela	43
2.5 Las evaluaciones de plagas y los datos de salida	43
Capítulo 3 Modelación matemática	47
3.1 Modelo del crecimiento poblacional de insectos (Modelo de Murray)	47
3.1.1 Implementación del modelo de Murray:	48
3.2 Modelo de Campbell (MC)	50
3.3 Modelo de Campbell modificado (MCM).....	51
3.4 Ecuaciones obtenidas.....	52
3.5 Algoritmo desarrollado en Python.....	53
Capítulo 4 Simulaciones y resultados.....	55
4.1 Simulaciones de los modelos	55
4.1.1 MM1	55
4.1.2 MM2	59
4.1.3 Comparación de los modelos con los datos reales	63
4.2 Validación de los modelos con nuevos datos	64
4.3 Separación de la incidencia de los trips por clases	64
4.4 Paper EIRCON	66
Conclusiones.....	71
Referencias bibliográficas.....	73
Apéndices	77
Apéndice A. Algoritmo MM1.....	79
Apéndice B. Algoritmo MM2.....	85

Anexos	92
Anexo A. Formato de reporte de plagas	94





Lista de figuras

Figura 1. Partes de la planta de banano.....	20
Figura 2. Producción mundial de banano y superficie cosechada, 2008-2017.....	23
Figura 3. Exportación mundial de banano por región 2015-2019.	24
Figura 4. Distribución de las importaciones netas mundiales por mercado, 2020	25
Figura 5. Evolución de las exportaciones del banano orgánico peruano.	27
Figura 6. Diferentes estados biológicos de la arañita roja, (A) huevo, (B) larva, (C) Ninfa y (D) Adulto.	29
Figura 7. Ceramidia adulta	29
Figura 8. Cochinilla en el pseudotallo.....	30
Figura 9. Presencia de escamas en el fruto.....	30
Figura 10. Imagen de un huevo en el envés de la hoja.....	31
Figura 11. Picudo negro.....	32
Figura 12. Galerías ocasionadas por las larvas del picudo.....	32
Figura 13. Efectos de los trips en el pseudotallo	33
Figura 14. Efecto de los trips de la mancha roja en el fruto	33
Figura 15. Índice NDVI, muestra diferentes estados de maduración y ausencia de vegetación en maíz	35
Figura 16. Parcela utilizada para la investigación.	37
Figura 17. Ubicación de la red de sensores en la parcela	38
Figura 18. Estación central	39
Figura 19. Nodo 1	39
Figura 20. Nodo 2	40
Figura 21. Realización de evaluación de plagas en la parcela.....	44

Figura 22. Evaluación de plagas de 25 plantas.....	44
Figura 23. Gráfico del comportamiento de los trips	45
Figura 24. Relación entre la tasa de desarrollo de los insectos y la temperatura.	51
Figura 25. Diagrama de flujo	53
Figura 26. Valores de "a" y "b" obtenido de los 100 conjuntos	56
Figura 27. Valores de "mu" y "alfa1" obtenido de los 100 conjuntos	56
Figura 28. Valores de "alfa2" y "gamma" obtenido de los 100 conjuntos.....	56
Figura 29. Valores de "Degradación de la fumigación 1" y "Degradación de la fumigación 2" obtenido de los 100 conjuntos.....	57
Figura 30. Valor de "Degradación de la limpieza" obtenido de los 100 conjuntos	57
Figura 31. R-cuadrado de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)	58
Figura 32. RMSE de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)	59
Figura 33. Valor de "a" y "b" obtenido de los 100 conjuntos	59
Figura 34. Valor de "C" y "D" obtenido de los 100 conjuntos.....	59
Figura 35. Valor de "E" y "mu" obtenido de los 100 conjuntos	60
Figura 36. Valor de "alfa1" y "alfa2" obtenido de los 100 conjuntos	60
Figura 37. Valor de "gamma" y "Degradación de la fumigación 1" obtenido de los 100 conjuntos.....	60
Figura 38. Valor de " Degradación de fumigación 2" y "Degradación de la limpieza" obtenido de los 100 conjuntos	61
Figura 39. R-cuadrado de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)	62
Figura 40. RMSE de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)	62
Figura 41. Comparación de los modelos con los datos experimentales usados para el desarrollo	63
Figura 42. Validación de los modelos matemáticos.....	64

Lista de tablas

Tabla 1. Información nutricional – banano entre 18 a 20 cm de largo.....	21
Tabla 2. Mayores productores de banano 2008-2017 (Millones de toneladas métricas).....	24
Tabla 3. Principales exportadores de banano, 2008-2017 (Millones de toneladas métricas)	24
Tabla 4. Zonas de producción de banano en la región norte del Perú.	26
Tabla 5: Datos de las exportaciones de banano orgánico y variación % anual	27
Tabla 6: Exportaciones de la campaña 2017/2018 de banano orgánico	28
Tabla 7. <i>Variables meteorológicas – Estación central</i>	40
Tabla 8. Variables meteorológicas - Nodo	41
Tabla 9. Ecuaciones matemáticas obtenidas	53
Tabla 10. Valores promedios de los parámetros de MM1.....	57
Tabla 11. Valores promedios de los parámetros de MM2.....	61
Tabla 12. Comparación de los resultados promedios de R-cuadrado de MM1 y MM2	63
Tabla 13. Comparación de los resultados promedios de RMSE de MM1 y MM2	63
Tabla 14. Métricas obtenidas en la validación	64
Tabla 15. División de las clases de las plagas	65



Introducción

La agroindustria en el Perú está poco desarrollada y se siguen manteniendo las técnicas y los métodos tradicionales debido a la poca importancia que se le da; siendo este sector clave en el desarrollo económico y la disminución de la pobreza en el país (MINAGRI, 2014). Gracias a los avances tecnológicos, la agricultura inteligente se ha vuelto una tendencia, en especial en los sectores en pleno crecimiento como la exportación del banano orgánico en Piura donde la exportación ha crecido significativamente lográndose exportar en distintos países como Alemania, Bélgica, España, Finlandia, Inglaterra, Corea del Sur y China lo cual impulsa a los agricultores a recurrir en la búsqueda de alternativas que solucionen sus principales problemas. Una de las soluciones es la denominada SMART FARMING (Agricultura inteligente), que consiste en utilizar la tecnología a disposición para tratar de mejorar el crecimiento y la producción como también evitar plagas en los campos. Siendo los trips de la mancha roja una de las principales plagas a las cuales se les atribuye una pérdida del rendimiento de producción entre 30 y 40% (M. Lopez, 2021), incluso el 100% si los agricultores no toman medidas efectivas.

Los trips de la mancha roja dañan la calidad de la fruta al concentrarse entre los dedos del racimo para su alimentación y reproducción, ocasionando una coloración café-rojiza. El impacto en la producción es muy significativo especialmente en el banano de exportación por las altas exigencias de calidad.

En la actualidad existen varios productos (orgánicos) que ayudan a controlar esta plaga, pero depende mucho del nivel de incidencia presente en la parcela pues si la parcela se encuentra infectada, se necesita aplicar de manera correctiva y el producto necesario puede costar entre 7 u 8 veces el valor de un producto que se utiliza de manera preventiva. En conclusión, para los agricultores es perjudicial un contagio total de sus parcelas pues, además de perder de manera parcial o total su producción, también el costo para recuperarlas se incrementa por lo que es relevante conocer el comportamiento de esta plaga y las variables climáticas que ayudan en su crecimiento para una mejor toma de decisiones por parte de los agricultores y de tal manera se podrá evitar en lo posible la reducción de la productividad de las parcelas. Por tal motivo, en esta investigación se modelan ecuaciones matemáticas que describe la incidencia de los trips de una parcela de cultivo de banano orgánico teniendo como entradas las variables climáticas registradas por una estación meteorológica como

temperatura del ambiente, humedad relativa, velocidad del viento y lluvia. En base a estos datos se puede conocer el comportamiento de los trips en el tiempo y posteriormente se puedan implementar algoritmos de predicción que ayuden a los agricultores a tomar medidas de prevención.

Esta investigación está dividida en 5 capítulos, el primer capítulo se explica los antecedentes y lo concerniente al cultivo de banano orgánico, además el lector se podrá relacionar con términos que más adelante serán utilizados. En el capítulo 2 corresponde al estudio de los datos utilizados como entrada y salida. Posteriormente se desarrollan en el capítulo 3 la modelación matemática de manera detallada.

Luego en el capítulo 4 se simulan los modelos y se analizan los resultados obtenidos, para eso se comparan las métricas como el R-cuadrado y el RMSE.



Capítulo 1

Generalidades

1.1 Antecedentes

En la literatura científica se han desarrollado propuestas de modelos lineales y no lineales para describir el desarrollo de *Spodoptera litura* (Fabricius) de la soya debido a que es una de las principales plagas causantes de pérdidas económicas. Con los modelos se pudo estimar la temperatura óptima para el desarrollo de dicha plaga como también el umbral superior. Además, se pudo realizar el modelo de fenología basadas en las temperaturas umbrales de desarrollo que fueron estimadas (Prasad, y otros, 2021).

También se ha evaluado el efecto de los parámetros meteorológicos en el cultivo de girasol mediante análisis de datos de cultivos desde el año 2003-2017, en tres lugares distintos donde se desarrollaron reglas semanales y mensuales para la predicción potencial del cultivo de girasol. Dichas reglas climáticas se utilizaron para la comparación de los datos reales y la evaluación del efecto de los parámetros meteorológicos (Singh & Kaur, 2021).

La Universidad de Piura (UDEP), en los últimos años han desarrollado modelos de predicción que se basan en algoritmos de machine learning como regresión logística y SVM, que estiman el nivel futuro de incidencia de los trips de la mancha roja por clases (baja o media). Los datos de entrada de los modelos son variables climáticas que son registrados por una estación meteorológica. Los resultados muestran una precisión del 79% con los datos de prueba (Almeyda, Paiva, & Ipanaqué, 2020). De igual manera en (Manrique Silupu, Campos, Paiva, & Ipanaqué, 2021) se desarrollan modelos de Machine learning donde se obtuvieron precisiones altas. Con estas investigaciones se busca ayudar a los productores a mejorar la gestión de control de plagas.

También en (Almeyda & Ipanaque, 2022) que resume las recientes investigaciones que involucran IA (Inteligencia Artificial) en las etapas de la cadena de suministro del banano como pre-cosecha, cosecha, post-cosecha, procesamiento y venta. Cubriendo literatura publicada del 2015 hasta 2020, siendo un total de 52 estudios más importantes que se realizaron en 23 países. En dichas investigaciones se han realizado muchas funcionalidades de algoritmos de aprendizaje como ANN, CNN, SVM y KNN.

1.2 Banano

1.2.1 Conceptos generales

El banano pertenece a la familia de las musáceas y es actualmente muy cotizado en los mercados internacionales como Europa, Asia y América del Norte donde es reconocido por su calidad y sabor (Guzmán Velásquez, 2014). Aunque se ha citado en varias ocasiones que el lugar de origen se centra en América Central la mayoría coincide que esta fruta es originaria del sudeste asiático más concretamente en la India. Las partes de la planta de banano se muestran en la siguiente figura.




Figura 1. Partes de la planta de banano.

Fuente: Tomado de “Guía práctica para el manejo de banano orgánico en el valle del Chira” (Torres, 2012).

Se estima que existen en el mundo más de 1000 variedades de banano, pero es la variedad Cavendish el más común y el más exportado. El fruto de dicha variedad es dulce y no posee semillas. Según análisis, de cada 100 gramos de fruta se obtienen 400 mg de potasio, que en comparación a otros alimentos equivalen a cantidades similares presentes en legumbres cocinadas, carne o pescado. Además, un consumo frecuente de banano trae beneficios para la salud como la regulación de la presión arterial y de la actividad del corazón,

de tal forma las personas que lo consumen tienen 27% menos riesgo de padecer enfermedades cardíacas (FAO, 2016).

En la siguiente imagen se muestran la información nutricional de un banano mediano de 18 a 20 cm de largo.

Tabla 1. Información nutricional – banano entre 18 a 20 cm de largo

Energía	349 kJ 105kcal
Proteína	1.29g
Carbohidratos	26.95g
• Fibra	3.1g
• Azúcar	14.43g
Grasa	0.39g
• Grasa saturada	0.132g
• Grasa Poli insaturada	0.086g
• Grasa Mono insaturada	0.038g
Colesterol	0mg
Sodio	1mg
Potasio	422mg

Fuente: Tomado de “Fatsecret”, (fatsecret, 2022)

El banano contiene fuentes de vitaminas y minerales, también es rico en fibras, aunque pobre en lípidos. Con respecto a los minerales es rico en potasio, fósforo calcio, magnesio. También contiene antioxidante como la dopamina y vitaminas del grupo B que se encuentran presentes en el reino vegetal (INFOCOM, 2000).

1.2.1.1 Fases fenológicas del cultivo de banano. Todo el ciclo fenológico se divide en 3 etapas:

1.2.1.1.1 Fase infantil. Dura aproximadamente 104 días y empieza cuando aparecen los retoños o llamadas hijos. Se estima que durante los 3 primeros meses el desarrollo del hijo está influenciado por la planta madre y alcanza una altura aproximada de 50cm y empieza a independizarse de la madre cuando empieza a desarrollar de 7.5 a 12.5 hojas, pero recién con la aparición de la primera hoja foliar con un ancho de 10cm (También llamado F10) es cuando se considera que ha concluido la etapa infantil (Vargas Céspedes, Morales, Watler, & Vignola, 2012).

1.2.1.1.2 Fase juvenil. Tiene una duración aproximada de 91 días y se considera su inicio después que la aparición de la hoja F10. Posteriormente crecen nuevas hojas hasta que aparece la hoja denominada Fm. Dicha hoja tiene dimensiones parecidas a la planta madre

apareciendo entre la hoja 13–20 y se puede presentar entre 10 y 50 días antes de la cosecha de la planta madre (Vargas Céspedes, Morales, Watler, & Vignola, 2012).

1.2.1.1.3 Fase reproductiva. Se estima que tiene una duración de más de 200 días y abarca desde la aparición de la hoja Fm hasta la cosecha del fruto. Siendo en promedio 404 días la duración de todo el ciclo fenológico donde dicho valor está definido por la variedad, la altitud y condiciones tanto del clima como del suelo de cada una de las regiones reproductivas (Vargas Céspedes, Morales, Watler, & Vignola, 2012).

1.2.1.2 Requerimientos medioambientales del banano. Es conocido por todos que tanto el clima como el suelo afectan directamente el desarrollo y crecimiento de las plantas por tal motivo se debe tener en cuenta las principales características como las que se explican a continuación.

1.2.1.2.1 Clima

- **Altitud:** Se estima que la altitud más adecuada para el desarrollo del banano se encuentra entre 0 a 30 msnm sin embargo es una planta que se puede adaptar hasta los 2200 msnm (Torres, 2012).
- **Requerimientos de agua:** Según la bibliografía la planta de banano está constituida por el 85 al 88% de agua por tal motivo es esencial un suministro mensual de 1200 – 1300 m³/ha. Es recomendable que los sembríos de banano estén en zonas que tengan entre 2000 -3000 mm de precipitación al año, aunque se considera que solo 100 mm al mes son más que suficientes. Para riegos por gravedad se recomienda una frecuencia de 15 a 20 días en la estación de verano y 20 a 25 días en la estación de invierno (Torres, 2012).
- **Temperatura:** Se considera que la temperatura óptima para un buen desarrollo del cultivo es de 25°C, aunque el buen desarrollo se mantiene en el rango de 25 a 30°C. Pero a medida que la temperatura descende el ciclo vegetativo se prolonga y si la temperatura llega por debajo de los 16°C, se paraliza la salida de hojas. En una situación extrema con un valor de temperatura de 12°C, la fructificación se detiene completamente (Torres, 2012).
- **Luminosidad:** Afecta a la duración del ciclo vegetativo, en condiciones de buena exposición a la luz el ciclo puede durar 8.5 meses sin embargo si la planta crece en penumbra el ciclo puede llegar hasta los 14 meses (Torres, 2012).
- **Vientos:** Debido a la forma de sus hojas y a la naturaleza herbácea de la planta (No está constituido de madera) no se recomienda en zonas donde la velocidad del viento llegue a valores superiores de los 200 km/hora (Torres, 2012).

1.2.1.2.2 Suelo. Las plantas de banano pueden soportar rangos de pH de 4.5 a 8 pero para mejores resultados se recomienda un pH de 6 a 7.5 (el pH ideal es de 6.5). Los suelos más

recomendables son los de textura media, como el franco arenoso, muy fino y fino hasta el franco arcilloso (Torres, 2012).

