

UNIVERSIDAD PRIVADA ANTENOR ORREGO

FACULTAD DE INGENIERÍA

ESCUELA PROFESIONAL DE COMPUTACIÓN Y SISTEMAS

TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE



INGENIERO DE COMPUTACIÓN Y SISTEMAS

**“Modelo de predicción de plagas en el cultivo de palto
utilizando metodología de aprendizaje automático supervisado,
empresa Virú S.A., 2019-2021”**

Área de Investigación:

Gestión de datos y de información

Autores:

Br. CESAR ANTHONY SOLANO ROBLES
Br. IVONNE DEL PILAR CABALLERO CRUZ

Jurado Evaluador:

Presidente: Ing. Carlos Alberto Gaytán Toledo

Secretario: Ing. Heber Gerson Abanto Cabrera

Vocal: Ms. Agustín Eduardo Ullón Ramírez.

Asesor:

Urrelo Huiman, Luis Vladimir

Código Orcid: <https://orcid.org/0000-0003-1523-2640>

TRUJILLO – PERÚ


2021

Fecha de sustentación: 2021/12/14


**“Modelo de predicción de plagas en el cultivo de palto
utilizando metodología de aprendizaje automático supervisado,
empresa Virú S.A., 2019-2021”**

Elaborado por:

Br. CABALLERO CRUZ, IVONNE DEL PILAR
Br. SOLANO ROBLES, CESAR ANTHONY



Ms. Carlos Alberto Gaytan Toledo
Presidente
CIP 84519



Ms. Heber Gerson Abanto Cabrera
Secretario
CIP 106421



Ms. Agustín Eduardo Ullon Ramírez
Vocal
CIP 137602



Dr. Luis Vladimir Urrelo Huiman
Asesor
CIP 88212

Dedicatoria

A mi mamá, papá y abuela por el esfuerzo y constante apoyo dedicado a mi persona.

César.

Dedicatoria

A mis padres, Nancy y Pedro por su apoyo y esfuerzo constante, por ser los principales impulsores de mis metas y haberme brindado una excelente educación. A mi toda familia por confiar en mí y a Dios por darme fortalezas y ser mi guía.

Ivonne

Agradecimiento

Agradecemos al Ingeniero Carlos Pérez gerente de Tecnologías de Información de la empresa VIRÚ S.A. por el apoyo brindado para poder desarrollar nuestra tesis y darnos las facilidades del caso según fue requerido. Agradecemos también a nuestro asesor de tesis por ser paciente y darnos las observaciones correspondientes para la mejora de nuestro trabajo de investigación.

Resumen

“Modelo de predicción de plagas en el cultivo de palto utilizando metodología de aprendizaje automático supervisado, empresa Virú S.A., 2019-2021”

Por:

Br. CESAR ANTHONY SOLANO ROBLES

Br. IVONNE DEL PILAR CABALLERO CRUZ

El uso de la tecnología en la gestión agrícola es un fuerte pilar para el desarrollo de la productividad en el Perú. Si bien en los últimos años este sector ha implementado tecnologías tal como drones, estaciones meteorológicas, entre otros, para el control de muchos factores que involucran en este sector, no siempre se explota la información que se genera de ello. El objetivo de este trabajo fue desarrollar un modelo de predicción de plagas en el cultivo de palto utilizando la metodología de aprendizaje automático supervisado. Se analizó un conjunto de datos de variables climatológicas y de la aparición de plagas en el cultivo de palto correspondiente a los años 2019-2020, en la Empresa Virú S. A. La investigación fue de tipo descriptivo y se utilizó las Cartillas fitosanitarias y las estaciones meteorológicas de la empresa, para recolectar datos sobre plagas y variables climatológicas respectivamente. Se construyó una base de datos, se realizó la limpieza de dataframe y el filtrado de datos. Para el procesamiento de los datos se utilizó Python, jupyterlab, Transt sql y Excel. En el análisis de datos se utilizó estadística descriptiva, estadística inferencial y las técnicas de regresión lineal. Se encontró que las plagas del cultivo del palto: *Oligonychus punicae*, *Oligonychus yothersi*, *Bemisia Tabaci* y *Trips Tabaci* presentan correlaciones significativas altas y moderadas con las variables climatológicas temperatura y humedad promedio. Se concluyó que, los modelos de predicción basados en aprendizaje automático supervisado que se estimaron predicen la aparición de estas plagas en el cultivo de palto, con una precisión menor al 90%.

Palabras clave: Python, regresión múltiple, estaciones meteorológicas, filtrado de dataframe.

Abstract

"Pest prediction model in avocado cultivation using supervised machine learning methodology, company Virú S.A., 2019-2021"

By:

Br. CESAR ANTHONY SOLANO ROBLES

Br. IVONNE DEL PILAR CABALLERO CRUZ

The use of technology in agricultural management is a strong pillar for the development of productivity in Peru. Although in recent years this sector has implemented technologies such as drones, weather stations, among others, to control many factors that involve this sector, the information generated from it is not always exploited. The objective of this work was to develop a pest prediction model in avocado cultivation using the supervised machine learning methodology. A data set of climatological variables and the appearance of pests in the avocado crop corresponding to the years 2019-2020 was analyzed, in the Virú SA Company. The investigation was descriptive and the phytosanitary cards and meteorological stations of the company, to collect data on pests and weather variables respectively. A database was built, data frame cleaning and data filtering was performed. Python, jupyterlab, Transt sql and Excel were used for data processing. Descriptive statistics, inferential statistics and linear regression techniques were used in the data analysis. It was found that the pests of the avocado crop: *Oligonychus punicae*, *Oligonychus yothersi*, *Bemisia Tabaci* and *Trips Tabaci* present significant high and moderate correlations with the climatological variable's temperature and average humidity. It was concluded that the prediction models based on supervised machine learning that were estimated predict the appearance of these pests in the avocado crop, with a precision of less than 90%.

Keywords: Python, multiple regression, weather stations, dataframe filtering.

Presentación

Estimados miembros del Jurado:

Ponemos a vuestra consideración el trabajo de investigación titulado “*Modelo de predicción de plagas en el cultivo de palto utilizando metodología de aprendizaje automático supervisado, empresa Virú S.A., 2019-2021*”; Este trabajo constituye una muestra de la búsqueda de conocimiento en nuestra área profesional, pues hemos explorado en campos poco abordados tal como es el manejo, aplicación y dominio del big data en el área agrícola. Con la realización de este trabajo de investigación pretendemos obtener el título profesional de Ingeniero de Computación y Sistemas.

En el primer apartado de nuestro trabajo se presenta el planteamiento del problema, los objetivos planteados y la justificación del estudio. La sección siguiente, comprende antecedentes, marco teórico, hipótesis y variables de estudio. A continuación, se presenta la metodología utilizada, sección que involucra el nivel y tipo de investigación, población, muestra y las técnicas de procesamiento y análisis de datos. Luego, otro apartado correspondiente a los resultados, en donde se presenta el análisis estadístico de datos. Finalizamos con la discusión de los resultados, las conclusiones y recomendaciones. Se adiciona las referencias bibliográficas y sección de anexos.

Los autores.

Índice de contenidos

Dedicatoria.....	ii
Agradecimiento	iv
Resumen	v
Abstract.....	vi
Presentación.....	vii
Índice de contenidos	viii
Índice de tablas.....	ix
Índice de figuras.....	x
Índice de anexos.....	xiii
I. INTRODUCCIÓN	1
1.1 . Problema.....	2
1.2 . Objetivos	5
Objetivo General	5
Objetivos Específicos.....	5
1.3 . Justificación.....	6
II. MARCO DE REFERENCIA	8
2.1. Antecedentes del estudio	9
Antecedentes Internacionales	9
Antecedentes Nacionales.....	10
2.2. Marco teórico.....	12
2.2.1. Cultivo del palto	12
2.2.2 Plagas en el cultivo del palto.....	13
23 . Características climatológicas que influyen en el cultivo de palto15	
24 Machine Learning	18
25 Modelo de predicción	19
2.3. Marco conceptual.....	20
Data Warehouse	20
2.4. Hipótesis	22
2.6 Operacionalización de las variables	23
III. METODOLOGÍA.....	24
3.1. Tipo y nivel de investigación	25

3.2. Población y muestra de estudio	25
3.3. Diseño de investigación	25
3.4. Técnicas e instrumentos de investigación	25
3.5. Procesamiento y análisis de datos	25
IV. RESULTADOS	27
IV. PRESENTACIÓN DE RESULTADOS	28
4.1. Algoritmos implementados para el procesamiento de resultados	28
4.2. Análisis e interpretación de resultados	56
V. DISCUSIÓN DE LOS RESULTADOS	80
VI. CONCLUSIONES.....	90
VII. RECOMENDACIONES	93
VIII.REFERENCIAS BIBLIOGRÁFICAS	95
IX. ANEXOS	101

Índice de tablas

Tabla 1 Principales plagas del palto	¡Error! Marcador no definido. 14
Tabla 2 Operacionalización de las variables	¡Error! Marcador no definido. 23
Tabla 3 Tipos de plagas detectadas en el fundo de la Agroindustrial Viru, 2019-2020	¡Error! Marcador no definido. 56
Tabla 4 Evapotranspiración máxima y mínima en 2019. ¡Error! Marcador no definido.	60
Tabla 5 Evapotranspiración máxima y mínima en 2020. ¡Error! Marcador no definido.	60
Tabla 6 Temperatura mínima 2019-2020	¡Error! Marcador no definido. 62
Tabla 7 Temperatura máxima en 2019-2020	¡Error! Marcador no definido. 2
Tabla 8 Radiación solar máxima y mínima en 2019-2020.....	¡Error! Marcador no definido. 63

Tabla 9 Radiación solar máxima y mínimo en 2019-2020.....	¡Error!
Marcador no definido.	63
Tabla 10 Humedad máxima y mínima en el 2019.....	64
Tabla 11 Humedad promedio máxima y mínima.....	¡Error! Marcador no definido.

Índice de figuras

Figura 1 Diagrama de flujo del diseño de trabajo investigativo.....	¡Error!
Marcador no definido.	26
Figura 2 Esquema de base de datos sobre la estructura de las cartillas de evaluación para los cultivos de Virú	¡Error! Marcador no definido.
	28
Figura 3 Cartilla fitosanitaria en instalación-Palto	30
Figura 4 Flujo de datos para cartilla de evaluación fitosanitaria.....	¡Error!
Marcador no definido.	30
Figura 5 Diagrama data warehouse.....	¡Error! Marcador no definido.
	31
Figura 6 Estructura de la tabla QM-lista-evaluaciones.....	32
Figura 7 Función para consolidar las evaluaciones en la tabla QM..	¡Error!
Marcador no definido.	32
Figura 8 Procedimiento que guardar datos consolidado en la tabla QM	¡Error! Marcador no definido.
Figura 9 Tratamiento de datos según librerías de pandas y numpy de Python.....	¡Error! Marcador no definido.
	33
Figura 10 Librería pyodbc para conectar base de datos..	¡Error! Marcador no definido.
Marcador no definido.	33
Figura 11 Procedimiento almacenado para evaluaciones fitosanitarias	¡Error! Marcador no definido.
	34

Figura 12 Algoritmo para el filtrado de dato	¡Error! Marcador no definido.
Figura 13 Datos sobre variables climatológicas	¡Error! Marcador no definido.
Figura 14 Importación de data desde Excel a dataframe con la librería pandas	¡Error! Marcador no definido.
Figura 15 Algoritmo para gráfico de evolución de variables climatológicas 2019.....	¡Error! Marcador no definido.
Figura 16 Algoritmo para gráfico de evolución de variables climatológicas 2020.....	¡Error! Marcador no definido.
Figura 17 Importación de paquetes para tratamientos de datos	¡Error! Marcador no definido.
Figura 18 Importación de paquetes para graficar matrices	¡Error! Marcador no definido.
Figura 19 Importación de paquetes para preprocesado y modelado	¡Error! Marcador no definido.
Figura 20 Bucle para revisar la mayor cantidad de evaluaciones por filtrado	¡Error! Marcador no definido.
Figura 21 Resultado del bucle de búsqueda de evaluaciones por filtrado	¡Error! Marcador no definido.
Figura 22 Los tres filtrados que tienen mayor cantidad de evaluaciones	¡Error! Marcador no definido.
Figura 23 Filtrando la plaga Olygonichis Punicae	¡Error! Marcador no definido.
Figura 24 Algoritmo para imprimir las correlaciones	40
Figura 25 Bucle para revisar la mayor cantidad de evaluaciones por filtrado	41
Figura 26 Resultado del bucle de búsqueda.....	41
Figura 27 Selección de filtrados con mayor número de evaluaciones	¡Error! Marcador no definido.

Figura 28 Filtrando los datos de la plaga Dagbertus minensis.....	¡Error!
Marcador no definido.	
Figura 29 Algoritmo para imprimir las correlaciones ...	¡Error! Marcador no definido.
Figura 30 Bucle para revisar la mayor cantidad de evaluaciones por filtrado	¡Error! Marcador no definido.
Figura 31 Resultado de bucle de búsqueda de evaluaciones por filtrado	¡Error! Marcador no definido.
Figura 32 Selección de filtrados con mayor número de evaluaciones	¡Error! Marcador no definido.
Figura 33 Filtrando los datos de la plaga Bemisia Tabaci.....	¡Error!
Marcador no definido.	
Figura 34 Algoritmo para imprimir las correlaciones, distribuciones de variables y gráficos	¡Error! Marcador no definido.
Figura 35 Bucle para revisar la mayor cantidad de evaluaciones por filtrado	¡Error! Marcador no definido.
Figura 36 Resultado de bucle de búsqueda de evaluaciones por filtrado	46
Figura 37 Selección de filtrados con mayor número de evaluaciones	¡Error! Marcador no definido.
Figura 38 Filtrando los datos de la plaga G ninfas y adultos.....	¡Error!
Marcador no definido.	
Figura 39 Algoritmo para imprimir las correlaciones	47
Figura 40 Bucle para revisar la mayor cantidad de evaluaciones y resultados del bucle	48
Figura 41 Selección del filtrado con mayor número de evaluaciones	¡Error!
Marcador no definido.	
Figura 42 Filtrando los datos de la plaga Dagbertus minensis.....	¡Error!
Marcador no definido.	
Figura 43 Algoritmo para imprimir correlaciones, y gráficos	50
Figura 44 Algoritmo para encontrar correlaciones de plaga Olygonichus punicae	51

Figura 45 Algoritmo para encontrar correlaciones de plaga Olygonichus punicae	52
Figura 46 Algoritmo para encontrar correlaciones de plaga Bemisia Tabaci	¡Error! Marcador no definido.
Figura 47 Algoritmo para encontrar correlaciones de plaga Trips Tabaci	¡Error! Marcador no definido.
Figura 48 Algoritmo para encontrar correlaciones de plaga Dagbertus minensis.....	¡Error! Marcador no definido.
Figura 49 Evolución de la plaga Dagbertus minensis .	¡Error! Marcador no definido.
Figura 50 Evolución de la plaga Olygonichus punicae .	¡Error! Marcador no definido.
Figura 51 Evolución de la plaga Trips Tabaci	¡Error! Marcador no definido.
Figura 52 Eemesia Tabaci	59
Figura 53 Comportamiento de la evapotranspiración 2019.....	¡Error! Marcador no definido.
Figura 54 Comportamiento de la evapotranspiración 2020.....	60
Figura 55 Evolución de la temperatura promedio 2019.....	61
Figura 56 Evolución de la temperatura promedio 2020.....	61
Figura 57 Comportamiento de la radiación solar promedio 2019.....	62
Figura 58 Comportamiento de la radiación solar promedio 2020.....	63
Figura 59 Evolución de la humedad promedio 2019 ...	¡Error! Marcador no definido.
Figura 60 Evolución de la humedad promedio 2020 ...	¡Error! Marcador no definido.
Figura 61 Datos filtrados y mapa de calor de correlaciones Olygonichus	66
Figura 62 Datos filtrados y mapa de calor de correlaciones Olygonichus	67
Figura 63 Datos filtrados y mapas de calor de correlaciones Bemisia Tabaci y humedad promedio.....	68
Figura 64 Datos filtrados y mapas de calor de correlaciones Bemisia Tabaci y temperatura promedio	69