1.2.2 Producción de banano orgánico en el mundo

El banano se ha convertido en uno de los principales cultivos en la producción y el comercio agrícola mundial. Es producido por más de 130 países, por pequeños y grandes agricultores desempeñando un rol muy importante en la contribución de la seguridad alimentaria, y como fuente de ingresos debido a la exportación. Se estima que hasta el 2017 una quinta parte de la producción mundial de banano se destinaba a los mercados internacionales, dándose en ese mismo año un aumento de 15.35% pasando de 98.76 millones de toneladas métricas (MMT) en el 2008 a 113.92 MMT en 2017 cuyos factores responsables de dicho crecimiento fue el incremento del rendimiento (5.76%) que pasó de 19.11 toneladas métricas/hectárea (Tm/ha) en 2008 a 20.21 Tm/ha en 2017 y también la superficie cosechada pasó de 5.17 millones de hectáreas (Mha) en 2008 a 5.64 Mha en 2017 (Evans, Ballen, & Siddiq, 2020).




Figura 2. Producción mundial de banano y superficie cosechada, 2008-2017.

Fuente: Tomado de “Banana Production, Global Trade, Consumption Trends, Postharvest Handling, and Processing” (Evans, Ballen, & Siddiq, 2020).

Curiosamente, ninguno de los 3 principales países productores de banano como lo es India, China e Indonesia, desempeña un papel importante en el mercado internacional, como sí lo son Ecuador, Filipinas y Costa Rica que son los más grandes exportadores de banano representando alrededor del 50% de las exportaciones mundiales del 2017 (Evans, Ballen, & Siddiq, 2020).

Tabla 2. Mayores productores de banano 2008-2017 (Millones de toneladas métricas)

País	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
India	26.2	26.5	29.8	28.5	26.5	27.6	29.7	29.2	29.1	30.5
China	7.8	8.8	9.6	10.4	11.6	12.1	11.8	12.5	13.1	11.2
Indonesia	6	6.4	5.8	6.1	6.2	6.3	6.9	9.5	7	7.2
Brasil	7	6.8	7	7.3	6.9	6.9	7	6.8	6.8	6.7
Ecuador	6.7	7.6	7.9	7.4	7	6	6.8	7.2	6.5	6.4


Fuente: Tomado de “Banana Production, Global Trade, Consumption Trends, Postharvest Handling, and Processing” (Evans, Ballen, & Siddiq, 2020).

Tabla 3. Principales exportadores de banano, 2008-2017 (Millones de toneladas métricas)

País	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
Ecuador	5.3	5.7	5.2	5.8	5.2	5.4	5.7	6.1	6	6.4
Costa Rica	2.1	1.7	1.9	1.9	1.9	1.9	2.2	2	2.4	2.5
Guatemala	1.4	1.5	1.4	1.5	1.9	2	2.1	2.2	2.1	2.3
Colombia	1.7	1.8	1.7	1.8	1.7	1.5	1.7	1.6	1.8	1.9
Filipinas	2.2	1.7	1.6	2	2.6	3.3	3.1	1.2	1.4	2.7

Fuente: Tomado de “Banana Production, Global Trade, Consumption Trends, Postharvest Handling, and Processing” (Evans, Ballen, & Siddiq, 2020).

En el 2019 se alcanzó un máximo histórico en las exportaciones mundiales de banano (21 millones de toneladas), indicando un aumento del 10.2% en comparación al año anterior (2018). Este crecimiento es consecuencia de la oferta en el Ecuador y Filipinas, quienes son los principales exportadores donde Ecuador es el mayor productor de banano en el 2019 con 23% de los envíos mundiales. Por otro lado, también influyó el fenómeno del niño que afectó los envíos de otros proveedores clave de Costa Rica y de Republica Dominicana. En general, las exportaciones de América Latina y el Caribe presentaron un aumento del 3% en 2019, y se situaron en 15,1 millones de toneladas (FAO, Análisis del mercado del banano, 2019).

**Figura 3.** Exportación mundial de banano por región 2015-2019.

Fuente: Tomado de “Análisis del mercado del banano”, (FAO, Análisis del mercado del banano, 2019).

En el año 2020 las exportaciones mundiales de banano se mantuvieron relativamente estables alrededor de 21.5 millones de toneladas. A pesar de la crisis desatada por COVID-19 los datos indican que para el 2020 las exportaciones mundiales de mantuvieron cerca del nivel record que fue alcanzado en el año 2019 por lo que se concluye que las cadenas de suministro de banano fueron más resistentes de lo que se esperaba al inicio del COVID-19 en términos de exportación global (FAO, Banana Market Review 2020, 2021).

La Unión Europea en el año 2020 siguió siendo el mayor importador de banano con una cuota aproximada de 26%. Esto en respuesta a la preocupación de su población al COVID-19 y la importancia de una buena nutrición para apoyar al sistema inmunológico lo que hizo que el banano sea una de las frutas más populares de la Unión Europea. Esto puede ser una de las explicaciones del porque la demanda de importaciones de banano se mantuvo especialmente en algunos países más afectados por la propagación del COVID-19 (FAO, Banana Market Review 2020, 2021).




Figura 4. Distribución de las importaciones netas mundiales por mercado, 2020

Fuente: Tomado de "Banana Market Review 2020", (FAO, Banana Market Review 2020, 2021)

1.2.3 Producción de banano orgánico en Piura-Perú

El agro tiene un gran impacto en la economía regional de Piura, ya sea de manera directa por la producción o indirecta por las industrias encargadas del proceso de los cultivos tradicionales como el arroz, algodón, café, etc. Y también los no tradicionales como el limón mango, plátano, etc. En el censo del 2012 se concluyó que la región Piura cultiva una amplia variedad de alimentos en comparación de las demás regiones con una superficie aproximada de 386 777 hectáreas pertenecientes a 142 850 productores (GORE, La agricultura en Piura, 2018).

En el norte del Perú, el banano orgánico se ha convertido en una alternativa que mejora la calidad de vida de cientos de productores que se encuentran en pobreza.

Las zonas que más producen están localizadas en el norte del país (Tumbes, Piura, Lambayeque y la Libertad) pertenecientes a aproximadamente 8000 pequeños agricultores que están agrupados en asociaciones y cooperativas donde cada agricultor posee en promedio 0.9 hectáreas. La participación en dichas cooperativas les facilita un mejor acceso a la adquisición de insumos, la comercialización del producto, el acceso a información, acceso a servicios financieros y la asistencia técnica por parte de entes estatales y privados (Mifflin, Luque, Peter, & Chiaravalli, 2017).

Hasta el año 2016 eran destinadas a las 6500 hectáreas al cultivo de banano de exportación mientras que para el mercado nacional se cultivaban 13724 hectáreas. En la siguiente tabla extraída del Ministerio de agricultura se muestran la información del norte del Perú donde los datos incluyen productores y áreas cultivadas de banano con destino nacional.

Tabla 4. Zonas de producción de banano en la región norte del Perú.

Departamento	Superficie cosechada (ha)	Producción (t)	Rendimiento (kg/ha)	Precio en chacra (s././kg)	Nro. de productores
La Libertad	486	7923	16319	0.64	751
Lambayeque	604	7435	12310	0.48	805
Tumbes	4810	114856	23880	0.80	4237
Piura	14324	274342	19153	0.74	20786

Fuente: Tomado de “Innovación tecnológica en el banano orgánico” (Mifflin, Luque, Peter, & Chiaravalli, 2017).

Hasta el año 2018 se estima que el 80% de la producción del banano se encuentra ubicado en Sullana (Valle del Chira) mientras que el 20% se encuentra en el alto Piura, Paita y San Lorenzo con una cantidad aproximada de 8 500 productores (GORE, La agricultura en Piura, 2018).

Las exportaciones en el 2018 fueron de 229 511 toneladas en volumen (+14.05 %) con un valor aproximado de USD 165.34 millones en valor FOB (+12.16 %) indicando un crecimiento significativo a comparación del año anterior donde se redujeron las exportaciones en un 2.77% ocasionado por el “niño costero” que afectó las zonas de Tumbes, Lambayeque y Piura que son los principales lugares de producción de banano orgánico (Castillo Martínez & Rodríguez García, 2019).



Figura 5. Evolución de las exportaciones del banano orgánico peruano.

Fuente: Tomado de “Análisis y propuesta de mejora de la cadena de suministro de banano orgánico de las provincias de Morropón y Sullana” (Castillo Martínez & Rodríguez García, 2019).

En el año 2017 (Figura 5) hubo un decremento a comparación del año anterior a causa de los efectos del fenómeno del niño costero, los efectos del fenómeno se vieron reflejados en todos los sectores productivos, pero exclusivamente en el sector del banano orgánico se vio afectada la producción, cosecha y comercialización. Se perdieron unas 500 hectáreas y las rutas de acceso destruidas impidieron que se pueda cosechar la producción. También las plagas se incrementaron afectando al producto y también se frenaron las expectativas del crecimiento que se habían planteado para dicho año. Las pérdidas superaron los 25 millones de dólares, además de las 600 toneladas que el mercado estadounidense devolvió (RPP, 2017).

Tabla 5: Datos de las exportaciones de banano orgánico y variación % anual

AÑO	PESO NETO (toneladas)	FOB (Miles USD)	% VAR. PESO	% VAR. FOB
2000	856	264	-	-
2001	7 996	2 409	833.80 %	811.55 %
2002	18 953	6 143	137.03 %	155.03 %
2003	18 103	6 797	-4.48 %	10.65 %
2004	27 208	10 552	50.29 %	55.25 %
2005	42 852	17 589	57.50 %	66.68 %
2006	57 095	26 542	33.24 %	50.91 %
2007	64 586	30 914	13.12 %	16.47 %
2008	78 162	45 553	21.02 %	47.36 %
2009	82 510	51 322	5.56 %	12.66 %
2010	78 783	49 519	-4.52 %	-3.51 %
2011	99 804	64 146	26.68 %	29.54 %
2012	117 667	80 366	17.90 %	25.29 %
2013	124 103	88 972	5.47 %	10.71 %
2014	159 563	119 318	28.57 %	34.11 %
2015	190 415	144 397	19.34 %	21.02 %
2016	201 505	151 623	5.82 %	5.00 %
2017	201 237	147 418	-0.13 %	-2.77 %
2018	229 511	165 338	14.05 %	12.16 %

Fuente: Tomado de “Análisis y propuesta de mejora de la cadena de suministro de banano orgánico de las provincias de Morropón y Sullana” (Castillo Martínez & Rodríguez García, 2019).

En la siguiente tabla se muestra la cantidad de exportaciones de banano orgánico en la región Piura en la campaña 2017-2018, siendo este año con el mejor resultado en cantidad de toneladas exportadas y valor.

Tabla 6: Exportaciones de la campaña 2017/2018 de banano orgánico

Variables	Unidad de medida	Banano Orgánico / Campaña 2017-2018
Producción	Tm	336,934
Áreas	Has	15,477
Rendimiento/Has	Tm	21.77
Precio Chacra /Kg	s/	1.13
Exportación	\$	147'216, 147.00
Volúmenes	Tm	200,532.94
Mercados		Países bajos 42%, EEUU 23%, Alemania 13%, Bélgica 7%, Corea 5%, Finlandia 4%, otros 5%.
Líneas de comercialización		Fruta fresca
Mercado Nacional	Tm	136,161.06

Fuente: Tomado de “La agricultura en Piura” (GORE, La agricultura en Piura, 2018)

En el 2019 el envío de fruta sumó 218 246 toneladas que equivalen a US\$ 151 millones, que refleja una reducción de al menos 4% en volumen y 9% en valor con respecto al año 2018. Mientras que para el año 2020 las exportaciones sumaron 211 162 toneladas equivalentes a US\$ 148 millones. Dichos valores reflejan una caída en el envío de la fruta, que corresponden en volumen a un 3% y en valor 2% en comparación al año anterior. Sin embargo, a pesar de esa caída no hubo variación en el ranking de proveedores globales, manteniéndose el banano en el puesto 14 donde los principales países exportadores fueron, Ecuador (25%), Filipinas (14%) y Guatemala (8%). También obtuvo una participación del 2% en la canasta agroexportadora peruana siendo así el noveno producto más importante. Sin embargo, se produjo una reducción en la producción siendo consecuencia de la llegada del COVID-19, pues en el primer bimestre del año 2020, las exportaciones de banano se incrementaron 7% con respecto al año anterior pero debido a la implementación de la cuarentena que se hizo con el fin de evitar la propagación del virus, obligaron a las asociaciones y cooperativas a reducir la producción. Además, se suma el hecho de que Piura fue una de las regiones más afectadas por el virus lo que trajo consigo una oferta laboral limitada para el campo (fruit, 2021).

1.3 Plagas presentes en el banano orgánico

La planta de banano es afectada por enfermedades y plagas, que afectan el sistema radicular, pseudotallo, tallo floral y frutos. En la planta pueden ocasionar problemas de anclaje de la planta, la actividad fotosintética, etc. Lo que conlleva a consecuencias en el rendimiento y la calidad de la producción (Agrobanco, 2013).

1.3.1 Principales tipos de plagas presentes en el valle del Chira

1.3.1.1 Arañita roja. *Tetranychus urticae*, es un insecto chupador de ambientes secos, su colonización inicialmente ocurre en el envés de las hojas, se alimenta de la planta. Como consecuencia de esta plaga la hoja toma un color amarillo (manchas cloróticas) y progresivamente se va bronceando y muchas veces la hoja se seca por completo con un aspecto de quemado. Las plantas más jóvenes se ven afectadas con síntomas de parches de aclaramiento (Benavides Martinez, 2020).



Figura 6. Diferentes estados biológicos de la arañita roja, (A) huevo, (B) larva, (C) Ninfa y (D) Adulto.

Fuente: Tomado de “Sorpresivo ataque de ‘arañita roja’ en plantaciones de banano en Urabá” (Benavides Martinez, 2020).

1.3.1.2 Ceramidia. *Antichloris viridis*, es una mariposa de 4cm de envergadura alar, cuyas alas son de color azul metálico, genera aberturas en la lámina foliar llegando a afectar entre 90 y 95 cm² del tejido cuando se tiene un nivel alto de infestación (Cox Quiñonez, 2019).



Figura 7. Ceramidia adulta

Fuente: Tomado de “Identificación y manejo integrado de plagas en banano y plátano Magdalena y Urabá Colombia” (Augura, 2009).

1.3.1.3 Cochinilla. Es un hemíptero del tipo picador – succionador cuyo alimento son los fluidos que se encuentran en los tejidos vegetales. Se pueden presentar en casi todos los órganos de la planta (hoja, pseudotallo y en la fruta). Esta plaga también facilita el crecimiento de la fumagina debido a las sustancias dulces que excretan. La población aumenta en los periodos de floración (Vargas Céspedes, Morales, Watler, & Vignola, 2012). En plantaciones de banano las principales especies de esta plaga son *Planococcus citri*, *Dymecoccus brevipes*, *Pseudococcus elisae*, *Saccharicoccus sacchari* y se encuentran tanto en el suelo como en la parte basal del pseudotallo. Tienen un ciclo de vida de 50 a 81 días y la temperatura ideal para su desarrollo es de 23 a 26 °C.



Figura 8. Cochinilla en el pseudotallo.

Fuente: Tomado de “Guía práctica para el manejo de banano orgánico en el valle del Chira” (Torres, 2012).

1.3.1.4 Escamas. Es un hemíptero de tipo picador – succionador de la especie *Diaspis boisduvallii*, se alimenta de los fluidos de la planta favoreciendo al crecimiento del hongo que causa la fumagina. Esta plaga se establece en la corona, en la fruta y los dedos provocando lesiones.



Figura 9. Presencia de escamas en el fruto

Fuente: Tomado de “plantwise” (Cubillo & Gonzáles, 2014).

1.3.1.5 Mosca blanca. Poseen el aparatado bucal del tipo picador – succionador. La temperatura favorable para el desarrollo de esta plaga oscila entre 29-39°C además de condiciones secas y calientes, sin embargo, su desarrollo es afectado en condiciones frías y de lluvias fuertes.

Las moscas blancas colonizan la hoja, colocan los huevos en el envés y también en la fruta, estos huevos son al inicio alargados y blanquecinos, aunque a medida que se acercan a la eclosión (9 a 11 días) van tornando un color oscuro. Son responsables de que aparezcan hongos causantes de la fumagina pues facilita el crecimiento de los mismos gracias a su vomito que contiene azucares (mielecillas) (Torres, 2012).



Figura 10. Imagen de un huevo en el envés de la hoja

Fuente: Tomado de “Guía práctica para el manejo de banano orgánico en el valle del Chira” (Torres, 2012).