Figura 65 Datos filtrados y mapas de calor de correlaciones Trips Tabaci	70
Figura 66 Resultados de la regresión lineal plaga Olygonichus punicae y temperatura promedio.....	71
Figura 67 Resultados de la regresión lineal plaga Olygonichus punicae y temperatura y humedad promedio	¡Error! Marcador no definido.
Figura 68 Gráficos de residuos	74
Figura 69 Resultados de la regresión lineal plaga Bemisia Tabaci y humedad promedio	¡Error! Marcador no definido.
Figura 70 Resultados de la regresión lineal plaga Bemisia Tabaci y temperatura promedio.....	¡Error! Marcador no definido.
Figura 71 Resultados de la regresión lineal plaga Trips Tabaci.....	78

Índice de anexos

Anexo 1. Cartillas de evaluación fitosanitarias	¡Error! Marcador no definido.
Anexo 2. Reunión de trabajo con el equipo del área fitosanitaria de la Empresa Virú S. A.	¡Error! Marcador no definido.3

I. INTRODUCCIÓN

11. . Problema

La producción agrícola presenta permanente problemas de plagas y enfermedades en casi la totalidad de cultivos. Sin duda, este factor afecta la productividad y por supuesto la calidad de los productos. Perú es un país que, según Peñaranda (2019, p.7-8), en los últimos años ha presentado un notable crecimiento en exportación agroindustrial, generando que el PBI del sector agroindustrial tenga un crecimiento de 13.7% en los años del 2014 al 2018; además, se suma a ello la inversión que se proyecta en el sector agrícola para los próximos seis años, una cartera de 15 proyectos con inversión que asciende a US\$ 2.922 millones. Esto constituye una gran oportunidad para que Perú siga en ascenso en la exportación agroindustrial, pero, requiere mejoras en la calidad de la productividad de estas empresas.

La calidad de la productividad de las empresas agroindustriales está asociada a las medidas anti-riesgos y de protección con sus cultivos, maquinarias, personal, etc. Pues, el principal problema con el que se enfrentan las industrias son las plagas y enfermedades de las plantas que afectan a los cultivos, amenazando la seguridad alimentaria. Cada cultivo exige forma diferente para afrontar las plagas, pues un factor predominante de éstas es el ambiente. Al respecto, Peñaranda (2019, p. 8) afirma: “uno de los desafíos del sector agroindustrial es elevar su productividad a través de transferencia de tecnología y una mayor y mejor infraestructura”. Del mismo modo, Arroyo, Rojas y Kleeberg (2016, p. 159) afirman: “Impulsando la mayor inversión en capital humano y en recursos tecnológicos, van a generar competitividad y máximo provecho a los tratados de libre comercio”; como también lo afirma el Ministerio de Agricultura (2012), cuando dice:

En el Perú se registra un avance insuficiente en materia de investigación y transferencia de tecnología agraria (incluye asistencia técnica y la capacidad de innovación), lo que origina una baja adopción de tecnologías por parte de los productores (exacerbado por restricciones de capital). (p.55)

El manejo y control de plagas constituye un factor primordial para el crecimiento de la calidad de la productividad y siendo que cada cultivo presenta diferentes formas de afrontar este problema, nos enfocamos en el cultivo de palto. Según Avendaño, Mercado, Soriano y Villamonte (2018):

La productividad de la palta en el Perú muestra niveles con tendencia creciente, pasó a registrar de un volumen de 9,5 toneladas por hectárea en el año 2000 a un volumen promedio de 11,2 toneladas por hectárea, en el año 2013. Asimismo, comparando con el resto del mundo, se aprecia que el rendimiento productivo promedio del Perú es mayor que el resto de los países del mundo, registrándose, de acuerdo a cifras de la FAO, que, entre el 2012 y 2013, mientras el Perú llegaba a rendimientos de 11.2 toneladas por hectárea, el rendimiento promedio mundial llegaba a las 9 toneladas por hectárea. (p. 16-17)

Al respecto Ripa, Vargas, Larral y Rodríguez (2007, p.29) afirman:

El gran desarrollo del cultivo del palto en nuestro país ha significado un incremento de la incidencia de plagas, las cuales actualmente causan pérdidas directas a través de la disminución de vigor, descarte de frutas dañadas y rechazo de fruta de exportación por la presencia de plagas cuarentenarias.

En la región La Libertad, una de las empresas agroexportadora de gran importancia en este sector es Virú S.A., donde su principal producto de exportación es la palta, además del esparrago, alcachofa, mango, otras (Agraria.pe, 2019). En la actualidad, la producción de palto en Virú S.A. presenta varias dificultades, siendo el principal factor que le afecta, las plagas entre ellas: Bemisia Tabaci,

Olygonichus punicae, Oligonychus yothersi, Dagbertus Minensis, Dagbertus Peruanus, Trips Tabaci. Estas varían de acuerdo a diferentes factores tales como: el clima, calidad del suelo, aplicación de insecticidas, cantidad de plantas, etc. (Cartillas fitosanitario, 2019)

Para controlar el factor clima, la empresa Virú S.A. cuenta con estaciones meteorológicas Davis instruments, dispuestas en puntos estratégicos. Estos dispositivos permiten medir algunas variables climatológicas que afectan los cultivos, tal como: temperatura, humedad, dirección del viento, velocidad del viento, presión atmosférica y rayos UV; mediante una interfaz que conecta la estación meteorológica con el sistema de control del clima, implementado en la empresa, se obtienen datos del clima y se consolidan en una hoja de cálculo Excel.

La empresa Virú S.A. cuenta también con *Áreas de sanidad palto*, encargadas de tomar decisiones oportunas sobre: cantidad, tipo, duración de insecticidas, etc. que se deben aplicar para evitar la proliferación de las plagas; así como, gestionar la compra y distribución de los materiales para aplicar estos insecticidas. Esta toma de decisiones debería asumirse en función a los reportes semanales de los datos del clima; sin embargo, los reportes semanales de los datos del clima no se comparten rápidamente y hay retrasos en la disponibilidad de éstos.

Una adecuada gestión de la información climatológica puede ayudar en una efectiva toma de decisiones, tanto en un mejor manejo del control de plagas como, en la optimización de los recursos disponibles. Si bien es cierto que, en los últimos años el sector agroindustrial se ha visto influenciado por la presencia del uso de la tecnología tal como: estaciones meteorológicas, softwares de gestión, entre otros; también se observa que, muchas de estas empresas aún no han hecho mayor uso de las grandes bases de datos que están

originando los registros meteorológicos, tal como viene sucediendo en la empresa agroindustrial Virú S.A.

En tal situación, con la evaluación de los patrones de comportamientos de los datos, análisis del comportamiento natural de las diferentes variables climatológicas y el histórico de la aparición de plagas en el cultivo de palto en la empresa agroindustrial Virú S. A. durante los últimos años, se pretende buscar y extraer conocimiento que permita o contribuya a una toma de decisiones efectivas, tanto en el manejo y control de plagas como en la predicción de estas.

Enunciado del problema:

¿Cómo predecir la aparición de plagas en el cultivo de palto mediante un modelo de predicción utilizando metodología de aprendizaje automático supervisado, en la Empresa Virú S.A.?

12 . Objetivos

Objetivo General

Desarrollar un modelo de predicción de plagas utilizando la metodología de aprendizaje automático supervisado para el cultivo de palto en la empresa Virú S.A.

Objetivos Específicos

- Elaborar un diagnóstico situacional del tipo de plaga en el cultivo de palto por lote según año 2019-2020.
- Elaborar un diagnóstico del comportamiento de las variables climatológicas en 2019-2020.
- Realizar un análisis relacional entre el tipo de plagas en el cultivo de palto y las variables climatológicas para el año 2019-2020.

- Entrenar y validar el modelo de predicción de plagas en el cultivo de palto a partir del comportamiento de las variables climatológicas, mediante metodología de aprendizaje automático supervisado.

13 . Justificación

Este trabajo constituye una forma de utilización del amplio volumen de datos no explorados con que cuenta la empresa agroindustrial Virú S.A. sobre variables meteorológicas y que se mantienen estáticos sin ser utilizados de forma óptima en la toma de decisiones, información que pretendemos descubrir y capitalizar con la aplicación de herramientas de data mining.

El modelo de predicción de plagas, propósito de este trabajo, permite construir información sobre patrones de comportamiento de las variables meteorológicas en la empresa y establecer su relación con la aparición de plagas en el cultivo de palto permitiendo al *Área de sanidad palto*, a tomar decisiones oportunas para un eficiente monitoreo y control de plagas, así como para la optimización de recursos necesarios para la gestión de plagas que se presentan en el cultivo de palto.

Este modelo de predicción constituye una fuente que provee información sobre qué posibles plagas pueden aparecer según la variabilidad del clima. Los hallazgos de este trabajo son un punto de partida para la implementación de nuevas formas de gestión agrícola muy de la mano con la tecnología y a la vez constituye un soporte para ampliar posteriormente al análisis del comportamiento de plagas en otros cultivos. Además, reduce el tiempo en toma de decisiones sobre qué métodos anti plagas usar y provee de información valiosa para tener en stock los elementos adecuados.

El aporte de este trabajo en la ciencia de los datos, el data mining y su aplicación en el campo agrícola constituye gran aporte al

conocimiento teórico del uso de herramientas predictivas a utilizar en datos agrícolas; puesto que, por la diversidad del comportamiento de las variables en este campo hay necesidad de seguir incrementando el uso de la tecnología en este sector.

II. MARCO DE REFERENCIA

2.1. Antecedentes del estudio

Antecedentes Internacionales

Heamin Lee, Aekyung Moon, Kiyeong Moon, Youngjae Lee (2017), realizaron la investigación "Disease and pest prediction IoT system in orchard: A preliminary study", mencionan que cerca del 40% de la producción de alimentos es destruida por las plagas y a pesar de que se utilicen insecticidas en los cultivos, esto solo ayuda a que los cultivos sean malos para la salud por su gran cantidad de químicos. Ellos plantearon una solución con datos meteorológicos establecidos en puntos estratégicos, para ello recolectaron información del clima y con datos de plagas que aparecieron en años anteriores establecieron una correlación en ambas partes dando así una predicción acertada de qué tipos de plagas podrían aparecer según las variables climatológicas. El procedimiento para estructurar el sistema de pronóstico IOT, fue: una estación meteorológica, módulos de predicción, aplicaciones de usuario y un servidor. Las estaciones meteorológicas realizaron la recopilación y transmisión de información meteorológica en tiempo real, almacenándose en servidores, luego esta información fue contrastada con los modelos de predicción para obtener la probabilidad de aparición de plagas y las fechas aproximadas dónde aparecerán. Concluyeron que, la infección antracnosis, está estrechamente relacionada con la temperatura y la duración de la humedad.

Lin Jiao, Shifeng Dong, Shengyu Zhang, Chengjun Xie, Hongqiang Wang (2020), en la investigación "Computers and Electronics in Agriculture", estos autores realizaron una red neuronal convolucional llamada AF-RCNN para poder detectar de forma precisa las plagas usando imágenes y aplicar los insecticidas correctos disminuyendo el impacto ambiental y contaminación de los cultivos. Utilizaron como parámetros para detectar las plagas: el tamaño, color, y región efectiva de estas. Desarrollaron diagramas

lógicos para escanear las muestras de plagas en los cultivos, alimentando así la red neuronal. Utilizaron, el algoritmo LOSS para visión artificial y clasificación de variantes de plagas. Los métodos para desarrollar la red Neuronal fueron: Adquisición de imágenes de plagas, Etiquetado de datos, División de datos, Características del conjunto de datos de plagas, Construcción del modelo de detección.

Concluyeron que, debido a la complejidad de las imágenes primero se desarrolló un modelo de detección AF-RCNN para poder clasificar las 24 clases de plagas agrícolas. En segundo lugar, se introdujo un sistema un campo receptivo, parecido al campo visual humano. Finalmente, con todos estos datos el detector AF-RCNN logra la detección integral de plagas de múltiples categorías.

Sebastian Lindgren (2020), realizó la investigación “Creating and Improvising Machine Learning Algorithms for Plant Disease Identification”, el cual utilizó un modelo de red neuronal convusional utilizando en promedio unas 50,000 imágenes para detectar las distintas enfermedades en los cultivos de la india, tales como, papa, pepino, legumbres y arroz. La tecnología usada para el desarrollo de esta red neural convusional fue Pythorch, una librería opern source para detección de imágenes basado en python.

En conclusión, el autor realizó distintos test sobre las imágenes en diferentes tonos de colores aplicando modelos de 64 canales, 32 canales, 16 canales. Quedando solo utilizables según los datos los modelos de 64 y 32 canales. El modelo que tuvo la mayor precisión fue el de 64 canales con un 93% de acierto aproximadamente.

Antecedentes Nacionales

Barrantes y Vigo (2015), en su tesis “Sistema experto móvil para el diagnóstico y manejo integral de plagas en el arroz” construyeron un sistema experto y diagramas UML orientados a un enfoque móvil,

cuyo objetivo fue el diagnóstico y manejo integral de la plaga en el arroz. El sistema obtiene la plaga de acuerdo a sus síntomas seleccionados por el agricultor usuario. El tratamiento que se le otorga a la enfermedad es obtenido por el sistema. Brinda información de: el nombre de la plaga diagnosticada y su descripción, el manejo integral que se puede utilizar para la plaga y la dosis para aplicar a las plagas. En la programación del sistema se utilizó JQuery Mobile con PHP. Concluyó que, el sistema experto móvil ayudará al agricultor a tener un diagnóstico y manejo integral a tiempo con una certeza del 80% en su diagnóstico.

Sullca, Molina, Rodríguez y Fernández (2018) realizaron el trabajo de investigación “Detección de enfermedades y plagas en las hojas de arándanos utilizando técnica de visión artificial”, enfocada en la implementación de un modelo de reconocimiento de enfermedades y plagas utilizando las hojas de los arándanos. Con el objetivo de solucionar una serie de problemas en los sembríos de arándanos y de esta manera reducir el tiempo de análisis o reconocimiento que normalmente se hacía en laboratorios, por uno de inmediato, con solo obtener una captura instantánea o un corto de video de la planta y alimentando al sistema para el reconocimiento del tipo de enfermedad con un acierto desde la primera captura.

Esta investigación focalizó el uso de visión artificial puesto que utilizaron técnicas para el procesamiento y análisis de imágenes, con estas imágenes se armó una base de datos. El algoritmo de aprendizaje que se utilizó fue SVM (Support Vector Machine), este algoritmo es un método de clasificación en el cual se grafica cada dato como un punto en un espacio de n dimensiones (donde n es el número de variables que se tiene) con el valor de cada variable siendo el valor de una coordenada en particular, este algoritmo determina si la planta de arándano está siendo afectada por una enfermedad o plaga, o no.

Como resultado, el modelo reconoce con un 85.6% de precisión, lo cual demuestra que el modelo entrenado con el algoritmo Redes neuronales y utilizando los vectores característicos extraídos con LBP, es adecuado para predecir el estado de la planta de arándano.


Prieto, J. y Trelles, R. (2021), en su tesis “Clasificación de hojas de tomate con plagas o enfermedades usando una máquina de soporte vectorial (SVM)” utilizaron el procesamiento de imágenes del cultivo del tomate en matlab para la implementación de su algoritmo SMV. Estas imágenes fueron clasificadas por color y textura para poder identificar plantas sanas de enfermas. Realizaron dos modelos, uno multiclase clasificando las imágenes por las plagas y otro binario de imágenes clasificadas por enfermas o sanas y de imágenes clasificadas por plagas. El primer modelo obtuvo una exactitud del 92% y el algoritmo de dos etapas una precisión del 99.3% en la primera etapa y del 97.2% en la segunda, determinando como mejor opción el uso del modelo SVM binario para el desarrollo de su algoritmo.

2.2. Marco teórico

2.2.1. Cultivo del palto

El palto (*Persea Americana Mill*) tiene su origen en la Época Precolombina, su extensión abarcó las zonas tropicales y subtropicales desde Perú hasta México (Ataucusi, 2015, p. 8).