1.3.1.6 Picudo. Este insecto puede llegar a causar hasta el 50% de perdidas, debido a que las larvas penetran en la corona de la planta cuando se alimentan, despojándola de su vitalidad pudiendo causar la caída de la planta madura (Agrobanco, 2013).

El picudo negro (*Cosmopolites sordidus*), puede llegar a medir de 10 hasta 15mm y se puede encontrar en las vainas foliares, en el suelo y en la base de la mata especialmente en donde hay residuos del cultivo. Las larvas del picudo cuando se alimentan realizan túneles en el cormo y pseudotallo, lo que limita o impide que el transporte de nutrientes, afectando la nutrición de la planta, estabilidad y productividad. Las plantas atacadas llegan a producir muy mal y muy poco (producen racimos y frutos pequeños), y también la planta se puede caer antes de alanzar la madurez (Torres, 2012).



Figura 11. Picudo negro

Fuente: Tomado de “Guía práctica para el manejo de banano orgánico en el valle del Chira” (Torres, 2012).



Figura 12. Galerías ocasionadas por las larvas del picudo

Fuente: Tomado de “Guía práctica para el manejo de banano orgánico en el valle del Chira” (Torres, 2012).

1.3.1.7 Trips de la mancha roja. Durante los últimos años se estima que el 98% de las plantaciones de banano tienen esta plaga en un nivel bajo y un 2% con un nivel de infestación alto, ocasionando que no sea posible la exportación (Agrobanco, 2013).

Tanto en Perú como en Ecuador que son dos países líderes en exportación vienen siendo afectadas por las frutas manchadas producto de los trips de la mancha roja. Estos efectos aumentaron drásticamente en el 2011 con un 30 a 40% en pérdidas del rendimiento. Esta plaga solo afecta la cascara del banano siendo solo cosmético, sin embargo, los exportadores aplican tolerancia cero (Arias de López, y otros, 2020).

Esta plaga la conforman especies como la *Chaetanaphothrips orchidii* y *Chaetanaphothrips signipennis*, tienen un aparato bucal raspador-lamedor y pueden formar enormes colonias. El daño es una mancha rojiza en el pseudotallo como también en la capa exterior de la cascara del fruto volviéndola áspera y sin brillo (Torres, 2012).

La fruta que tiene esta mancha roja no se puede exportar porque es rechazada por los mercados internacionales por baja calidad. Y se estima que hasta un 30% de la producción se pierde por esta plaga (Agrobanco, 2013).



Figura 13. Efectos de los trips en el pseudotallo

Fuente: Tomado de “Trips de la macha roja” (GORE, Trips de la macha roja, 2017)



Figura 14. Efecto de los trips de la mancha roja en el fruto

Fuente: Tomado de “Manejo integrado de banano orgánico” (Agrobanco, 2013).

1.4 Agricultura inteligente (Smart Farming) en la producción de banano orgánico

La agricultura inteligente o Smart Farming es un término nuevo que se está utilizando en la agricultura que busca aumentar la productividad, la calidad del producto final y la reducción de los costos. Emplea lo más reciente en tecnología como el uso de vehículos aéreos no tripulados, vehículos terrestres no tripulados, *Big Data*, procesamiento de imágenes, machine learning y hasta red de sensores inalámbricos y se espera que con el uso de esta tecnología la disminución de costes, al optimizar los insumos necesarios como los fertilizantes, los pesticidas y el combustible, además la reducción de los esfuerzos laborales (Moysiadis, Sarigiannidis, Vitsas, & Khelifi, 2021).

1.4.1 Vehículos aéreos no tripulados (UAVs)

Para la década de los 2000 se utilizaban las imágenes proporcionadas por los satélites que permitían la visión de un campo extenso pero cuya resolución era relativamente mala con muy baja frecuencia en el tiempo y un intervalo muy largo entre observación y uso de las imágenes. Posteriormente se utilizaron aviones y globos donde se obtuvieron las imágenes con mejores resoluciones, pero el costo de la adquisición de datos era muy elevado para aplicaciones de agricultura. Con los avances tecnológicos se ha podido utilizar en los últimos años los vehículos no tripulados, que ha facilitado la obtención de la información con accesibilidad inmediata incluso para áreas extensas (Milics, 2019).

Existen 3 principales tipos de vehículos aéreos no tripulados, los multirrotores, los de ala fija y los de un solo motor, aunque también híbridos que intentan combinar dichos tipos, pero debido a su complejidad no se comercializan (Milics, 2019).

La aplicación de los UAVs en la agricultura está en fase de desarrollo e investigación, pero algunos agricultores ya los están utilizando de manera diaria sin embargo el resto no ven las ventajas o las posibilidades que les ofrece su uso. Algunas de las aplicaciones se pueden enfocar en la visión general de la parcela junto con la comprobación del estado, mapeo del agua en la parcela, mapeo del estado de la vegetación y los daños causados por la fauna, también se puede hacer un mapeo de las malezas y muchas aplicaciones más (Milics, 2019).




Figura 15. Índice NDVI, muestra diferentes estados de maduración y ausencia de vegetación en maíz

Fuente: Tomado de “Application of UAVs in Precision Agriculture” (Milics, 2019).

1.4.2 Big data

La solución con *Big Data* puede ayudar a mejorar la previsión y la eficiencia operativa para conducir a una mejor toma de decisiones. También se puede realizar análisis de predicciones que ayuden a la obtención de mejores resultados. Sin embargo, para el desarrollo es necesario contar con una gran información procesable. Se puede implementar en muchos campos de la agroindustria, por ejemplo, el análisis de los datos meteorológicos, la previsión del rendimiento y la producción, decisiones con sistemas con alertas en tiempo real que se basan con los datos de los campos, etc. (Ribarics, 2016).

El uso de *Big Data* puede ser el punto de partida para las correlaciones de los campos con los datos meteorológicos y también con los productos básicos para la optimización del riego, la fertilización y la cosecha de los cultivos. Como análisis predictivo se puede anticipar la demanda de semillas, fertilizantes, y ayudar a los proveedores tomar las medidas adecuadas para adecuarse a la demanda (Ribarics, 2016).

1.4.3 Internet de las cosas (IoT)

El IoT consiste en la unificación de sensores y dispositivos en objetos de uso cotidiano donde estos se conecten a internet (Redes fijas o inalámbricas). Una de las áreas donde mayor se está aplicando el IoT es la meteorología, donde se utilizan varios sensores para la monitorización de las condiciones climáticas en tiempo real. De esta forma se busca obtener predicciones más precisas (Quiroga Montoya, Jaramillo Colorado, Campo Muñoz, & Chanchi Golondrino, 2016).



Capítulo 2

Adquisición de datos de entrada y salida

2.1 Lugar de investigación

La parcela utilizada para la investigación está ubicada en el distrito de Buenos Aires que pertenece a la provincia de Morropón del departamento de Piura con coordenadas $5^{\circ} 16' 13.4''$ S $79^{\circ} 57' 10.1''$ W. La parcela tiene un área de 1 hectárea de banano orgánico.



Figura 16. Parcela utilizada para la investigación.

2.2 Equipos

Los datos meteorológicos son registrados por un sistema EnviroMonitor conformado por un Gateway y 2 nodos, donde cada nodo puede soportar hasta 4 sensores. Los nodos transmiten los datos a un vínculo con la malla que puede ser el Gateway u otro nodo (la red en malla funciona a 902-928 MHz), y posteriormente el Gateway los envía a WeatherLink.com por medio de conexión de telefonía celular.

Los datos se registran en tres niveles diferentes, el suelo, el microclima (por debajo de las hojas) y el clima (por encima de las hojas). La estación central (sensores ubicados por encima de las hojas de la plantación de banano) registra variables como temperatura, humedad relativa, lluvia, radiación solar, presión barométrica y velocidad del viento, pero también se realizan cálculos de manera interna utilizando las variables registradas obteniéndose así variables como la evapotranspiración, etc. Cada nodo tiene 4 sensores, 3 que corresponden al suelo que registran temperatura, humedad y electroconductividad a 30, 60, y 90 cm y un sensor de temperatura y humedad del ambiente por debajo de las hojas (sensor del microclima) (Manrique Silupu, Campos, Paiva, & Ipanaqué, 2021).



Figura 17. Ubicación de la red de sensores en la parcela

Fuente: Tomado de “Thrips incidence prediction in organic banana crop with Machine learning” (Manrique Silupu, Campos, Paiva, & Ipanaqué, 2021).

Los nodos envían los datos por medio de ZigBee que es un protocolo de comunicación que emplea ondas de radio de baja energía. Los datos de ambos nodos llegan a la estación central y se actualizan en la nube en un intervalo de 15 minutos.

Con respecto al sistema de alimentación la estación central cuenta con un panel solar y una batería de 6V y 12ah, mientras que en los nodos el panel solar es más pequeño y la batería es una de litio recargable y además tiene una alimentación extra conformado por 4 pilas tipo “D”.



Figura 18. Estación central



Figura 19. Nodo 1



Figura 20. Nodo 2

2.2.1 Variables medidas por la red de sensores IoT

En la Tabla 7 se muestran todas las variables que registra la estación principal y en la Tabla 8 los datos registrados por los nodos.

Tabla 7. Variables meteorológicas – Estación central

	Variable	Unidades
1	Presión barométrica	mb
2	Temperatura	°C
3	Temperatura Alta	°C
4	Temperatura Baja	°C
5	Humedad	%
6	Punto de rocío	°C
7	Bulbo húmedo	°C
8	Velocidad del viento	m/s
9	Dirección del viento	--
10	Viento corriente	m
11	Alta velocidad del viento	m/s
12	Alta dirección del viento	--
13	Viento frío	°C
14	Índice de calor	°C
15	THW	°C
16	Lluvia	mm
17	Tasa de lluvia	mm/h
18	Evapotranspiración	mm
19	Grados día de calentamiento	--
20	Grados día de enfriamiento	--
21	THWS	°C
22	Radiación solar	W/m ²
23	Energía solar	Ly
24	Radiación solar alta	W/m ²

Fuente: Tomado de “Producto 6. Monografía de diseño técnico de la aplicación” (Ipanaqué Alama, Belupú, Estrada, Neyra Hau Yon, & Campos Cercado, 2021).

Tabla 8. Variables meteorológicas - Nodo

	Sensor Microclima	Unidades
1	Temperatura Baja	°C
2	Temperatura	°C
3	Temperatura Alta	°C
4	Humedad Baja	%
5	Humedad	%
6	Humedad Alta	%
7	Punto de rocío	°C
8	Bulbo húmedo	°C
9	Índice de calor	°C
	Sensor de suelo	
10	Temperatura de Suelo	°C
11	Humedad de suelo	%
12	EC de suelo	dS/m

Fuente: Tomado de “Producto 6. Monografía de diseño técnico de la aplicación” (Ipanaqué Alama, Belupú, Estrada, Neyra Hau Yon, & Campos Cercado, 2021).

2.3 Metodología

Para la investigación se han requerido datos de la parcela como también los datos meteorológicos de la estación.

Los datos de la parcela se han realizado con una frecuencia de una a dos veces por semana mientras que los datos meteorológicos registrados por la estación son medidos cada 15 minutos, siendo 96 datos por día. Dichos datos meteorológicos son procesados a valores diarios y posteriormente utilizados como entradas para el modelo matemático.

El modelo matemático toma como base el modelo exponencial para describir el crecimiento poblacional, y se ajusta con las variables observadas experimentalmente que influyen en su desarrollo. Dicho modelo es implementado en Python y se valida comparando los datos reales obtenidos por las evaluaciones de plagas con los resultados del modelo.

Para desarrollar el modelo matemático se hace uso del enfoque de validación cruzada, lo que significa que los datos son divididos en dos grupos ($n = n_c + n_v$), donde n_c se utiliza para la construcción del modelo mientras que el conjunto de datos n_v es utilizado para la validación del modelo.

Para la verificación del ajuste del modelo se utilizan las métricas de R-cuadrado (R^2) y el RMSE, donde el R-cuadrado indica lo cerca que están los datos de la línea de regresión

ajustada mientras que el segundo mide el error que hay entre los datos reales y los datos obtenidos por el modelo.

Una vez ajustado el modelo matemático, se simula con nuevos datos entrada y de salida para la verificación del modelo.

2.4 Datos de entrada

La estación meteorológica mide muchas variables, pero no todas están involucradas directamente en el crecimiento de los trips de la mancha roja, por lo tanto, es necesario una investigación profunda de las variables más importantes que favorecen o perjudican el crecimiento poblacional de esta plaga. El siguiente análisis resume los puntos más importantes de cada variable tomada en cuenta en esta investigación, parte del análisis son en base a bibliografía como también a la información recopilada de la experiencia de los agricultores.

2.4.1 Temperatura

La tasa de desarrollo de los insectos depende de la temperatura a la que están expuestos. Para cada especie existe un umbral de temperatura donde a valores inferiores a dicho umbral no se produce ningún desarrollo (Campbell, Frazer, Gilbert, Gutierrez, & Mackauer, 1974), por lo tanto esta variable es fundamental para el análisis y su influencia ha sido notada por los agricultores que a través de los años se han dado cuenta que en estaciones de verano aumenta exponencialmente la población de los trips mientras que en invierno disminuye.

2.4.2 Humedad relativa

Es un factor importante para el desarrollo de algunas especies, su valor bajo o elevado puede influenciar en el crecimiento poblacional de los trips de la mancha roja. Además con la variabilidad climática además de otras variables también se ven alteradas la lluvia y la humedad, que posiblemente afecten positivamente o negativamente al ciclo de vida o el ambiente de los insectos (Giraldo Jaramillo, 2018) y con respecto a los trips de la mancha roja existen algunas investigaciones (Castillo Jiménez, 2021) donde se confirma el efecto tanto de la temperatura como la humedad relativa del aire en el crecimiento poblacional.

2.4.3 Lluvia

La lluvia no está relacionada con el fenómeno del niño, pero su frecuencia se intensifica con la llegada del mismo, con respecto a su influencia con los trips según los agricultores, una lluvia intensa puede disminuir la población de trips, aunque no es una reducción muy significativa. La lluvia los obliga a salir al aire libre e incluso los puede arrojar al suelo alterando de alguna u otra forma su desarrollo.

2.4.4 Velocidad del viento

Cuando los trips de la mancha roja se encuentran en condiciones donde el clima es cálido, tienen a volar por lo que pueden dispersarse por la parcela, por lo tanto, la velocidad del viento puede influir en ese cambio de lugar (León Tigrero, 2018).

2.4.5 Fumigaciones

La palabra fumigación por definición hace referencia a la aplicación de agentes químicos para el control de las plagas, sin embargo, la plantación de la parcela es banano orgánico por lo que es una palabra mal usada, pero es muy usada coloquialmente.

Con respecto a las fumigaciones de la plaga de los trips se ha dividido en dos tipos, fumigación preventiva, y fumigación correctiva. La fumigación preventiva se hace de manera más frecuente con fungicidas que son accesibles para los agricultores, que sirven para controlar no solo a los trips sino también a las demás plagas, sin embargo, cuando se realiza la fumigación correctiva demanda de más costo pues se tiene que comprar productos que pueda hacer frente a los trips en una situación de infestación grave de la parcela, pero a la vez cumplir con los estándares de la certificación. Este tipo de fumigación puede costar hasta 8 veces el costo del producto utilizado de manera preventiva por lo que se busca siempre controlar la plaga con anticipación.

2.4.6 Limpieza de la parcela

Según la experiencia de los agricultores la limpieza de la parcela es un factor muy importante para el desarrollo de los trips de la macha roja, la realización de aireación del suelo ocasiona la exposición de las pupas de los trips tanto a los enemigos naturales como a la luz solar que ocasiona su deshidratación (Agrobanco, 2013). Por tal motivo la inclusión de la limpieza de la parcela es un factor muy importante que no debe obviarse al momento del modelamiento matemático.

2.5 Las evaluaciones de plagas y los datos de salida

La asociación ASPROBO lleva un registro de las plagas durante todo el año. Dichas evaluaciones se han realizado en la parcela de investigación con un intervalo de 1 o 2 veces por semana desde noviembre del 2019, fecha donde fue instalada la estación meteorológica.

En la evaluación se registran 8 tipos de plagas (Explicados en el capítulo 1) como la arañita roja, ceramidia, cochinilla, escamas, mosca blanca, picudo, pulgón, trips de la mancha roja.



Figura 21. Realización de evaluación de plagas en la parcela

Las evaluaciones de plagas es un formato utilizado por la asociación ASPROBO para el registro de plagas. Para el llenado de la información es necesario el conteo manual, para eso un técnico de la asociación toma como muestra 25 plantas, 9 de lado derecho de la parcela, 8 del lado central y 8 de lado izquierdo. De las muestras tomadas se saca un valor promedio y se asume dicho promedio para toda la plantación. De tal forma el agricultor puede saber cómo está su parcela con respecto a las plagas y puede planificar mejor las fumigaciones.

En la siguiente imagen se muestra el formato de una evaluación de plagas con 25 plantas como cantidad de muestreo (En el Anexo A se puede ver con mejor detalle).

REPORTES DE PLAGAS

Zona: LA PAMPA		Productor: MAXIMO LOPEZ ROJAS										Evaluador: PERCY AGUIRRE										FECHA: 30/04/2021										07:25 AM			
		LD 1	LD 2	LD 3	LD 4	LD 5	LD 6	LD 7	LD 8	LD 9	CE 10	CE 11	CE 12	CE 13	CE 14	CE 15	CE 16	CE 17	LI 18	LI 19	LI 20	LI 21	LI 22	LI 23	LI 24	LI 25	Total	Max	Min	% de plaga					
ARAÑITA ROJA	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	HOJAS	0	0	0	0	6	0	0	0	2	0	0	0	0	5	2	0	0	2	0	0	0	0	0	0	0	0	17	6	0	0.68				
	Total	0	0	0	0	6	0	0	0	2	0	0	0	0	5	2	0	0	2	0	0	0	0	0	0	0	0	17			0.68				
CERAMIDIA	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	HOJAS	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	Total	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
COCHINILLA	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	PEDUNCULO	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0.04				
	PSEUDOTALLO	0	0	2	3	0	0	0	0	0	0	0	0	3	0	2	0	0	0	3	1	0	0	0	2	2	2	20	3	0	0.8				
	RACIMO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
ESCAMAS	Total	0	0	2	3	0	0	0	0	1	0	0	0	3	0	2	0	0	0	3	1	0	0	2	2	2	2	21			0.84				
	HOJAS 4TA	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	HOJAS 5TA	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	PEDUNCULO	5	0	6	0	0	2	0	5	0	0	12	6	3	0	7	0	8	0	0	0	0	0	12	4	70	12	0	2.8						
MOSCA BLANCA	Total	5	0	6	0	0	2	0	5	0	0	12	6	3	0	7	0	8	0	0	0	0	12	4	70				2.8						
	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	HOJAS	2	0	0	0	3	0	0	0	3	0	0	0	3	0	4	0	0	5	2	2	0	0	0	0	0	24	5	0	0.96					
	PSEUDOTALLO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
PICUDO	Total	2	0	0	0	3	0	0	0	3	0	0	0	3	0	4	0	0	5	2	2	0	0	0	0	0	24			0.96					
	INDIVIDUOS	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	Total	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
PULGON	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	PEDUNCULO	0	0	0	0	0	12	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	13	12	0	0.52					
	RACIMO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0				
	Total	0	0	0	0	0	12	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	13			0.52					
TRIPS	ADULTOS	0	2	0	2	0	2	3	2	0	1	5	0	1	3	1	5	0	2	2	0	0	3	3	0	0	37	5	0	1.48					
	NINFAS	0	3	0	4	0	6	2	6	0	2	2	0	2	2	2	2	0	3	6	0	2	2	2	0	3	51	6	0	2.04					
	Total	0	5	0	6	0	8	5	8	0	3	7	0	3	5	3	7	0	5	8	0	2	5	5	0	3	88			3.52					

Figura 22. Evaluación de plagas de 25 plantas

Al lado derecho de la figura 22 están los valores promedios. Con respecto a los trips se puede afirmar que, en esta evaluación, la parcela tuvo un promedio de 3.52 trips/planta siendo este valor utilizado como dato de salida. Por lo tanto, los datos de salida que son utilizados en los modelos son los valores promedios de trips de todas las evaluaciones o registro de plagas realizados en la parcela.

La Figura 23 muestra el comportamiento de la población de trips que se han utilizado para el ajuste del modelo. En el eje “x” muestra el tiempo en días, el día 0 corresponde al 11/12/2019 hasta el día 453 correspondiente al 8/03/2021.

Con una simple inspección visual se puede afirmar que los días donde la cantidad de trips aumentan significativamente con respecto a los demás corresponde a los meses de verano, el primer pico es el verano del 2020 mientras que el segundo corresponde al verano del año 2021.

Una desventaja que puede afectar en el ajuste del modelo es la poca cantidad de datos que se tienen, por ejemplo, solo se cuenta con 6 datos donde el valor de trips/planta es mayor a 7.5 y además no se tiene datos con valores de trips superiores a 20 o cercanos a 30, en consecuencia, el modelo no estaría entrenado para cuando se presente dichos casos atípicos (En situaciones reales se evita llegar a dichos valores de trips ya que indicarían una infestación total de la parcela).




Figura 23. Gráfico del comportamiento de los trips



Capítulo 3

Modelación matemática

Para describir la dinámica poblacional de los insectos, se puede utilizar el modelo exponencial de crecimiento poblacional de Murray, modelo que ha sido implementado en un estudio sobre el desarrollo de un aplicativo que determina el valor de los parámetros del modelo para la estimación de la cantidad de microorganismos (Hernández y Rivera, 2018). Es un modelo básico que describe el crecimiento poblacional por medio de una ecuación diferencial de primer orden. A este modelo también se le conoce como modelo exponencial.

En este caso en particular se utiliza el modelo de Murray para aproximar el crecimiento poblacional de los trips de la mancha roja (insectos/planta) en un cultivo de banano orgánico en cualquier instante de tiempo (días).

3.1 Modelo del crecimiento poblacional de insectos (Modelo de Murray)

El modelo de Murray o exponencial se puede describir de la siguiente manera:

$$\frac{dN}{dt} = bN - dN = (b - d)N = rN \quad (1)$$

Donde:

- b : Nacimientos
- d : Muertes
- r : Tasa de crecimiento

Pasando la ecuación (1) al dominio del tiempo, la ecuación queda en la forma exponencial:

$$N(t) = N_0 e^{(b-d)t} \rightarrow N(t) = N_0 e^{rt} \quad (2)$$

Donde:

- $N(t)$: Es la población de la especie en un momento t .
- N_0 : Cantidad inicial de Thrips

3.1.1 Implementación del modelo de Murray:

En el caso de estudio se reescribe la ecuación 1 con parámetros más adecuados a nuestra aplicación y además se estudia a profundidad la tasa de crecimiento:

$$\frac{dP_T}{dt} = \rho \cdot P_T - \psi \cdot P_T = (\rho - \psi) \cdot P_T = r \cdot P_T \quad (3)$$

Donde:

- P_T : Representa la población de tris de la mancha roja (*trips/planta*)
- ρ : Tasa de crecimiento natural de la población (*1/día*)
- ψ : Tasa de muertes naturales de la población (*1/día*)
- r : Tasa de crecimiento (*1/día*)

De tal forma, si $\rho > \psi$ la población crece de manera exponencial, pero si $\rho < \psi$ la población disminuye.

El principal reto de la investigación es modelar la tasa de crecimiento de tal forma que se pueda incorporar los aspectos que influyen en el aumento en la cantidad de los trips como también en su reducción poblacional.

Considerando aspectos que disminuyen la cantidad poblacional de estos insectos como las fumigaciones y la limpieza de la parcela se obtiene el siguiente modelo para la tasa de crecimiento.

$$r = \rho - \psi - \phi_1 \cdot F_1 - \phi_2 \cdot F_2 - \gamma \cdot C \quad (4)$$

Donde:

- ρ : Tasa de crecimiento natural de la población
- ψ : Tasa de muertes por causas naturales de la población (*1/día*)
- ϕ_1 : Tasa de mortalidad causado por la fumigación de trips (*1/día*)
- ϕ_2 : Tasa de mortalidad causado por fumigación general para todas las plagas (*1/día*)
- γ : Tasa de mortalidad causado por la limpieza (*1/día*)
- F_1 : Concentración del fungicida aplicado para los trips (Fumigación 1)
- F_2 : Concentración del fungicida aplicado para las plagas en general (Fumigación 2)
- C : Concentración teórica de limpieza de la parcela

Se consideran dos fumigaciones uno que se realiza cuando la parcela está totalmente infestada (Fumigación correctiva) y la fumigación más frecuentemente utilizado cuya aplicación se realiza de forma preventiva para plagas como la araña roja, la mosca blanca, los trips, etc. Además, su efecto es más débil en comparación con el primero. Por esta razón, se consideran en el modelo definidos por F_1 y F_2 , y se expresan de forma similar a la ecuación utilizada en la estimación poblacional de bacterias sometidos a antibióticos (Esteve, Ibargüen Mondragon, & Romero Leyton, 2011).

$$F_1 = e^{-\varphi_{f1} \cdot \tau_{F1}} \quad (5)$$

$$F_2 = e^{-\varphi_{f2} \cdot \tau_{F2}} \quad (6)$$

Donde:

- F_1 : Concentración del fungicida aplicado para los trips (Fumigación 1)
- F_2 : Concentración del fungicida aplicado para las plagas en general (Fumigación 2)
- φ_{F_1} : Tasa de degradación correspondiente al fungicida aplicado para los trips
- φ_{F_2} : Tasa de degradación correspondiente al fungicida aplicado a las plagas en general
- τ_{F_1} : Días transcurridos desde la última fumigación 1

τ_{F_1} es la diferencia entre el día en que se ha realizado la última fumigación 1 (t_{2f1}) y el día que se evalúa la incidencia de trips posterior a la fumigación 1 (t_{1f1}).

$$\tau_{F_1} = t_{2f1} - t_{1f1} \quad (7)$$

- τ_{F_2} : Días transcurridos desde la última fumigación 2

τ_{F_2} es la diferencia entre el día en que se ha realizado la última fumigación 2 (t_{2f2}) y el día que se evalúa la incidencia de trips posterior a la fumigación 2 (t_{1f2}).

Durante el tercer estado ninfal, las ninfas maduras migran de la planta al suelo o a la epidermis y se transforman en prepupas. En esta fase, la limpieza de la parcela es un factor influyente en el crecimiento de la población de trips, ya que interfiere directamente en su ciclo de vida. Si no se realiza esta actividad, se produciría un aumento significativo del número de insectos.

Además, dicha información es observada de manera práctica en los agricultores, pues aseguran que con las limpiezas evitan un ambiente propicio para el desarrollo de los trips, por lo tanto, para una mejor precisión en el ajuste del modelo es necesario la inclusión de la limpieza. El término de limpieza que se ha implementado se modela de forma similar a los términos de las fumigaciones (Modelación teórica), ya que su impacto en la población de insectos disminuye a medida que transcurre el tiempo.

$$C = e^{-\varphi_c \cdot \tau_c} \quad (8)$$

Donde:

- C : Concentración teórica de limpieza de la parcela
- φ_c : Tasa de degradación de la limpieza
- τ_c : Días transcurridos desde la última limpieza

En la parcela, los trips están bajo influencia de las variables climáticas siendo solo 4 tomadas en cuenta en esta investigación (*temperatura atmosférica, humedad relativa, velocidad del viento y lluvia*). Dichas variables pueden influir de manera positiva o negativa en el desarrollo poblacional.

3.2 Modelo de Campbell (MC)

La tasa de desarrollo de los insectos depende de la temperatura a la que están expuestos, por lo tanto, para cada especie existe un valor de temperatura donde por debajo de aquel valor no se produce ningún desarrollo. En un rango de temperaturas, la relación entre la tasa de crecimiento y la temperatura puede representarse mediante una línea recta que, al extenderse, corta el eje x en el umbral de temperatura (T), tal como se muestra en la Figura 24, por lo tanto, se puede llegar a la conclusión de que no es práctico analizar la tasa de crecimiento promedio en el dominio del rango A , debido a la elevada mortalidad causada por las bajas temperaturas (Aunque existen una selección de individuos que pueden desarrollarse a bajas temperaturas) y de manera similar ocurre para altas temperaturas, en el dominio del rango C la tasa de desarrollo promedio disminuye con respecto al crecimiento lineal observado en el rango B (Campbell, Frazer, Gilbert, Gutierrez, & Mackauer, 1974).

Sin embargo, esta reducción de la tasa de crecimiento observada a altas temperaturas sólo se produce si la temperatura permanece constante o fluctúa dentro de un pequeño rango durante un largo periodo de tiempo, siendo esto poco usual. Por lo tanto, en la práctica las condiciones de campo se encuentran casi siempre en la sección lineal correspondiente al dominio del rango B . A efectos prácticos, la tasa de crecimiento de los insectos puede aproximarse mediante una ecuación lineal (Prasad, y otros, 2021)




Figura 24. Relación entre la tasa de desarrollo de los insectos y la temperatura.

Fuente: Tomado de “Temperature requirements of some aphids and their parasites” (Campbell, Frazer, Gilbert, Gutierrez, & Mackauer, 1974).

Tal y como se ha explicado, para efectos prácticos se puede aproximar la tasa de desarrollo de los insectos mediante una ecuación lineal.

$$\rho = a + b \cdot T \quad (9)$$

Donde los parámetros a y b son constantes cuyos valores son estimados con los datos “experimentales”.

- a : Valor de intercepción con la tasa de desarrollo (1/día)
- b : Pendiente que relaciona la temperatura con la tasa de crecimiento (1/día · °C)
- T : Temperatura (°C)

Reemplazamos la ecuación 9 en la ecuación 4 y se obtiene la tasa de desarrollo de los trips en función de la variable climática de la temperatura.

$$r = (a + b \cdot T) - \psi - \phi_1 \cdot F_1 - \phi_2 \cdot F_2 - \gamma \cdot C \quad (10)$$

Por lo tanto, la ecuación general del modelo matemático usando el modelo de Campbell para la descripción la tasa de crecimiento natural de la población de los trips queda de la siguiente manera:

$$\frac{dP_T}{dt} = (a + b \cdot T - \psi - \phi_1 \cdot F_1 - \phi_2 \cdot F_2 - \gamma \cdot C) \cdot P_T \quad (11)$$

3.3 Modelo de Campbell modificado (MCM)

En el modelo de Campbell (MC) solo toma en cuenta la temperatura para describir la tasa de crecimiento natural de la población, y deja de lado otras variables climáticas que

pueden influir en el desarrollo de los insectos, como la temperatura o las precipitaciones (Elbenri, y otros, 2015). Para la inclusión de otras variables además de la temperatura se hizo un estudio tanto de la bibliografía como de la experiencia de los agricultores (Este análisis se describe en el capítulo 2 en la sección de datos de entrada).

Las variables que se introdujeron en la tasa de crecimiento natural de la población son la *humedad relativa*, la *velocidad del viento*, y la *tasa de lluvia*. Se agregaron para cada variable una constante cuyo valor es encontrado por el algoritmo realizado en Python.

$$\rho = a + b \cdot T + C \cdot H + D \cdot V + E \cdot R \quad (12)$$

Donde:

- H : Humedad relativa (%)
- V : Velocidad del viento (m/s)
- R : Tasa de lluvia (mm/h)
- C : ($1/dia \cdot \%$)
- D : ($1/dia \cdot m/s$)
- E : ($1/dia \cdot mm/h$)

La forma en la que se introdujeron las nuevas variables en la ecuación de la tasa de crecimiento natural, busca influenciar el comportamiento de la recta inicial descrita por MC, de tal forma la respuesta del modelo se vuelve más robusta con respecto a los valores de entrada, ya que no solo depende de la temperatura sino también de las variables como humedad relativa, velocidad del viento y la tasa de lluvia.

Reemplazando la ecuación 12 en la ecuación 4 se obtiene el siguiente modelo matemático que describe la tasa de desarrollo de los trips en función de las variables climáticas de la *temperatura*, *humedad relativa*, *velocidad del viento* y *tasa de lluvia*.

$$\frac{dP_T}{dt} = (a + b \cdot T + C \cdot H + D \cdot V + E \cdot R - \psi - \phi_1 \cdot F_1 - \phi_2 \cdot F_2 - \gamma \cdot C) \cdot P_T \quad (13)$$

3.4 Ecuaciones obtenidas

De todo el análisis desarrollado se han modelado dos ecuaciones diferenciales de primer orden que se resumen en la siguiente tabla. Los parámetros desconocidos son calculados por el algoritmo.


Tabla 9. Ecuaciones matemáticas obtenidas

z	Modelos matemáticos desarrollados
M1	$\frac{dP_T}{dt} = (a + b \cdot T - \psi - \phi_1 \cdot F_1 - \phi_2 \cdot F_2 - \gamma \cdot C) \cdot P_T$
M2	$\frac{dP_T}{dt} = (a + b \cdot T + C \cdot H + D \cdot V + E \cdot R - \psi - \phi_1 \cdot F_1 - \phi_2 \cdot F_2 - \gamma \cdot C) \cdot P_T$

3.5 Algoritmo desarrollado en Python

Para la validación se ha utilizado la validación cruzada, que significa que los datos de entrada y de salida se han dividido en una cierta cantidad de conjuntos aleatorios (100) y cada conjunto se ha dividido en 75% para el entrenamiento y 25% para la validación. La separación de los conjuntos se ha realizado con el metodo Group Shuffled Split (GSS) de la biblioteca Sci-kit learn de Python.