El palto “es una especie polimorfa, por ello se adapta a diferentes ambientes y sus características como la dimensión de las hojas, tamaño del fruto, coloración de epicarpio, entre otros, son muy variables” (Baiza, 2003, p. 7).



Fuente: Guía técnica del cultivo del aguacate (Baiza, 2003, p.16)

Sus características principales se pueden resumir como: tallo leñoso, follaje siempre verde y raíz muy superficial. Las hojas son simples, enteras; forma: elíptica, alargada y nervadura pinnada. De color rojizo y pubescente cuando es joven; al llegar a la madurez estas se vuelven lisas, coriáceas y de un verde intenso y oscuro, alcanzan aproximadamente 15 cm de largo y 6 cm. de ancho. Las raíces son superficiales, la profundidad puede ser de 1-1.5 m; de muy pocos pelos radicales y la principal absorción de nutrientes y agua se realiza en las puntas de las raíces a través de los tejidos primarios (Baiza, 2003, p.9).

2.2.2 Plagas en el cultivo del palto

Según Jiménez (2009) “La plaga agrícola es una población de animales fitófagos (se alimentan de plantas) que disminuye la producción del cultivo, reduce el valor de la cosecha o incrementa sus costos de producción” (p.12).

Para Falconí (2013):

Las plagas agrícolas están constituidas principalmente por insectos, ácaros, nematodos, caracoles, aves y roedores; las enfermedades agrícolas son causadas por microorganismos como virus, bacterias, micoplasmas, viroides y hongos; y las malezas son aquellas plantas que resultan indeseables en un campo porque compiten con las plantas cultivadas en el uso de espacio, nutrientes y agua. (p. 5)

Para Torres (2017) “en el palto es clave mantener los árboles con un vigor adecuado y libre de plagas. Bajo este concepto, es importante reducir el impacto del estrés ambiental y nutricional” (p. 60).

Siendo fundamental el abordaje específico sobre las plagas que presenta el cultivo de palto, aspectos relevantes de las principales plagas, se resume en la Tabla 1.

Tabla 1

Principales plagas del palto

Nombre común de la plaga	Daño	Monitoreo	Ciclo de Vida	Periodo Susceptible del cultivo
Chanchito blanco de cola larga	Presencia en troncos, ramas y hojas. Decoloración de brotes y frutos	En hojas, brotes, frutos, flores, grietas del tronco, hojarasca. Trampa: cartón corrugado en ramas principales.	Huevo a ninfa: 16 a 18 días a 20° C. Huevo a adulto: 90 días a 18°C	Floración, brotación, cuaja, hasata la cosecha
Trips del Palto (Trips Tabasi)	Presencia de fecas color negro, bronceado en hojas y fruto, lesiones corchosas en fruto.	Marcar focos(detección de fecas en hojas) y definir niveles de daño en hojas.	Huevo a larva: 20 días a 19-25 °C. Huevo a adulto: 37 a 41 días.	Hojas y frutos desde cuaja a cosecha.
Mosca blanca (Bemesia Tabaci)	Depresiones y decoloraciones alrededor de la escama. Presencia de escamas y fumagina en frutos.	Marcar árboles con presencia de escamas en ramas, hojas o frutos.	Huevo a adulto: 35 días.	Febrero-Agosto y Diciembre.
Arañita roja (Oligonychus)	Hongo que produce coloración cobriza en nervaduras de hojas, color pardo generalizado en hojas, defoliación	Marcar focos, revisar plantas a orillas de camino, revisar semanalmente desde Febrero a Mayo, y registrar variaciones de la población.	Huevo a adulto: 16 días a 25°C	Árboles en orillas de camino. Meses desde Febrero a Noviembre
Chinche (Dagbertus minensis)	Afecta los botones florales, el cuajado de frutos y frutos pequeños.	Detectar su presencia en envés de las hojas y marcar árboles y sectores afectados. Observar aumento de poblaciones. Observar presencia de chinche.	Promedio: 79.5 días en primavera y 22.5 días en verano	Meses críticos: Enero, Abril, setiembre, Noviembre

Fuente: Yarita y Cisneros (2010); Cartillas fitosanitarias Virú, Boletín INIA N° 129-Ministerio de agricultura, Chile;

2.2.3. Características climatológicas que influyen en el cultivo de palto

- Evapotranspiración

Es la cantidad de agua que vuelve a la atmósfera como producto de la evaporación y transpiración de las plantas, tal como lo afirma Salvo, Torres, Olivares, Riquelme, Leris, Rodriguez y Abarca (2017):

Para determinar la cantidad de agua que necesita la planta es necesario realizar algunos cálculos y que se relacionan específicamente con la estimación de la transpiración y la evaporación de agua (la pérdida del agua que ocurre desde el suelo). Para ello se calcula la evapotranspiración (evaporación + transpiración). (p. 41)

- Humedad relativa

“La humedad relativa es la relación entre contenido de vapor de agua y la cantidad de vapor de agua que el aire puede retener a esta temperatura” Gliessman (2002, p. 73). El autor agrega que, la humedad relativa es determinante en la proliferación de plagas en este tipo de cultivo tal como lo es Antracnosis: *Colletotrichum* sp, un hongo que crece fácilmente en ambientes con humedad relativa del 80 % al 100% y temperaturas de 27° C. (Gliessman, 2002)

- Temperatura

Por conocimiento general sabemos que, la temperatura es una magnitud que mide la cantidad de calor de cuerpo o de la atmósfera. En relación a los cultivos, Matarín y Morales (2018) afirma: “La temperatura es el factor climático más conocido, y el que más se controla en los cultivos. La temperatura juega un papel fundamental en la regulación de los procesos metabólicos y en la nutrición de la planta” (p. 17).

- Presión atmosférica

Según Apuntes en página web SailandTrip (2016)

La presión atmosférica es el peso de la columna de aire que hay sobre cualquier punto o lugar de la tierra y es por tanto el peso por unidad de superficie. Cuanto mayor es la altura, menor es la presión atmosférica y cuanto menor es la altura y más se acerque a nivel del mar, mayor será la presión.

- Precipitación

En términos meteorológicos, según Soriano (2020) “la precipitación es un fenómeno atmosférico que se presenta como cualquier tipo de meteoro que proviene de la atmosfera y que llega a la superficie terrestre. Incluye diferentes formas como son la lluvia, llovizna, nieve y granizo” (p.2).

Para el cultivo palto significa que mientras las precipitaciones sean mayores, la vigorosidad de este será mayor comparada con zonas donde esté ausente. La web InfoAgro (2020) afirma:

Se considera que 1.200 mm anuales bien distribuidos son suficientes. Sequías prolongadas provocan la caída de las hojas, reduciendo el rendimiento; el exceso de precipitación durante la floración y la fructificación reduce la producción y provoca la caída del fruto. (Apartado 2.1)

- Velocidad del viento

En EcuRed (2020, p.1) se afirma que: “Viento es aire en movimiento y se produce en dirección horizontal, a lo largo de la superficie terrestre. La dirección, depende directamente de la distribución de las presiones”. Un ejemplo de cómo afecta la velocidad del viento en el cultivo del palto es explicado por Salvo et al. (2017, p. 34), cuando afirman:

Las hojas que permanecen bajo la sombra del sol, son eficientes en mantener activos los procesos de fotosíntesis en bajos niveles de iluminación, por lo que no deben ser removidas mediante poda. Más aún, cuando el viento mueve las ramas y la luz ingresa en forma intermitente, los cloroplastos captan rápidamente estos niveles

crecientes de energía solar y los niveles de fotosíntesis aumentan en forma temporal.

En tal sentido, es fácil entender que el proceso de fotosíntesis es afectado tanto por los rayos UV y el viento, pues como producto del movimiento por acción del viento, las hojas realizan este proceso.

- Dirección del viento

Para EcuRed (2020, p. 1) “es el punto del horizonte de donde viene o sopla el viento. El instrumento más antiguo para conocer la dirección de los vientos es la veleta que, con ayuda de la rosa de los vientos, definen su procedencia”.