La implementación del modelo se realiza mediante una integración multiperodo, donde el valor de trips se predice a partir del dato anterior. Se empieza con un dato inicial de trips y el algoritmo estima los valores de los parametros desconocidos y estima el dato de trips del dia siguiente, esto se realiza hasta cuando se encuentre otro dato real donde se compara con el del modelo y se calcula el error, para posteriormente ajustar los valores de los parametros.

**Figura 25.** Diagrama de flujo

Fuente: Tomado de “Thrips incidence prediction in organic banana crop with Machine learning” (Manrique Silupu, Campos, Paiva, & Ipanaqué, 2021)

Con el 75% de cada conjunto se ajustan los valores desconocidos del modelo para posteriormente utilizar dichos valores con el 25% de los datos de validación, obteniéndose así las metricas de R-cuadrado y RMSE que indican la presición del modelo.

En el el diagrama de flujo mostrado en Figura 25 se describe brevemente el funcionamiento del algoritmo y en los apendices A y B se encuentran los códigos utilizados para la estimación de parámetros de ambos modelos.



Capítulo 4

Simulaciones y resultados

4.1 Simulaciones de los modelos

Para el modelo matemático 1 (*MM1*), se han ajustado 9 parámetros, mientras que para el modelo matemático 2 (*MM2*), se ajustaron 12 parámetros.

Para cada simulación se han obtenido diagramas de barras de los 100 conjuntos, donde el eje x indica el rango de valores que ha tomado dicho parámetro en cada conjunto. Lo ideal sería la obtención de una distribución normal, lo que significaría una gran precisión en el modelo sin embargo a su vez se obtienen diagramas que indican una tendencia de los parámetros a moverse en un intervalo muy pequeño.

4.1.1 *MM1*

En el modelo matemático 1 (*MM1*), se han ajustado 9 parámetros. En la Figura 26 se observan los diagramas de a y b .

Donde en el parámetro a se puede observar que hay más de 35 conjuntos que han tenido un valor de aproximadamente -0.14 , 18 conjuntos con un valor cercano a -0.12 , etc. Si se sumasen todos esos conjuntos se obtendrían los 100 conjuntos, siendo ese mismo razonamiento el que se aplica para todos los diagramas de barras.

Lo que se obtiene de las simulaciones son todos los valores que cada parámetro ha tomado, por lo tanto, hay varios criterios para la selección de valores de los parámetros que se pueden utilizar en los modelos matemáticos.

Se pueden tomar los valores del conjunto que mejor precisión tuvo en la validación, también se pueden utilizar los valores donde los datos del diagrama están más agrupados o simplemente se puede tomar el promedio, siendo esto último lo que se ha realizado en esta tesis.




Figura 26. Valores de "a" y "b" obtenido de los 100 conjuntos




Figura 27. Valores de "mu" y "alfa1" obtenido de los 100 conjuntos




Figura 28. Valores de "alfa2" y "gamma" obtenido de los 100 conjuntos




Figura 29. Valores de "Degradación de la fumigación 1" y "Degradación de la fumigación 2" obtenido de los 100 conjuntos




Figura 30. Valor de "Degradación de la limpieza" obtenido de los 100 conjuntos

En la siguiente tabla se muestran los valores de los promedios de cada parámetro, dichos valores son los utilizados en el MM1.

Tabla 10. Valores promedios de los parámetros de MM1

Parámetro	Promedio
a	-0.0957
b	0.0142
μ	0.1836
α_1	0.6351
α_2	0.0953
γ	0.1214
ϕ_{f1}	0.0985
ϕ_{f1}	0.5926
ϕ_c	0.0655

4.1.1.1 Métricas de MM1 obtenidas. Para la evaluación de la precisión se ha utilizado las métricas de R-cuadrado (R^2) y se han evaluado para los conjuntos de entrenamiento y validación.

El razonamiento de las métricas es el mismo de los diagramas explicados anteriormente, cada resultado de métrica corresponde a cada uno de los 100 conjuntos tanto para el entrenamiento y validación.

4.1.1.1.1 R-Cuadrado (R^2). Con respecto a R^2 en el entrenamiento se puede observar que la gran cantidad de los resultados están agrupados en la parte derecha (75% de los datos) con valores de R^2 que oscilan entre 0.75 y 0.90 con un valor promedio de aproximadamente 0.78, mientras que en los resultados de validación más del 50% de los conjuntos tuvieron un R^2 superior a 0.60 con un promedio de 0.66.




Figura 31. R-cuadrado de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)

4.1.1.1.2 RMSE. Para la métrica RMSE en los conjuntos de entrenamiento (RMSE train) aproximadamente el 70% de los resultados están agrupados en un rango de valores entre 1.40 y 1.60. También hay un pequeño grupo que representa el 15% de los conjuntos que tienen mejores valores de RMSE al estar entre valores de 1.05 y 1.30. En promedio se obtuvo un RMSE en entrenamiento aproximado de 1.50.

En la validación se obtuvieron algunos con altos valores de RMSE, pero dichos conjuntos son pocos en comparación a los 98% que oscilan entre 0.50 y 3.60, siendo el promedio aproximadamente 1.60.




Figura 32. RMSE de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)

4.1.2 MM2

Con respecto al modelo matemático 2 (*MM2*), los resultados obtenidos fueron un poco superiores al *MM1*. Se ajustaron 12 parámetros, el razonamiento para entender los diagramas de barras son los mismos que el modelo anterior.




Figura 33. Valor de "a" y "b" obtenido de los 100 conjuntos




Figura 34. Valor de "C" y "D" obtenido de los 100 conjuntos




Figura 35. Valor de "E" y "mu" obtenido de los 100 conjuntos




Figura 36. Valor de "alfa1" y "alfa2" obtenido de los 100 conjuntos




Figura 37. Valor de "gamma" y "Degradación de la fumigación 1" obtenido de los 100 conjuntos




Figura 38. Valor de " Degradación de fumigación 2" y "Degradación de la limpieza" obtenido de los 100 conjuntos

En la siguiente tabla se muestran los valores de los promedios de cada parámetro, dichos valores son los utilizados en el *MM2*.

Tabla 11. Valores promedios de los parámetros de *MM2*

Parámetro	Promedio
a	-0.0632
b	0.0288
C	-0.0049
D	0.1399
E	-0.6666
μ	0.2434
α_1	0.7664
α_2	0.0751
γ	0.2699
Φ_{f1}	0.1081
Φ_{f1}	0.4190
Φ_c	0.0785

4.1.2.1 Métricas de *MM2* obtenidas

4.1.2.1.1 R-Cuadrado (R^2). En el conjunto de entrenamiento se puede observar que casi el 80% de los conjuntos tuvieron un R^2 superior a 0.75 y con un promedio de aproximadamente 0.80, que supera levemente al modelo matemático 1.

El valor promedio del R^2 para los conjuntos de validación también son mejores con respecto al modelo matemático 1, pues pasa de 0.66 (*MM1*) a 0.70 (*MM2*).




Figura 39. R-cuadrado de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)

4.1.2.1.2 RMSE. Lo ideal es que se tenga un valor de RMSE con valor a cero, lo que indicaría de que no existe error entre los resultados del modelo matemático y los datos reales, sin embargo, esto no sucede, pero en estas dos comparaciones de los RMSE tanto de entrenamiento y validación se pueden observar, que con el *MM2* se obtienen valores inferiores al *MM1* lo que indica que el ajuste es mucho mejor con *MM2*.

Con respecto a la métrica de RMSE para los conjuntos de entrenamiento el valor promedio mejora levemente al pasar de 1.50 (*MM1*) a 1.45 (*MM2*).

De igual forma que los conjuntos de entrenamiento para los conjuntos de validación se obtiene una mejora leve al pasar de 1.60 (*MM1*) a 1.55 (*MM2*).




Figura 40. RMSE de los conjuntos de entrenamiento (lado izquierdo) y validación (lado derecho)

En la siguiente tabla se resumen los promedios de las métricas utilizadas tanto para *MM1* y para *MM2*.

Tabla 12. Comparación de los resultados promedios de R-cuadrado de MM1 y MM2

Conjuntos de:	R-Cuadrado (R^2)	
	MM1	MM2
Entrenamiento (Train)	0.78	0.80
Validación (Test)	0.66	0.70

Tabla 13. Comparación de los resultados promedios de RMSE de MM1 y MM2

Conjuntos de:	RMSE (Root mean square error)	
	MM1	MM2
Entrenamiento (Train)	1.50	1.45
Validación (Test)	1.60	1.55

4.1.3 Comparación de los modelos con los datos reales

En la siguiente figura se muestra la comparación de la respuesta de los modelos *MM1* y *MM2* con los datos de trips reales obtenidos de las evaluaciones de plagas que se han utilizado para la obtención de los modelos.

Para *MM1* se ha obtenido un valor de R-cuadrado de 0.72 y RMSE de 1.78 mientras que para *MM2* los resultados mejoraron pues el R-cuadrado ha sido de 0.73 y RMSE de 1.76. Al ser los datos que se utilizaron para la obtención de los parámetros de los modelos es de esperarse que los valores de las métricas tengan una buena precisión, aunque se puede observar en los resultados una mejor precisión de *MM2* con respecto a *MM1*.




Figura 41. Comparación de los modelos con los datos experimentales usados para el desarrollo

4.2 Validación de los modelos con nuevos datos

En la siguiente figura se muestra las respuestas de los modelos matemáticos con datos que no han sido utilizados para la modelación, dichos datos corresponden al periodo de fechas entre 8 de julio y el 19 de octubre del 2021 (intervalo de 103 días), y dentro de ese rango de días se realizaron 10 evaluaciones de plagas que sirven para validar los modelos.

De manera gráfica se visualiza que los datos de *MM2* se ajustan mejor que *MM1*, debido a que valores de *MM1* se alejan considerablemente de las mediciones reales.




Figura 42. Validación de los modelos matemáticos.

Lo mencionado anteriormente se puede confirmar con los valores de las métricas que se muestran en la Tabla 14, donde el R^2 del modelo *MM1* es un valor negativo, que indica que dicho modelo realiza un pésimo ajuste y además el RMSE está muy alto, eso se puede explicar en la gráfica donde los puntos correspondientes a dicho modelo están muy distantes al valor real, sin embargo, las métricas mejoran para el *MM2*, logrando un R^2 de 0.67 y un RMSE de 1.40 que inclusive es un valor más bajo que las simulaciones anteriores hechas para el desarrollo del modelo.

Tabla 14. Métricas obtenidas en la validación

Conjuntos de:	RMSE (Root mean square error)	
	MM1	MM2
R^2	-0.68	0.67
RMSE	4	1.40

4.3 Separación de la incidencia de los trips por clases

Desde fines del año 2021 la asociación ASPROBO ha implementado el uso de clases para la incidencia de las plagas. Anteriormente para referirse al nivel de incidencia de algún tipo de plaga de la parcela se hacía mediante un promedio que se extraía de la evaluación de

plagas. Un ejemplo es la evaluación que se muestra en la Figura 22 donde la cantidad de trips de toda la parcela se asume que es 3.52 trips/planta (Valor promedio de la muestra que son las 25 plantas). Sin embargo, la asociación ha cambiado esa forma de describir la incidencia de plagas pasando a los grados tal como se explica a continuación:

Tabla 15. División de las clases de las plagas

Clase	Rango de plagas
Grado 0	0 insectos/planta
Grado 1	1-15 insectos/planta
Grado 2	16 – 30 insectos/planta
Grado 3	30 a más insectos /planta

Por lo tanto, para la cantidad de 3.52 trips/planta sería lo mismo que grado 1. Dicho concepto da un margen de error a los modelos matemáticos desarrollados.

Se puede decir que los datos reales de la validación (Figura 42) están en grado 1 (1-15 trips/planta) y también lo están las estimaciones de ambos modelos matemáticos lo que significa una precisión del 100% para esa simulación.

Lamentablemente en los nuevos datos usados para la validación no se llega a grado 2 ni mucho menos a grado 3 (En los conjuntos de desarrollo de los modelos tampoco hay valores en grado 3) por lo que para esta tesis no se puede conocer la respuesta de los modelos para valores altos de trips.

4.4 Paper EIRCON

Mathematical modeling for prediction of banana rust thrips from atmospheric variables

Carlos Estrada

*Automatic Control Systems Lab
Universidad de Piura*

Piura, Peru

carlos.estrada.macalupu@gmail.com

Jose Manrique

*Automatic Control Systems Lab
Universidad de Piura*

Piura, Peru

jose.manrique@udep.edu.pe

William Ipanaque

*Automatic Control Systems Lab
Universidad de Piura*

Piura, Peru

william.ipanaque@udep.edu.pe

Abstract—The following article presents a mathematical model to describe and predict the level of incidence of rust thrips on organic banana, with the aim of assisting growers in making decisions to reduce the effects of this pest on their crops. The model is based on the Campbell model (a model that depends only on temperature), but a modification is also proposed with the addition of variables such as relative humidity, wind speed and rainfall rate to describe the rate of insects' development. For the estimation of the parameters of the equations, random cross-validation of 100 sets, validated with real measurements of thrips, was used. Using the Campbell model, accuracies greater than 50% were obtained and with the addition of the variables the accuracy increased to 81%.

Keywords—mathematical modeling, pests, IOT sensors, banana rust thrips, prediction model, cross validation.

I. INTRODUCTION

Organic banana is the fourth most important food crop in the world, after rice, wheat, and maize, contributing to the food security of billions of people in much of the world by providing income and employment to rural populations through exports [1]. In the last ten years, Peru, with an area of 197,837 ha [2] in 2017, has joined the large community of organic banana exporting countries, with the main production areas located on the northern coast of the country: Tumbes (13%), Piura (81%), Lambayeque (4%) and La Libertad (2%) [3], with exports reaching around 223,298 tons of organic bananas in 2019 [4]. The organic banana crop is attacked by diseases that affect all the organs that make it up, such as the root system or strain, pseudostem, flower stalk and fruit, the latter being directly related to rust thrips (*Chaetanaphothrips signipennis*) [3]. Since 2010, rust thrips have become a serious pest in organic banana plantations, causing yield losses of 30%-40% [4], and up to 100% of the production, if effective measures are not applied. In the Piura region, it has been reported that this pest is present in approximately 98% of the areas at a low to medium level of infestation; however, 2% of these areas cannot export because of high levels of infestation [5]. The impact of pests is significant for production, making

it necessary to explore for and implement alternative solutions such as precision agriculture, an approach to agricultural management that uses the so-called "4.0 technologies". These technologies, which include smart sensing and automated data collection, big data analytics and modelling approaches, have the potential to increase crop yields, early detect diseases, pests, or weeds, improve control, maximize economic benefits, and ensure the preservation of resources [6]. Multisensor networks in agriculture aim to satisfy different needs with respect to detection, monitoring and control. They collect information for timely intervention for the prevention of situations that lead in yield losses and quality degradation [7]. Mathematical models provide the basis for decision making tools. Linear and nonlinear models have been performed for the development of *Spodoptera litura* (Fabricius) of soybean [8], studies were also conducted to evaluate the effect of weather parameters on sunflower crops where it was possible to predict the crop yield [9].

This research focuses on the mathematical modeling of the thrips population growth by building on the Campbell model [8] [10], with the addition of new parameters, such as the relative humidity, wind speed and rainfall rate. The objective is to investigate and quantify the influence of these variables in the development of the rust thrips, facilitate decision making and thus improve productivity with an early detection of this pest.

II. METHODOLOGY

Data is collected by a sensor network located in the district of Buenos Aires, province of Morropón, department of Piura (Peru) with the coordinates 5° 16' 13.4" S 79° 57' 10.1" W in a 1 ha organic banana plot. The variables of interest are processed to be used as inputs, and subsequently a mathematical model is developed based on the analysis of the thrips behavior observed "experimentally" and implemented in Python, and finally the mathematical model is validated by comparing its predictions with real data. For validation, a cross validation approach has been implemented. The input data $n = nc + nv$ is divided into two sets, with nc the data used for the construction of the model, and nv the data used for the validation of the model [11]. Two metrics from the scikit-learn library were used to analyze the model: the R-squared, which indicates

This research is funded by Proyecto CONCYTEC-Banco Mundial, through its executing unit Fondecyt, under contract 165-2018-FONDECYT-BM-IADT-AV - Project: "Transformación Digital del sector Agro-Industrial aplicado al Banano Orgánico"

how close the data are to the fitted regression line and the RMSE which measures the error between the actual data and those obtained by the model.

A. Data acquisition

For the parameter estimation it is necessary to quantify the amount of rust thrips. This task is performed by a technician who oversees the pest evaluations. Each evaluation is carried out on 25 randomly selected plants and the number of 8 pests (rust thrips, scale, mealybug, weevil, red spider mite, ceramide, aphid, and whitefly) is recorded. At the end of the evaluation the total of each pest is averaged resulting in a value "per plant", which reflects the state of the plot. With respect to the rust thrips, a value greater than 1 or 2 per plant indicates a medium level of infection but requires measures to prevent their spread. These evaluations are carried out once or twice a week and are used for the training and validation of the developed model.

For the environmental parameters a meteorological station consisting of two nodes and a central station is used. The data is uploaded to the cloud every 15 minutes, so there are 96 values in a day, being the variables of interest; ambient temperature, relative humidity, precipitation and wind speed [12].

III. MATHEMATICAL MODELING

A. Development of the mathematical model

The equation (1) describes the population growth of thrips and is based on the exponential model [13], which is a basic model used in population dynamics and can be used to determine the number of microorganisms in a culture at any instant of time, according to an exponential function that can be posed by a first order ordinary differential equation [14].

$$\frac{dIT}{dt} = \beta \times IT - \mu \times IT = (\beta - \mu) \times IT = r \times IT \quad (1)$$

Where IT represents population of Thrips per plant, β represents the birth rate, μ represents the death rate and r describes the growth rate. From equation (1) a differential equation is modeled that does not consider a constant value for the growth rate, but adds the influenced of the crop conditions such as pesticide spraying, cleaning that affect thrips' mortality.

$$r = \beta - \mu - \alpha_1 \times F1 - \alpha_2 \times F2 - \gamma \times C \quad (2)$$

Where β is the rate of thrips development, μ is the natural mortality rate, α_1 is the mortality rate from spraying with chemical 1, α_2 is the mortality rate from spraying with chemical 2, γ is the mortality rate from the cleaning.

To date, two types of pesticides were sprayed in the plot. The first is purely for the rust thrips, hence more aggressive, and the second is used against pests such as the red spider mite, whitefly, etc., so the effect is weaker. For this reason, F_1 and F_2 are considered in the modeling by modifying an

equation used to describe antibiotic degradation in bacteria [15] and described using the following equations:

$$F_1 = e^{-\varphi_{f1} \times timeF1} \quad (3)$$

$$F_2 = e^{-\varphi_{f2} \times timeF2} \quad (4)$$

Where F_1 is the concentration of organic pesticide 1, F_2 is the concentration of organic pesticide 2, φ_{f1} is the degradation rate of pesticide 1, φ_{f2} is the degradation rate of pesticide 2, $timeF1$ is the difference between the current day and the day pesticide 1 was sprayed, $timeF2$ is the difference between the current day and the day pesticide 2 was sprayed.

During the third nymphal stage, the mature nymphs migrate from the plant to the soil or epidermis and transform into pre-pupae. At this stage, the cleanliness of the plot is an influential factor in the thrips population growth. For this reason, the rate of cleanliness is considered in the model and in a similar way as spraying:

$$C = e^{-\varphi_c \times timeC} \quad (5)$$

Where C is the variable representing the cleanliness of the plot, φ_c is the degradation rate of the cleanliness level. Equation (1) would be described as follows:

$$\frac{dIT}{dt} = (\beta - \mu - \alpha_1 \times F1 - \alpha_2 \times F2 - \gamma \times C) \times IT \quad (6)$$

B. Campbell Model

The rate of development of insects in general is related to the temperature to which they are exposed and is approximated by a linear equation in the Campbell's model [8] [10].

$$\beta = a + b \times T \quad (7)$$

The parameters a and b are constants estimated from "experimental" data, a is the intercept with the rate of development, b is the slope relating temperature to the rate of thrips development, and T is the temperature (microclimate) [8].

C. Modified Campbell model

The Campbell model only takes into account the temperature, leaving out variables such as rainfall, wind speed and humidity, therefore, this research seeks to improve the Campbell model by adding these variables that are measured in the plot, leaving the expression for the development rate as follows:

$$\beta = a + b \times T + C \times H + D \times V + E \times R \quad (8)$$

Where H is the relative microclimate humidity, V the wind speed, and R rain rate, while C , D , E , as well as a and b are dimensionless numbers whose values are calculated by parameter estimation using Python.

IV. RESULTS

For each simulation (two in total) 100 sets (input data and thrips measurements) have been randomly generated, and each set is divided into 75% training data and 25% validation data. The Python code adjusts the values of all the parameters and does so for each set, taking the real thrips data as a reference. The following histograms (R-squared and RMSE) describe the results of the metrics for all 100 sets.

A. Campbell model

Tables I shows the average values of the simulation results:

TABLE I
AVERAGE SIMULATION PARAMETERS

Parameters	Average	Parameters	Average
a	-0.0957	γ	0.1214
b	0.0142	ϕ_{f1}	0.0985
μ	0.1836	ϕ_{f2}	0.5926
α_1	0.6351	ϕ_c	0.0655
α_2	0.0953		

In the training sets of model 1, good fits were obtained, more than 75% of the results had an R-squared between 0.75 and 0.90 with the average being approximately 0.78. In the test sets (Fig. 1), more than 50% of the sets had an R-squared greater than 0.60, the average being 0.66.




Fig. 1. R-squared of test sets in model 1.

Approximately 70% of the ensemble results had an RMSE value between 1.40 and 1.60, 15% with better results between 1.05 and 1.30 while the remainder obtained RMSE values greater than 1.80. On average, an RMSE value of approximately 1.50 was obtained for the training set. For the test sets (Fig. 2), 98% of the data had an RMSE value between 0.50 and 3.60 with the average being approximately 1.60.

B. Modified Campbell Model

Table II shows the average values of the parameters of model 2.

For model 2 better results were obtained, where almost 80% of the training sets had an R-squared with values greater than 0.75, the average of all sets being 0.80. In the test sets (Fig. 3)




Fig. 2. RMSE of test sets in model 1.

TABLE II
AVERAGE SIMULATION PARAMETERS

Parameters	Average	Parameters	Average
a	-0.0632	α_1	0.7664
b	0.0288	α_2	0.0751
C	-0.0049	γ	0.2699
D	0.1399	ϕ_{f1}	0.1081
E	-0.6666	ϕ_{f2}	0.4190
μ	0.24349	ϕ_c	0.0785

75% of the sets had an r-squared higher than 0.60 and on average of all sets an r-squared of 0.70 was obtained.




Fig. 3. R-squared of test sets model 2.

In model 2 the RMSE values are less than 2.0 for all sets and on average about 1.45 is obtained and for the test (Fig. 4) sets the average is 1.55. Based on these metrics it can be concluded that model 2 is more accurate than model 1.

TABLE III
MODEL 1 METRICS (AVERAGE VALUES).

	MODEL 1		MODEL 2	
	<i>R-squared</i>	<i>RMSE</i>	<i>R-squared</i>	<i>RMSE</i>
Train	0.78	1.50	0.80	1.45
Test	0.66	1.60	0.70	1.55

The average of the metrics of both simulations is shown in Table III, where it can be concluded that model 2 is more




Fig. 4. RMSE of test sets model 2.

accurate, and this is verified in the validation.

C. Validation

For the validation of the models, the data recorded from April 15, 2021, to May 15, 2021, were used. There are 30 days of data and in that range of time 5 pest evaluations were carried out, therefore there are 5 points of comparison between the predicted model results and the real data. According to the simulations the mathematical model 2 has better results. Metrics with values of 0.81 and 1.25 are obtained while in model 1, 0.50 and 2.04 are obtained for R-squared and RMSE respectively.




Fig. 5. Validation of model 1.




Fig. 6. Validation of model 2.

V. CONCLUSIONS

It has been demonstrated that it is possible to obtain a mathematical model for the prediction of banana rust thrips

based on the proposed analysis, together with the improvement of the Campbell's model. This has been achieved by incorporating new variables (e.g., relative humidity, wind speed, rainfall) that make the model more robust. It is also possible to extend the analysis and quantify the influence of each variable on the model. A limitation for this paper has been the reduced amount of data that have been recorded (454 were used for the creation of the model). However, with the new data that are taken day by day, the proposed model can be significantly improved. This is an important contribution for organic banana growers because understanding the banana rust thrips population behavior with respect to the climate variables studied enables them to will take preventive measures before infestation takes place, and thus improve productivity.

REFERENCES

- [1] MINAGRI, "El banano peruano producto estrella de exportación," Tech. Rep., 2014.
- [2] J. Sánchez Castañeda, "Mercado de productos agrícolas ecológicos en colombia," *Suma de Negocios*, vol. 8, no. 18, pp. 156–163, 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2215910X1730023X>
- [3] J. C. Rojas Llanque, "Manejo integrado de banano organico," Tech. Rep., 2013.
- [4] M. Lopez, R. Corozo-Ayovi, R. Delgado, B. Osorio, D. Moyón, D. Rengifo, P. Suarez, A. Paulino, S. Medrano, L. Sanchez, J. Rojas Llanque, U. Vegas, D. Alburquerque, C. Staver, R. Van Tol, and L. Clercx, "Red rust thrips in smallholder organic export banana in latin america and the caribbean: pathways for control, compatible with organic certification," *Acta Horticulturae*, pp. 153–161, 03 2020.
- [5] J. C. Rojas, "Manejo integrado de plagas y enfermedades en banano orgánico y convencional," Tech. Rep., 2013.
- [6] m. c. Anzosi, F. Brunetta, A. Monti, and F. Nat, "Is the trend your friend? an analysis of technology 4.0 investment decisions in agricultural smes," *Computers in Industry*, vol. 109, pp. 59–71, 08 2019.
- [7] X. E. Pantazi, D. Moshou, and D. Bochtis, "Chapter 3 - utilization of multisensors and data fusion in precision agriculture," in *Intelligent Data Mining and Fusion Systems in Agriculture*, X. E. Pantazi, D. Moshou, and D. Bochtis, Eds. Academic Press, 2020, pp. 103–173. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/B9780128143919000030>
- [8] Y. G. Prasad, M. Gayathri, V. Sailaja, M. Prabhakar, G. Ramachandra Rao, G. Rekha, and S. Vennila, "Evaluation of linear and nonlinear models for temperature driven development of spodoptera litura (fabri-cius) on soybean crop," *Journal of Agrometeorology*, vol. 23, no. 2, pp. 169–175, 2021.
- [9] J. Singh and KAUR-PRABHJYOT, "Formulation of weekly and monthly thumb rule models for prediction of potential productivity of sunflower in punjab," *Journal of Agrometeorology*, vol. 23, no. 2, pp. 176–182, 2021.
- [10] A. Campbell, B. D. Frazer, N. Gilbert, A. P. Gutierrez, and M. J. P. Mackauer, "Temperature requirements of some aphids and their parasites," *Journal of Applied Ecology*, vol. 11, pp. 431–438, 1974.
- [11] A. Kozak and R. Kozak, "Does cross validation provide additional information in the evaluation of regression models?" *Canadian Journal of Forest Research*, vol. 33, 02 2011.
- [12] A. Elbehri, G. Calberto, C. Staver, A. Hospido, L. Roibas, D. Skully, P. Siles, J. Arguello, I. Sotomayor, and A. Bustamante, *Cambio climático y sostenibilidad del banano en el Ecuador: Evaluación de impacto y directrices de política*. Roma, Italia: Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), Roma, Italia, 2015.
- [13] J. Murray, *Mathematical Biology I: An Introduction*, 01 2002, vol. 1.
- [14] D. M. H. y José Díaz Rivera, "Determinación de parámetros del modelo exponencial mediante una aplicación móvil," *CIENCIA ergo-sum*, vol. 25, no. 2, 2018. [Online]. Available: <https://cienciaergosum.uaemex.mx/article/view/10099>
- [15] J. Romero Leiton, E. Ibarquen-Mondragon, and L. Esteva, "Un modelo matemático sobre bacterias sensibles y resistentes a antibióticos," *Matemáticas: Enseñanza Universitaria*, vol. 20, pp. 55–73, 01 2011.



Conclusiones

Se ha demostrado que es posible obtener un modelo matemático para la predicción de los trips de la mancha roja basado en el análisis propuesto, junto con la mejora del modelo de Campbell. Esto se ha logrado mediante la incorporación de nuevas variables (humedad relativa, velocidad del viento y precipitación) que hacen que el modelo sea más robusto.

Es posible ampliar el análisis y cuantificar la influencia de cada variable en el modelo. Una limitación para este trabajo ha sido la reducida cantidad de datos que se han registrado (se utilizaron 454 utilizados para la creación del modelo). Sin embargo, con los nuevos datos que se toman día a día, el modelo propuesto puede ser mejorado significativamente el modelo propuesto.

Esta es una contribución importante para los productores de banano orgánico, ya que la comprensión del desarrollo poblacional de los trips de la mancha roja con respecto a las variables climáticas estudiadas puede permitir tomar medidas preventivas antes de que se produzca la infestación, y así mejorar la productividad de los agricultores y optimizar los costes del mantenimiento de la parcela.

Los resultados obtenidos muestran una buena concordancia con los datos experimentales, proporcionando una solución que puede ser implementada en herramientas de toma de decisiones para los productores de plátano ecológico. Estas pueden ser utilizadas en trabajos a futuro para mejorar el monitoreo y control de la incidencia de la plaga, definiendo mejores programas de fumigación y limpieza que aumenten su eficiencia y beneficien la calidad del producto final.



Referencias bibliográficas

- Agrobanco. (2013). *Manejo integrado de banano orgánico*. La libertad.
- Almeyda, E., & Ipanaque, W. (2022). Recent developments of artificial intelligence for banana: Application areas, learning algorithms, and future challenges. *Engenharia Agrícola [online]*, v.42. DOI: <https://doi.org/10.1590/1809-4430-Eng.Agric.v42nepe20210144/2022>.
- Almeyda, E., Paiva, J., & Ipanaque, W. (2020). Pest Incidence Prediction in Organic Banana Crops with Machine Learning Techniques. *IEEE Engineering International Research Conference (EIRCON)*, DOI: 10.1109/EIRCON51178.2020.9254034.
- Arias de López, M., Corozo-Ayovi, R., Delgado, R., Osorio, B., Moyón, D., Rengifo, D., . . . Clercx, L. (2020). Red rust thrips in smallholder organic export banana in Latin America and the Caribbean: pathways for control, compatible with organic certification. *International Symposium on Banana: ISHS-ProMusa Symposium*.
- Augura. (2009). *Identificación y manejo integrado de plagas en banano y plátano Magdalena y Urabá Colombia*. Medellín: Comunicaciones AUGURA.
- Benavides Martinez, Á. (2020). *Sorpresivo ataque de "arañita roja" en plantaciones de banano en Urabá*.
- Campbell, A., Frazer, B. D., Gilbert, N., Gutierrez, A. P., & Mackauer, M. (1974). Temperature requirements of some aphids and their parasites. *Journal of Applied Ecology*, 11(2), 431-438. <https://doi.org/10.2307/2402197>.
- Castillo Jiménez, D. B. (2021). *Determinar la correlación poblacional del "Trips de la mancha roja" Chaetanaphotrips signipennis en cultivo de banano orgánico en los distritos de Buenos Aires, Carrasquillo y La Matanza*. Tesis Ing. Piura: Universidad Nacional de Piura.
- Castillo Martínez, F. D., & Rodríguez García, W. (2019). *Análisis y propuesta de mejora de la cadena de suministro de banano orgánico de las provincias de Morropón y Sullana [Título profesional, Universidad de Piura]*. Repositorio PIRHUA de la Universidad de Piura.
- Cox Quiñonez, G. (2019). *Control de Ceramidia viridis en el cultivo de banano (Musa AAA)*. Ing. Babahoyo: Universidad Técnica de Babahoyo.