- Rayos ultravioletas

Es una forma de radiación, las plantas son bastantes susceptibles a los rayos ultravioleta, siendo que la exposición alta a estos puede causar una disminución en los nutrientes del suelo provocando una escasez de alimentos necesarios para las plantas. Al respecto, Carrasco-Ríos (2009) afirma:

La luz es uno de los factores más importantes que regulan el crecimiento y desarrollo de las plantas. Sin embargo, el aumento de la radiación ultravioleta-B debido a la acción antropogénica puede tener un impacto negativo en éstas, provocando una disminución de la fotosíntesis y de la producción de biomasa. Esta radiación puede además causar daño en distintas biomoléculas, entre las cuales la más importante es el DNA. (p.1)

- Índice de calor

Asociación de propietarios de Can Derroca (2020) afirma:

El índice de calor usa la temperatura y la humedad relativa para determinar cuán caliente realmente se siente el aire. Cuando la humedad es baja, la temperatura aparente será más baja que la temperatura del aire, dado que la transpiración se evapora rápidamente para enfriar el cuerpo. Sin embargo, cuando la humedad es alta (por ej., el aire está más saturado de vapor de agua) la

temperatura aparente se siente más alta que la temperatura real del aire, porque la transpiración se evapora más lentamente. (p.1)

2.2.4. Machine Learning

Para IBERDROLA (2021):

El Machine Learning es una disciplina del campo de la Inteligencia Artificial que, a través de algoritmos, brinda a los ordenadores la capacidad de identificar patrones en datos masivos para hacer predicciones. Este aprendizaje permite a los computadores realizar tareas específicas de forma autónoma, es decir, sin necesidad de ser programados. (p.1)

Según la web sas, el:

Machine learning es un método de análisis de datos que automatiza la construcción de modelos analíticos. Es una rama de la inteligencia artificial basada en la idea de que los sistemas pueden aprender de datos, identificar patrones y tomar decisiones con mínima intervención humana. (p.1)

Para precisar sobre los algoritmos de Machine Learning, citamos a la web IBERDROLA (2021), en donde se afirma que éstos se dividen en tres categorías, pero, resaltan como más comunes las dos primeras, como son:

- **Aprendizaje supervisado:** constituidos por algoritmos que poseen un aprendizaje previo que utiliza un sistema de etiquetas a datos que facilitan la toma de decisiones y el análisis predictivo. Ejemplo de ello constituye un detector de spam (según patrones aprendidos de un histórico de correos puede discriminar entre un e-mail conocido o desconocido).
- **Aprendizaje no supervisado:** a diferencia del aprendizaje supervisado los algoritmos no tienen conocimiento previo. Buscan patrones dentro del caos de datos y tratan de encontrar forma de organizarlos. Este tipo de aprendizaje, por ejemplo, es muy

utilizado en el marketing, para extraer patrones de comportamiento de grandes volúmenes de datos y encontrar una utilidad en la implementación de campañas de publicidad.

- **Aprendizaje por refuerzo:** utilizado cuando se pretende que un algoritmo aprenda a partir de la propia experiencia. Un ejemplo de esto es el reconocimiento facial, clasificación de secuencias de ADN, entre otros.

2.2.5. Modelo de predicción

La web UNIR (2020), considera que los modelos de análisis predictivo son: “Modelos matemáticos que predicen el comportamiento de una variable en función de un conjunto de otras variables. Cuanto más relacionadas estén el conjunto de variables predictoras con la variable a predecir (correlación), más exactas serán las predicciones”. Desarrollar un modelo de predicción requiere disponer de datos históricos, los cuales se dividen en dos: un conjunto de datos de entrenamiento, para calibrar la predicción y un conjunto de datos de prueba. Posteriormente, comparar el resultado de la predicción con los valores reales (históricos) para comprobar su exactitud.

Según la web sas (2021):

Existen dos tipos de modelos predictivos. Los modelos de clasificación predicen membresía de clase. Por ejemplo, usted intenta clasificar si alguien tiene probabilidad de irse, si responderá a una convocatoria, si es un riesgo de crédito bueno o malo, etc. En general, los resultados del modelo se dan en la forma de 0 o 1, donde 1 es el evento que usted pretende lograr. Los modelos de regresión predicen un número – por ejemplo, cuántos ingresos generará un cliente en el próximo año o el número de meses antes de que falle un componente de una máquina.
(p.1)

2.2.6. Técnicas de modelado predictivo: las más utilizadas son los árboles de decisión, la regresión y las redes neurales. (sas.com)

Los árboles de decisión: constituyen modelos de clasificación en los que los datos se particionan en subconjuntos, según las categorías de las variables de entrada.

La regresión: “el análisis de regresión es una técnica estadística para investigar y modelar la relación entre variables” (Montgomery, Peck y Vining, 2005, p.1). Está diseñada para trabajar con datos continuos; este método es muy útil para la búsqueda de patrones clave en grandes conjuntos de datos y a menudo se utiliza para evaluar qué factores específicos o variables independientes (x), pueden explicar o predecir el comportamiento de una variable respuesta (y). Cuando se analizan una variable independiente y una variable respuesta, se denomina regresión simple y estaremos en un caso de regresión múltiple, cuando se evalúa una variable respuesta (y) en función de dos o más variables independientes (x_1, x_2, \dots, x_n). Entre los modelos de regresión de alto uso se encuentran: la regresión lineal y la regresión logística.

Las redes neurales: son técnicas avanzadas, poderosas y flexibles, se utilizan para modelar relaciones extremadamente complejas; pues, tienen, alto poder para gestionar relaciones no lineales en los datos. Son muy utilizadas en el reconocimiento de patrones y algunos procesos artificialmente inteligentes.

2.3. Marco conceptual

Data Warehouse

Un Data Warehouse (DW) “es un gran repositorio lógico de datos que permite el acceso y manipulación flexible de grandes volúmenes de información provenientes tanto de transacciones detalladas como datos agregados de fuentes de distinta naturaleza” (Silberschatz, Korth, & Sudarshan, 2006). Un buen repositorio de datos constituye una fuente de información para construir un sistema de inteligencia de negocios que ayude a una efectiva toma

de decisiones. Según (Montero, 2018, p. 30) una Data Warehouse posee las siguientes características: está orientado a sujetos, permite administrar gran volumen de información, abarca una variedad de versiones de esquemas de Bases de datos, permite comprimir y adicionar información e integra y reúne información de muchas fuentes de datos.

Procedimiento almacenado

“Un procedimiento almacenado de SQL Server es un grupo de una o más instrucciones Transact-SQL o una referencia a un método de Common Runtime Language (CLR) de Microsoft .NET Framework”. (WilliamDAssafMSFT, 2021).

Además, WilliamDAssafMSFT (f. p. 25/5/2021) menciona que:

Los procedimientos se asemejan a las construcciones de otros lenguajes de programación, porque pueden: 1) Aceptar parámetros de entrada y devolver varios valores en forma de parámetros de salida al programa que realiza la llamada. 2) Contener instrucciones de programación que realicen operaciones en la base de datos. Entre otras, pueden contener llamadas a otros procedimientos. 3) Devolver un valor de estado a un programa que realiza una llamada para indicar si la operación se ha realizado correctamente o se han producido errores, y el motivo de estos.

Algoritmo

Según Duque et al (2017)

Un Algoritmo es una secuencia de pasos para resolver un problema y debe contar con las siguientes características:
Preciso: cada paso debe ser claro y exacto en su construcción para que así determine puntualmente lo que se desea hacer.
Definido: toda vez que se ejecute el algoritmo con los mismos

datos de entrada, éste debe generar el mismo resultado. Finito: todo algoritmo debe tener un fin. (p.37)

2.4. Hipótesis

Un modelo basado en aprendizaje automático supervisado permite predecir la aparición de plagas en el cultivo de palto, con una precisión de al menos 90%, en la Empresa Virú S.A.