- Cubillo, D., & Gonzáles, M. (setiembre de 2014). *plantwise*. Obtenido de plantwise: <https://www.plantwise.org/KnowledgeBank/pmdg/20167801162>
- Elbenri, A. G., Staver, C., Hospido, A., Roibas, L., Skully, D., Siles, P., . . . Bustamante, A. (2015). *Cambio climático y sostenibilidad del banano en el Ecuador: Evaluación de impacto y directrices de política*. Roma, Italia: Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO).
- Esteva, L., Ibargüen Mondragon, E., & Romero Leyton, J. (2011). *Un modelo matemático sobre bacterias sensibles y resistentes a antibióticos*. Matemáticas: Enseñanza Universitaria.
- Evans, E. A., Ballen, F. H., & Siddiq, M. (2020). Banana Production, Global Trade, Consumption Trends, Postharvest Handling, and Processing. *Banana production, posharvest science, processing technology, and nutrition*, 1-18. DOI: <https://doi.org/10.1002/9781119528265.ch1>.
- FAO. (26 de Octubre de 2016). FAO. Obtenido de FAO: <https://www.fao.org/zhc/detail-events/es/c/447827/#:~:text=El%20banano%20Cavendish%20contiene%20unos,contolar%20la%20actividad%20del%20coraz%C3%B3n>.
- FAO. (2019). *Análisis del mercado del banano*.
- FAO. (2021). *Banana Market Review 2020*. Rome.
- fatsecret. (4 de febrero de 2022). *fatsecret*. Obtenido de fatsecret: <https://www.fatsecret.com.mx/calor%C3%ADas-nutrici%C3%B3n/gen%C3%A9rico/banano?portionid=32978&portionamount=1,000>
- fruit, f. (28 de febrero de 2021). *fresh fruit*. Obtenido de fresh fruit: <https://freshfruit.pe/2021/02/28/las-exportaciones-de-banano-siguen-creciendo/>
- Giraldo Jaramillo, M. (2018). Efecto de la humedad relativa sobre la duración y sobrevivencia de *Hypothenemus hampei* en dieta artificial cenibroca. *Cenicafé*, 69(1), 32-39.
- GORE. (2017). *Trips de la macha roja*. Piura.
- GORE. (2018). *La agricultura en Piura*. Piura.
- Guzmán Velásquez, P. (2014). *Estudio experimental de la elaboración de puré de banano orgánico de la región Piura [Título profesional, Universidad de Piura]*. Repositorio institucional PIRHUA de la Universidad de Piura. https://pirhua.udep.edu.pe/bitstream/handle/11042/2044/ING_546.pdf?sequence=1&isAllowed=y.
- INFOCOM. (2000). *Banano*. Ginebra, Suiza.
- Ipanaqué Alama, W., Belupú, I., Estrada, C., Neyra Hau Yon, J., & Campos Cercado, J. (2021). *Producto 6. Monografía de diseño técnico de la aplicación*. Fontagro.

- León Tigrero, J. C. (2018). *Evaluación de la funda protectora impregnada con Bifentrina sobre el daño de la "mancha roja" causado por Chaetanaphotrips signipennis en banano*, ING. Babahoyo: Universidad Técnica de Babahoyo.
- M. Lopez, R. C.-A. (2021). Red rust thrips in smallholder organic export banana in latin america and the caribbean: pathways for control, compatible with organic certification. *Acta Horticulturae*, pp. 153–161. DOI: 10.17660/ActaHortic.2020.1272.19.
- Manrique Silupu, J., Campos, J. C., Paiva, E., & Ipanaqué, W. (2021). Thrips incidence prediction in organic banana crop with Machine learning. *Heliyon*, 7(e08575). DOI: <https://doi.org/10.1016/j.heliyon.2021.e08575>.
- Mifflin, I., Luque, A., Peter, M., & Chiaravalli, M. (2017). *Innovación tecnológica en el banano orgánico*. Lima: Nova Print S.A.C.
- Milics, G. (2019). Application of UAVs in Precision Agriculture. *International Climate Protection*, 93-97.
- MINAGRI. (Noviembre de 2014). *El Banano Peruano "Producto Estrella de Exportación"*. Lima: MINAGRI - DGPA. Obtenido de <https://www.minagri.gob.pe> › portal › analisis-economico › analisis-2014
- Moysiadis, V., Sarigiannidis, P., Vitsas, V., & Khelifi, A. (2021). Smart Farming in Europe. *Computer Science Review*, 39,100345.
- Prasad, Y. G., Gayathri, M., Sailaja, V., Prabhakar, M., Ramachandra Rao, G., & Vennila, S. (2021). Evaluation of linear and nonlinear models for temperature driven development of *Spodoptera litura* (Fabricius) on soybean crop. *Journal of Agrometeorology*, 23(2), 169-175. <https://doi.org/10.54386/jam.v23i2.63>.
- Quiroga Montoya, E. A., Jaramillo Colorado, S. F., Campo Muñoz, W. Y., & Chanchi Golondrino, G. (2016). Propuesta de una Arquitectura para Agricultura de Precisión Soportada en IoT. *Revista Ibérica de Sistemas y Tecnologías de Información*, 39-56.
- Ribarics, P. (2016). Big Data and its impact on agriculture. *Ecocycles*, 2(1), 33-34.
- RPP. (19 de noviembre de 2017). *El "Niño Costero" afectó exportaciones de banano orgánico en Piura*. Obtenido de RPP: <https://rpp.pe/peru/piura/los-efectos-del-nino-costero-golpean-exportaciones-de-banano-organico-en-piura-noticia-1089444?ref=rpp>
- Singh, J., & Kaur, P. (2021). Formulation of weekly and monthly thumb rule models for prediction of potential productivity of sunflower in Punjab. *Journal of Agrometeorology*, 23(2), 176-182. DOI: <https://doi.org/10.54386/jam.v23i2.63>.
- Torres, S. (2012). *Guía práctica para el manejo de banano orgánico en el valle del Chira*. Piura.

Vargas Céspedes, A., Morales, M., Watler, W., & Vignola, R. (2012). *Ficha técnica Cultivo de banano*. Piura.



Apéndices





Apéndice A. Algoritmo MM1

```

import numpy as np
from numpy.core.numeric import Inf
from numpy.lib.function_base import append
from scipy.integrate import odeint
import matplotlib.pyplot as plt
import math
import copy
import seaborn as sns
from scipy.optimize import minimize
from scipy.optimize import Bounds

import pandas as pd
import time
from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score
from sklearn.model_selection import GroupShuffleSplit

tic = time.time()

print('Defining ODE equation...')
def ODE_PobThrips(PT, t, x, parameters):
    a = parameters[0]
    b = parameters[1]
    mu = parameters[2]
    alfa1 = parameters[3]
    alfa2 = parameters[4]
    gamma = parameters[5]

    degF1 = parameters[6]
    degF2 = parameters[7]
    degL = parameters[8]

    Temp = x[0]
    time_F1 = x[1]
    time_F2 = x[2]
    time_L = x[3]

    F1 = np.exp(-degF1*time_F1)
    F2 = np.exp(-degF2*time_F2)
    L = np.exp(-degL*time_L)
    #print("F1,F2,L:", F1,F2,L)
    dPT = ((a + b*Temp) -mu- alfa1*F1 - alfa2*F2 - gamma*L)*PT

    return dPT

print('Defining Integration function...')
def IntODE(t, PT0, matriz_x, parameters):
    sol = PT0
    for k in range(len(t)-1):
        time = [t[k], t[k+1]]

```

```

        x = matriz_x[k,:]
        sol = odeint(ODE_PobThrips, sol, time, args=(x,parameters)
,rtol=1e-4, atol=1e-4)
        sol = sol[-1].item()
        if sol < 0.04:
            sol = 0.04
    return sol

print('Defining Multi period integration function ...')
def IntMultiPeriod(vector_t, PT_real, MATRIZ_X, parameters):
    PT_sim = []
    PT_sim.append(PT_real[0])
    for k in range(len(vector_t)-1):
        t = np.linspace(vector_t[k],vector_t[k+1],vector_t[k+1]-
vector_t[k]+1)
        matriz_x = MATRIZ_X[vector_t[k]:vector_t[k+1],:]
        PT_sim.append(IntODE(t, PT_real[k], matriz_x, parameters))
    return PT_sim

print('Defining Objective function...')
def ObjectiveFunction(parameters, t, PT_real, MATRIZ_X):
    ResultsSim = IntMultiPeriod(t, PT_real, MATRIZ_X, parameters)
    ObjectiveValue = mean_squared_error(PT_real,ResultsSim)
    return ObjectiveValue

print('Setting parameter limit values...')

a_Max = 0
a_min = -0.15

b_Max = 0.1
b_min= 0

mu_Max = 0.5
mu_min = 0

alfa1_Max = 0.9
alfa1_min = 0.3

alfa2_Max = 0.65
alfa2_min = 0

gamma_Max = 0.55
gamma_min = 0

degF1_Max = 0.5
degF1_min = 0

degF2_Max = 0.8
degF2_min = 0.45

degLim_Max = 0.2
degLim_min = 0

```

```

UpperBound = [a_Max, b_Max, mu_Max, alfa1_Max, alfa2_Max, gamma_Max,
degF1_Max, degF2_Max, degLim_Max]
LowerBound = [a_min, b_min, mu_min, alfa1_min, alfa2_min, gamma_min,
degF1_min, degF2_min, degLim_min]
bounds_Opt = Bounds(LowerBound, UpperBound)

print('Setting parameter initial values...')

parameters = [-0.1221, 0.01251, 0.15780168, 0.56494051, 0.05330372,
0.02, 0.0455004, 0.60010958, 0.04795748]
#a, b, mu, alfa1, alfa2
#gamm, degf1, degf2, degc

print('Uploading input data ...')
inputs = pd.read_csv("dataEntrada2.csv", sep=";")
MATRIX_X = np.array(inputs[["TempMic", "tF1", "tF2", "tL"]])

print('Uploading output data ...')
outputs = pd.read_csv("dataSalida2.csv", sep=";")
t = np.array(outputs[["t_y"]])
t = np.ravel(t)
PT_real = np.array(outputs[["y"]])
PT_real = np.ravel(PT_real)
#pt_real = np.log(PT_real)

('Splitting training and test dataset for cross validation ...')
groups = np.array(range(113))
gss = GroupShuffleSplit(n_splits=100, train_size=.75, random_state=15)

('Setting conditions for training sets...')
fold_no = 1
fun_per_fold = []
success_per_fold = []
par_per_fold = []
r2train_per_fold = []
RMSEtrain_per_fold = []
r2test_per_fold = []
RMSEtest_per_fold = []
font = {'family': 'Tahoma',
'color': 'black',
'weight': 'normal',
'size': 14,
}

('Training and validation loop for defined data sets')
for train, test in gss.split(t, PT_real, groups):
    print('Training Set N°: ', fold_no)
    t_train = t[train]
    t_test = t[test]
    PT_train = PT_real[train]
    PT_test = PT_real[test]
    print('Estimating parameters')

```



```

    result = minimize(ObjectiveFunction, parameters, args = (t_train,
PT_train, MATRIX_X), bounds=bounds_Opt, options={'maxiter':500,'disp':
True})

    nuevos_params = result.x
    par_per_fold.append(nuevos_params)
    fun_per_fold.append(result.fun)
    success_per_fold.append(result.success)

    print('Simulation ')
    PT_sim = IntMultiPeriod(t, PT_real, MATRIX_X, result.x)
    PT_sim = np.array(PT_sim)
    PT_sim_train = PT_sim[train]
    PT_sim_test = PT_sim[test]

    r2train_per_fold.append(r2_score(PT_train,PT_sim_train))
    r2test_per_fold.append(r2_score(PT_test,PT_sim_test))
    RMSEtrain_per_fold.append(np.sqrt(mean_squared_error(PT_train,PT_sim_t
rain)))
    RMSEtest_per_fold.append(np.sqrt(mean_squared_error(PT_test,PT_sim_tes
t)))

    print('Dataset N° ',fold_no, ' termination.')
    fold_no += 1

print("fun_per_fold:", fun_per_fold)
#metrica r2
r2_train_test = [r2train_per_fold,r2test_per_fold]
RMSE_train_test = [ RMSEtrain_per_fold, RMSEtest_per_fold]

np.save("Result_simulation.npy",par_per_fold)
np.save("Result_R2.npy",r2_train_test)
np.save("Result_RMSE.npy",RMSE_train_test)

print('Statistical analysis.')
alfa1_list = []
alfa2_list = []
gamma_list = []
degF1_list = []
degF2_list = []
degLim_list = []
a_list = []
b_list = []
mu_list = []
C_list = []
D_list = []
E_list = []

for params in par_per_fold:
    a_list.append(params[0])
    b_list.append(params[1])
    mu_list.append(params[2])
    alfa1_list.append(params[3])
    alfa2_list.append(params[4])

```

```

gamma_list.append(params[5])
degF1_list.append(params[6])
degF2_list.append(params[7])
degLim_list.append(params[8])

def histograma(serie, nombre):
    plt.figure(figsize=(7,5))
    sns.histplot(serie)
    plt.axvline(serie.mean(), linestyle="dashed", label="mean", color="k")
    plt.legend(loc="best",prop={"size":14})
    plt.title(nombre, size = 14)
    plt.show()

print('Plotting graphs')

histograma(np.array(a_list),'Parameter "a"')
histograma(np.array(b_list),'Parameter "b"')
histograma(np.array(mu_list),'Parameter "mu"')
histograma(np.array(alfa1_list),'Parameter "alfa1" ')
histograma(np.array(alfa2_list),'Parameter "alfa2"')
histograma(np.array(gamma_list),'Parameter "gamma" ')
histograma(np.array(degF1_list),'Parameter "Degradation Fumigation 1" ')
histograma(np.array(degF2_list),'Parameter "Degradation Fumigation 2" ')
histograma(np.array(degLim_list),'Parameter "Degradation Cleaning" ')
#metricas
histograma(np.array(r2train_per_fold),'R2 train')
histograma(np.array(r2test_per_fold),'R2 test')
histograma(np.array(RMSEtrain_per_fold),'RMSE train')
histograma(np.array(RMSEtest_per_fold),'RMSE test')
#resultados de los conjuntos

print('Best model selection.')
err = np.abs(np.array(r2train_per_fold)-np.array(r2test_per_fold))
min_err = min(err)
index_min = np.where(err == min_err)
index_min = index_min[0][0]
print('Conjunto con mejores resultados: ',index_min)
print('R2 train mejor conjunto: ', r2train_per_fold[index_min])
print('R2 test mejor conjunto: ',r2test_per_fold[index_min])
params_opt = par_per_fold[index_min]
print('parametros optimos:', params_opt)
print('Model validation with new data.')
in_validation = pd.read_csv("dataEntradaValidacion.csv", sep=";")
out_validation = pd.read_csv("dataSalidaValidacion.csv", sep=";")
print('Uploading validation data')
MATRIX_X_val = np.array(in_validation[["TempMic","tF1","tF2","tL"]])
t_val = np.array(out_validation[["t"]])
t_val = np.ravel(t_val)
PT_val = np.array(out_validation[["y"]])
PT_val = np.ravel(PT_val)
print('Simulation with validation data')
PT_sim_val = IntMultiPeriod(t_val, PT_val, MATRIX_X_val, params_opt)
PT_sim_val = np.array(PT_sim_val)

```

```

print('R2 Validacion: ', r2_score(PT_val,PT_sim_val))
print('RMSE Validacion: ',np.sqrt(mean_squared_error(PT_val,PT_sim_val)))

fig = plt.figure(figsize=(7,5))
ax = plt.scatter(t_val, PT_val)
ax = plt.scatter(t_val, PT_sim_val,marker="+" )
plt.legend(['Real', 'Model'])
plt.title("Training", fontdict=font)
plt.xlabel("Days", fontdict=font)
plt.ylabel("Thrips Incidence (Insects/Plant)", fontdict=font)
plt.show()

##desviacion estandar
a_STD = np.array(a_list).std()
b_STD = np.array(b_list).std()
mu_STD = np.array(mu_list).std()
alfa1_STD = np.array(alfa1_list).std()
alfa2_STD = np.array(alfa2_list).std()
gamma_STD = np.array(gamma_list).std()
degF1_STD = np.array(degF1_list).std()
degF2_STD = np.array(degF2_list).std()
degC_STD = np.array(degLim_list).std()

#STD = [a_STD, b_STD, mu_STD, alfa1_STD, alfa2_STD, gamma_STD, degF1_STD,
degF2_STD, degC_STD, C_STD, D_STD, E_STD]

STD = [a_STD, b_STD, mu_STD, alfa1_STD, alfa2_STD, gamma_STD, degF1_STD,
degF2_STD, degC_STD]
np.save("Result_STD.npy", STD)
parameters = ['a', 'b', 'mu', 'alfa1', 'alfa2', 'gamma', 'degF1', 'degF2',
'degC']
a_m = np.array(a_list).mean()
b_m = np.array(b_list).mean()
mu_m = np.array(mu_list).mean()
alfa1_m = np.array(alfa1_list).mean()
alfa2_m = np.array(alfa2_list).mean()
gamma_m = np.array(gamma_list).mean()
degF1_m = np.array(degF1_list).mean()
degF2_m = np.array(degF2_list).mean()
degC_m = np.array(degLim_list).mean()
Mean = [a_m, b_m, mu_m, alfa1_m, alfa2_m, gamma_m, degF1_m, degF2_m,
degC_m]
np.save("Result_mean.npy", Mean)
fig = plt.figure(figsize=(8,5))
ax = plt.errorbar(parameters, Mean, yerr=STD, fmt='bo', ecolor='r',
barsabove = 'True')
plt.title("Model Campbell", fontdict=font)
plt.xlabel("Model parameters", fontdict=font)
plt.ylabel("Value", fontdict=font)
plt.show()

toc = time.time()
elapsed = toc - tic
print('Simulation time (min): ', elapsed/60)

```

Apéndice B. Algoritmo MM2

```

import numpy as np
from numpy.core.numeric import Inf
from numpy.lib.function_base import append
from scipy.integrate import odeint
import matplotlib.pyplot as plt
import math
import copy
import seaborn as sns
from scipy.optimize import minimize
from scipy.optimize import Bounds

import pandas as pd
import time
from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score
from sklearn.model_selection import GroupShuffleSplit

tic = time.time()

print('Defining ODE equation...')
def ODE_PobThrips(PT, t, x, parameters):
    a = parameters[0]
    b = parameters[1]
    C = parameters[2]
    D = parameters[3]
    E = parameters[4]
    mu = parameters[5]
    alfa1 = parameters[6]
    alfa2 = parameters[7]
    gamma = parameters[8]

    degF1 = parameters[9]
    degF2 = parameters[10]
    degL = parameters[11]

    Temp = x[0]
    humed = x[1]
    viento = x[2]
    Tlluvia = x[3]
    time_F1 = x[4]
    time_F2 = x[5]
    time_L = x[6]

    F1 = np.exp(-degF1*time_F1)
    F2 = np.exp(-degF2*time_F2)
    L = np.exp(-degL*time_L)
    #print("F1,F2,L:", F1,F2,L)
    dPT = ((a + b*Temp+C*humed+D*viento+E*Tlluvia) -mu- alfa1*F1 -
    alfa2*F2 - gamma*L)*PT

```

```

return dPT

print('Defining Integration function...')
def IntODE(t, PT0, matriz_x, parameters):
    sol = PT0
    for k in range(len(t)-1):
        time = [t[k], t[k+1]]
        x = matriz_x[k,:]
        sol = odeint(ODE_PobThrips, sol, time, args=(x,parameters)
,rtol=1e-4, atol=1e-4)
        sol = sol[-1].item()
        if sol < 0.04:
            sol = 0.04
    return sol

print('Defining Multi period integration function ...')
def IntMultiPeriod(vector_t, PT_real, MATRIZ_X, parameters):
    PT_sim = []
    PT_sim.append(PT_real[0])
    for k in range(len(vector_t)-1):
        t = np.linspace(vector_t[k],vector_t[k+1],vector_t[k+1]-
vector_t[k]+1)
        matriz_x = MATRIZ_X[vector_t[k]:vector_t[k+1],:]
        PT_sim.append(IntODE(t, PT_real[k], matriz_x, parameters))
    return PT_sim

print('Defining Objective function...')
def ObjectiveFunction(parameters, t, PT_real, MATRIX_X):
    ResultsSim = IntMultiPeriod(t, PT_real, MATRIX_X, parameters)
    ObjectiveValue = mean_squared_error(PT_real,ResultsSim)
    return ObjectiveValue

print('Setting parameter limit values...')

a_Max = 0
a_min = -0.2

b_Max = 0.0375
b_min= 0.0265

C_Max = 0
C_min = -0.016

D_Max = 0.45
D_min = 0

E_Max = 0
E_min = -1.4

mu_Max = 0.65
mu_min = 0

alfa1_Max = 0.9
alfa1_min = 0.4

```

```

alfa2_Max = 0.15
alfa2_min = 0

gamma_Max = 0.8
gamma_min = 0

degF1_Max = 0.2
degF1_min = 0

degF2_Max = 0.429
degF2_min = 0.408

degLim_Max = 0.141
degLim_min = 0

UpperBound = [a_Max, b_Max, C_Max, D_Max, E_Max, mu_Max,
               alfa1_Max, alfa2_Max, gamma_Max, degF1_Max, degF2_Max, degLim_Max]
LowerBound = [a_min, b_min, C_min, D_min, E_min, mu_min,
               alfa1_min, alfa2_min, gamma_min, degF1_min, degF2_min, degLim_min]
bounds_Opt = Bounds(LowerBound, UpperBound)

print('Setting parameter initial values...')

parameters = [-0.10659105, 0.04543748, -0.01375856, 0.32482888, -0.25,
              0.17233691,
              0.5999726, 0.05301236, 0.04999256, 0.05238576, 0.42, 0.10002858]
#alf1,alf2, gamm,degf1,degf2,degc

print('Uploading input data ...')
inputs = pd.read_csv("dataEntrada2.csv", sep=";")
MATRIX_X = np.array(inputs[["TempMic", "Hum", "Vel
Viento", "TasaLluvia", "tF1", "tF2", "tL"]])

print('Uploading output data ...')
outputs = pd.read_csv("dataSalida2.csv", sep=";")
t = np.array(outputs[["t_y"]])
t = np.ravel(t)
PT_real = np.array(outputs[["y"]])
PT_real = np.ravel(PT_real)
#pt_real = np.log(PT_real)

('Splitting training and test dataset for cross validation ...')
groups = np.array(range(113))
gss = GroupShuffleSplit(n_splits=500, train_size=.75, random_state=15)

('Setting conditions for training sets...')
fold_no = 1
fun_per_fold = []
success_per_fold = []
par_per_fold = []
r2train_per_fold = []
RMSEtrain_per_fold = []
r2test_per_fold = []

```



```

RMSEtest_per_fold = []
font = {'family': 'Tahoma',
        'color': 'black',
        'weight': 'normal',
        'size': 14,
        }

('Training and validation loop for defined data sets')
for train, test in gss.split(t, PT_real, groups):
    print('Training Set N°: ', fold_no)
    t_train = t[train]
    t_test = t[test]
    PT_train = PT_real[train]
    PT_test = PT_real[test]
    print('Estimating parameters')
    result = minimize(ObjectiveFunction, parameters, args = (t_train,
PT_train, MATRIX_X), bounds=bounds_Opt, options={'maxiter':500,'disp':
True}))

    nuevos_params = result.x
    par_per_fold.append(nuevos_params)
    fun_per_fold.append(result.fun)
    success_per_fold.append(result.success)

    print('Simulation ')
    PT_sim = IntMultiPeriod(t, PT_real, MATRIX_X, result.x)
    PT_sim = np.array(PT_sim)
    PT_sim_train = PT_sim[train]
    PT_sim_test = PT_sim[test]

    r2train_per_fold.append(r2_score(PT_train,PT_sim_train))
    r2test_per_fold.append(r2_score(PT_test,PT_sim_test))
    RMSEtrain_per_fold.append(np.sqrt(mean_squared_error(PT_train,PT_sim_t
rain))))
    RMSEtest_per_fold.append(np.sqrt(mean_squared_error(PT_test,PT_sim_tes
t))))

    print('Dataset N° ',fold_no, ' termination.')
    fold_no += 1

print("fun_per_fold:", fun_per_fold)
#metrica r2
r2_train_test = [r2train_per_fold,r2test_per_fold]
RMSE_train_test = [ RMSEtrain_per_fold, RMSEtest_per_fold]

np.save("Result_simulation.npy",par_per_fold)
np.save("Result_R2.npy",r2_train_test)
np.save("Result_RMSE.npy",RMSE_train_test)

print('Statistical analysis.')
alfa1_list = []
alfa2_list = []
gamma_list = []
degF1_list = []

```

```

degF2_list = []
degLim_list = []
a_list = []
b_list = []
mu_list = []
C_list = []
D_list = []
E_list = []

for params in par_per_fold:
    a_list.append(params[0])
    b_list.append(params[1])
    C_list.append(params[2])
    D_list.append(params[3])
    E_list.append(params[4])
    mu_list.append(params[5])
    alfa1_list.append(params[6])
    alfa2_list.append(params[7])
    gamma_list.append(params[8])
    degF1_list.append(params[9])
    degF2_list.append(params[10])
    degLim_list.append(params[11])

def histograma(serie, nombre):
    plt.figure(figsize=(7,5))
    sns.histplot(serie)
    plt.axvline(serie.mean(), linestyle="dashed", label="mean", color="k")
    plt.legend(loc="best",prop={"size":14})
    plt.title(nombre, size = 14)
    plt.show()

print('Plotting graphs')

histograma(np.array(a_list), 'Parameter "a"')
histograma(np.array(b_list), 'Parameter "b"')
histograma(np.array(C_list), 'Parameter "C"')
histograma(np.array(D_list), 'Parameter "D"')
histograma(np.array(E_list), 'Parameter "E"')
histograma(np.array(mu_list), 'Parameter "mu"')
histograma(np.array(alfa1_list), 'Parameter "alfa1" ')
histograma(np.array(alfa2_list), 'Parameter "alfa2"')
histograma(np.array(gamma_list), 'Parameter "gamma" ')
histograma(np.array(degF1_list), 'Parameter "Degradation Fumigation 1" ')
histograma(np.array(degF2_list), 'Parameter "Degradation Fumigation 2" ')
histograma(np.array(degLim_list), 'Parameter "Degradation Cleaning" ')
#metricas
histograma(np.array(r2train_per_fold), 'R2 train')
histograma(np.array(r2test_per_fold), 'R2 test')
histograma(np.array(RMSEtrain_per_fold), 'RMSE train')
histograma(np.array(RMSEtest_per_fold), 'RMSE test')
##resultados de los conjuntos

print('Best model selection.')
err = np.abs(np.array(r2train_per_fold)-np.array(r2test_per_fold))

```

```

min_err = min(err)
index_min = np.where(err == min_err)
index_min = index_min[0][0]
print('Conjunto con mejores resultados: ', index_min)
print('R2 train mejor conjunto: ', r2train_per_fold[index_min])
print('R2 test mejor conjunto: ', r2test_per_fold[index_min])
params_opt = par_per_fold[index_min]
print('parametros optimos:', params_opt)

print('Model validation with new data.')
in_validation = pd.read_csv("dataEntradaValidacion.csv", sep=";")
out_validation = pd.read_csv("dataSalidaValidacion.csv", sep=";")

print('Uploading validation data')
MATRIX_X_val = np.array(in_validation[["TempMic", "Hum", "Vel
Viento", "TasaLluvia", "tF1", "tF2", "tL"]])
t_val = np.array(out_validation[["t"]])
t_val = np.ravel(t_val)
PT_val = np.array(out_validation[["y"]])
PT_val = np.ravel(PT_val)

print('Simulation with validation data')
PT_sim_val = IntMultiPeriod(t_val, PT_val, MATRIX_X_val, params_opt)
PT_sim_val = np.array(PT_sim_val)

print('R2 Validacion: ', r2_score(PT_val, PT_sim_val))
print('RMSE Validacion: ', np.sqrt(mean_squared_error(PT_val, PT_sim_val)))

fig = plt.figure(figsize=(7,5))
ax = plt.scatter(t_val, PT_val)
ax = plt.scatter(t_val, PT_sim_val, marker="+")
plt.legend(['Real', 'Model'])
plt.title("Training", fontdict=font)
plt.xlabel("Days", fontdict=font)
plt.ylabel("Thrips Incidence (Insects/Plant)", fontdict=font)
plt.show()

##desviacion estandar
a_STD = np.array(a_list).std()
b_STD = np.array(b_list).std()
mu_STD = np.array(mu_list).std()
alfa1_STD = np.array(alfa1_list).std()
alfa2_STD = np.array(alfa2_list).std()
gamma_STD = np.array(gamma_list).std()
degF1_STD = np.array(degF1_list).std()
degF2_STD = np.array(degF2_list).std()
degC_STD = np.array(degLim_list).std()
C_STD = np.array(C_list).std()
D_STD = np.array(D_list).std()
E_STD = np.array(E_list).std()

#STD = [a_STD, b_STD, mu_STD, alfa1_STD, alfa2_STD, gamma_STD, degF1_STD,
degF2_STD, degC_STD, C_STD, D_STD, E_STD]

```

```

STD = [a_STD, b_STD, C_STD, D_STD, E_STD, mu_STD, alfa1_STD, alfa2_STD,
gamma_STD, degF1_STD, degF2_STD, degC_STD]
np.save("Result_STD.npy", STD)
parameters = ['a', 'b', 'C', 'D', 'E', 'mu', 'alfa1', 'alfa2', 'gamma',
'degF1', 'degF2', 'degC']

a_m = np.array(a_list).mean()
b_m = np.array(b_list).mean()
C_m = np.array(C_list).mean()
D_m = np.array(D_list).mean()
E_m = np.array(E_list).mean()
mu_m = np.array(mu_list).mean()
alfa1_m = np.array(alfa1_list).mean()
alfa2_m = np.array(alfa2_list).mean()
gamma_m = np.array(gamma_list).mean()
degF1_m = np.array(degF1_list).mean()
degF2_m = np.array(degF2_list).mean()
degC_m = np.array(degLim_list).mean()

Mean = [a_m, b_m, C_m, D_m, E_m, mu_m, alfa1_m, alfa2_m, gamma_m, degF1_m,
degF2_m, degC_m]
np.save("Result_mean.npy", Mean)

fig = plt.figure(figsize=(7,5))
ax = plt.errorbar(parameters, Mean, yerr=STD, fmt='bo', ecolor='r',
barsabove = 'True')
plt.title("Model Campbell", fontdict=font)
plt.xlabel("Model parameters", fontdict=font)
plt.ylabel("Value", fontdict=font)
plt.show()

toc = time.time()
elapsed = toc - tic
print('Simulation time (min): ', elapsed/60)

```



Anexos





Anexo A. Formato de reporte de plagas

REPORTE DE PLAGAS

Zona: LA PAMPA

Productor: MAXIMO LOPEZ ROJAS

Evaluador: PERCY AGUIRRE

FECHA:30/04/2021

07:25 AM

		LD 1	LD 2	LD 3	LD 4	LD 5	LD 6	LD 7	LD 8	LD 9	CE 10	CE 11	CE 12	CE 13	CE 14	CE 15	CE 16	CE 17	LI 18	LI 19	LI 20	LI 21	LI 22	LI 23	LI 24	LI 25	Total	Max	Min	% de plaga	
ARAÑITA ROJA	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	HOJAS	0	0	0	0	6	0	0	0	2	0	0	0	0	5	2	0	0	2	0	0	0	0	0	0	0	17	6	0	0.68	
	Total	0	0	0	0	6	0	0	0	2	0	0	0	0	5	2	0	0	2	0	0	0	0	0	0	0	17				0.68
CERAMIDIA	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	HOJAS	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	Total	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
COCHINILLA	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	PEDUNCULO	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0.04	
	PSEUDOTALLO	0	0	2	3	0	0	0	0	0	0	0	0	3	0	2	0	0	0	3	1	0	0	2	2	2	20	3	0	0.8	
	RACIMO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0	
	Total	0	0	2	3	0	0	0	0	1	0	0	0	3	0	2	0	0	0	3	1	0	0	2	2	2	21				0.84
ESCAMAS	HOJAS 4TA	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	HOJAS 5TA	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	PEDUNCULO	5	0	6	0	0	2	0	5	0	0	12	6	3	0	0	7	0	8	0	0	0	0	0	12	4	70	12	0	2.8	
	Total	5	0	6	0	0	2	0	5	0	0	12	6	3	0	0	7	0	8	0	0	0	0	0	12	4	70				2.8
MOSCA BLANCA	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	HOJAS	2	0	0	0	3	0	0	0	3	0	0	0	0	3	0	4	0	0	5	2	2	0	0	0	0	24	5	0	0.96	
	PSEUDOTALLO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	Total	2	0	0	0	3	0	0	0	3	0	0	0	0	3	0	4	0	0	5	2	2	0	0	0	24					0.96
PICUDO	INDIVIDUOS	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	Total	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
PULGON	HIJUELO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	PEDUNCULO	0	0	0	0	0	12	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	13	12	0	0.52	
	RACIMO	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0
	Total	0	0	0	0	0	12	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	13					0.52
TRIPS	ADULTOS	0	2	0	2	0	2	3	2	0	1	5	0	1	3	1	5	0	2	2	0	0	3	3	0	0	37	5	0	1.48	
	NINFAS	0	3	0	4	0	6	2	6	0	2	2	0	2	2	2	2	0	3	6	0	2	2	2	0	3	51	6	0	2.04	
	Total	0	5	0	6	0	8	5	8	0	3	7	0	3	5	3	7	0	5	8	0	2	5	5	0	3	88				3.52