2.5. Variables e indicadores

Variable de estudio: Desarrollo de un modelo de predicción de aparición de plagas

Variables que involucra el **desarrollo del modelo de predicción:**

- Grado de infestación
- Porcentaje de infestación
- Características climatológicas:
 - Evapotranspiración
 - Humedad relativa
 - Temperatura interior (°C)
 - Temperatura exterior (°C)
 - Presión atmosférica (bar)
 - Precipitación (mm)
 - Velocidad del viento (km/h)
 - Dirección del viento (E-O-N-S)
 - Rayos ultravioletas (UV)
 - Índice de calor (index)

2.6 Operacionalización de las variables

Tabla 2

Operacionalización de las variables

Variables	Definición conceptual	Definición operacional	Indicadores	Instrumento	Escalas de medición
Desarrollo de un modelo de predicción de plagas	“Modelos matemáticos que predicen el comportamiento de una variable en función de un conjunto de otras variables. Cuanto más relacionadas estén el conjunto de variables predictoras con la variable a predecir (correlación), más exactas serán las predicciones”. (UNIR, 2020)	Para desarrollar el modelo de predicción se considera como variable dependiente al grado de infestación y porcentaje de infestación, según el tipo de plaga.	-Grado de infestación -Porcentaje de infestación	Cartillas fitosanitarias	Razón
Características climatológicas	Las condiciones climatológicas son factores muy importantes en la producción del palto. Estos factores influyen en la calidad y rendimiento.	Todas las mediciones climatológicas que reportan las estaciones meteorológicas implementadas por la empresa.	- Humedad relativa, -Temperatura interior (°C) -Temperatura exterior (°C) -Presión atmosférica (bar) -Precipitación (mm) -Velocidad del viento (km/h) -Dirección del viento (E-O-N-S) -Rayos ultravioletas (UV) -Índice de calor (index)	Estaciones Meteorológicas Davis instrument	Intervalo y Razón

III. METODOLOGÍA

3.1. Tipo y nivel de investigación

La investigación fue de enfoque cuantitativo, de nivel descriptivo y transversal.

3.2. Población y muestra de estudio

Población

Conjunto de datos de las variables climatológicas y de la aparición de plagas en el cultivo de palto, en la Empresa Virú S. A.

Muestra

Conjunto de datos de las variables climatológicas y de la aparición de plagas en el cultivo de palto correspondiente a los años 2019-2020, en la Empresa Virú S. A.

3.3. Diseño de investigación

Para la comprobación de la hipótesis se utilizó el diseño descriptivo, tal como:

M_____O

Donde:

M: Conjunto de datos filtrados 2019-2020

O: Observación, medición y análisis predictivo del conjunto de datos

3.4. Técnicas e instrumentos de investigación

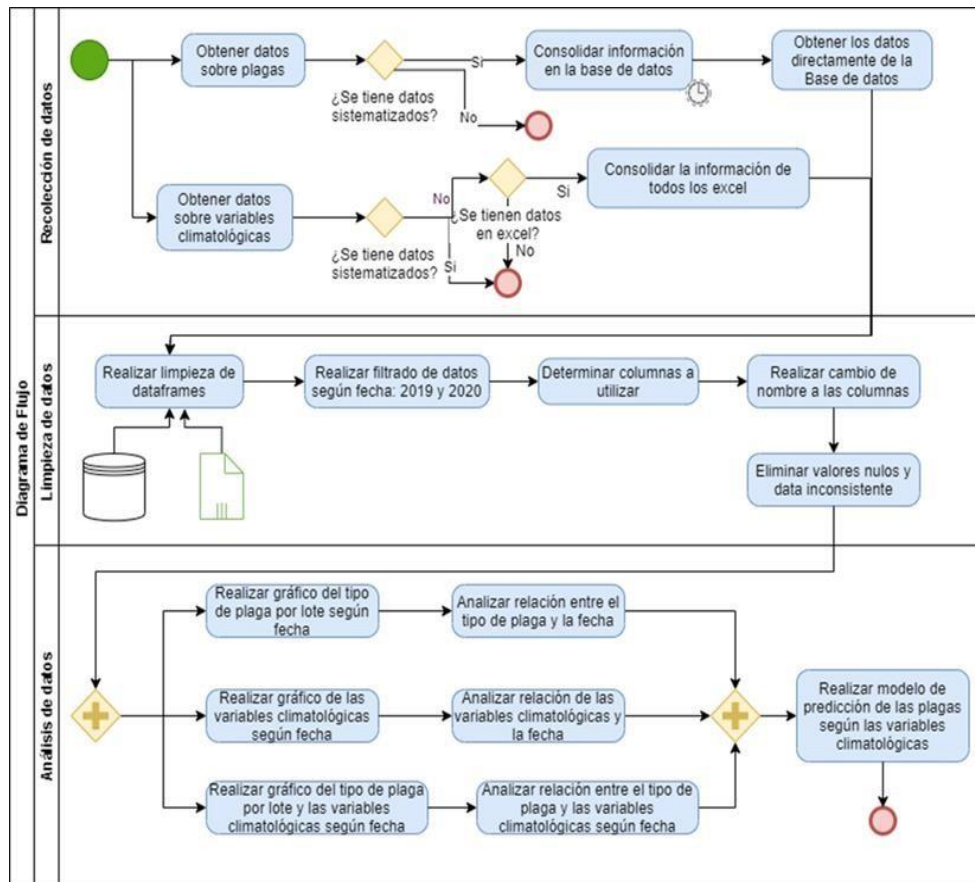
Para la recolección de datos se utilizó la técnica documental y el instrumento de recolección de datos fueron las Cartillas fitosanitarias.

3.5. Procesamiento y análisis de datos

El procedimiento para el trabajo investigativo se realizó considerando el siguiente esquema:

Figura 1

Diagrama de flujo del diseño de trabajo investigativo



El procesamiento de datos se realizó a través de Python, jupyterlab, Transt sql y Excel. Para el análisis de datos se utilizó estadística descriptiva, estadística inferencial y las técnicas de regresión múltiple.

IV. RESULTADOS

IV. PRESENTACIÓN DE RESULTADOS

4.1. Algoritmos implementados para el procesamiento de resultados

1. Elaborar un diagnóstico situacional del tipo de plaga en el cultivo de palto por lote según año 2019-2020.

a) Recolección de datos

Los datos se encontraron almacenados en la base de datos BDVirunet, los cuales fueron reportados en Cartillas fitosanitarias en instalación-Palto, tal como se muestra en las figuras 2; 3 y 4.

Figura 2

Esquema de base de datos sobre la estructura de las Cartillas de evaluación para los cultivos de Virú

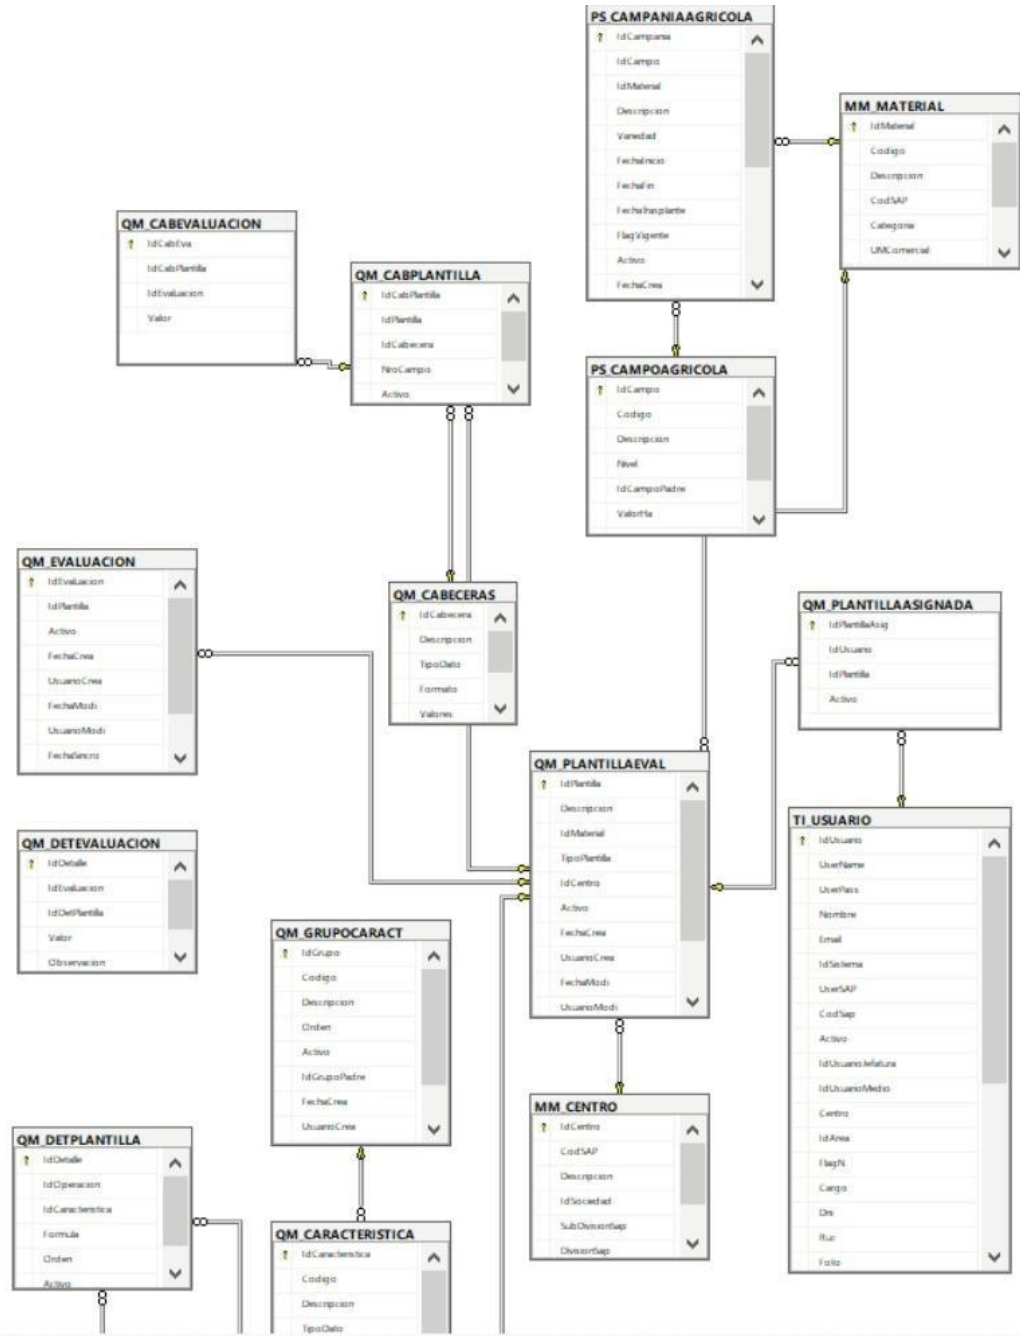


Figura 3

Cartilla fitosanitaria en instalación-Palto

		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	TOTAL	GRADO	PROMEDIO	%	
DIF. BROTES	PROTOPLOSIS LONGIFLUA	N° BROTES INFESTADOS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0
		N° LARVAS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	ARGYROTAENIA SPHALEROPEA	N° BROTES INFESTADOS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0
		N° LARVAS BROTE	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	PULGON	N° BROTES INFESTADOS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0
		3° DE INFESTACION	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	TRIPS TABACO	N° BROTES INFESTADOS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0
		3° NINFAS Y ADULTOS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	OLIGONCHUS PUNICAE OLIGONCHUS VOTHEREI	N° HOJAS INFESTADAS	2	1	1	1	2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	27
		3° INFESTACION (NINFAS-ADU)	2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	28
		3° INFESTACION (HUEVOS)	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
	ALEURODIDUS COCCUS ALEURODIDUS JULIENAE	N° HOJAS INFESTADAS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
3° INFESTACION (NINFAS-ADU)		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
3° DE FLUMAGINA		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
OXYDA VESULIA	N° HOJAS INFESTADAS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0	
	N° MASAS HOJAS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	N° LARVAS CHICAS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	N° LARVAS GRANDES	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
ONETICUS KIRBYI	N° HOJAS INFESTADAS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0	
	N° LARVAS CHICAS	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	N° LARVAS GRANDES	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	

Figura 4

Flujo de datos para obtener la cartilla de evaluación Fitosanitaria en instalación-Palto

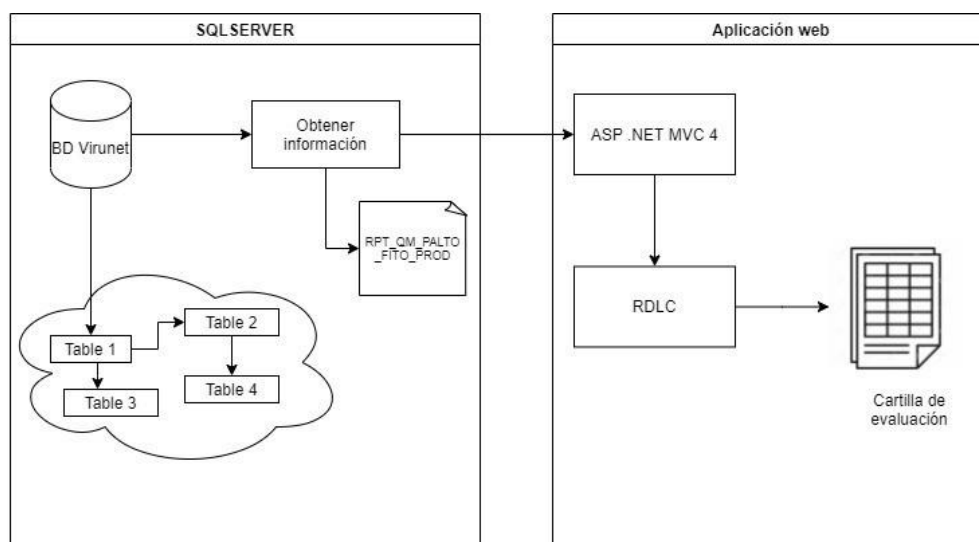
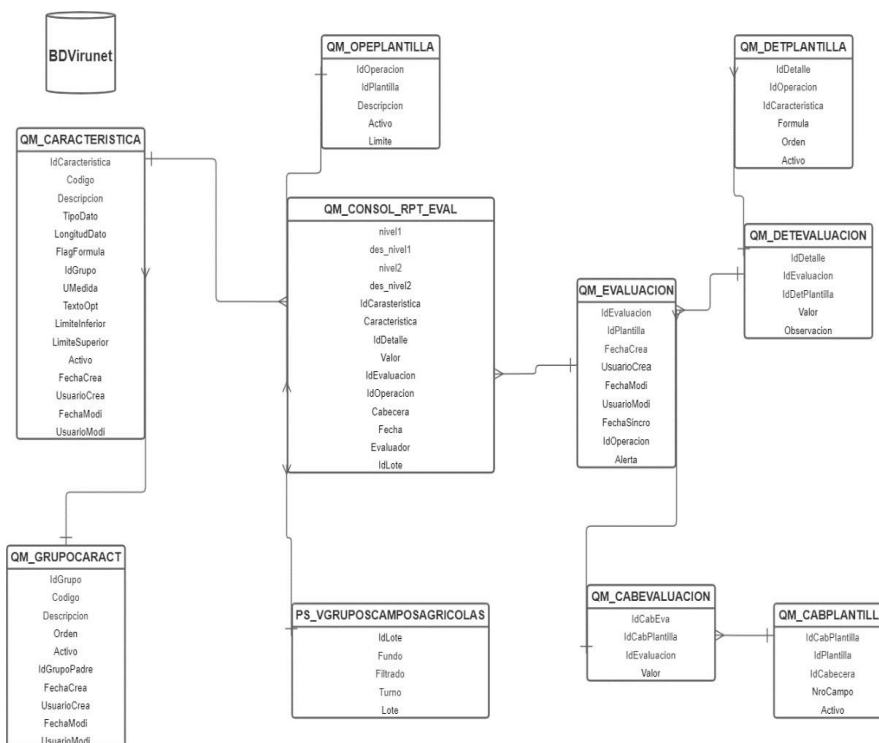


Figura 5.

Diagrama data warehouse*, según tablas del reporte de Instalación Fitosanitaria – Palto



*modelo copo de nieve

Teniendo el modelo data warehouse, se procedió a consolidar toda la data en la tabla QM_CONSOL_RPT_EVAL y para ello:

1. Se consolidó todas las evaluaciones de la cartilla de evaluación Fitosanitaria en Instalación–Palto correspondientes a los años 2019 y 2020, tal como se muestran en las figuras 5; 6 y 7.

Figura 6

Estructura de la tabla QM_LISTA_EVALUACIONES

QM_LISTA_EVALUACIONES
IDLISTAEVALUACION
NOMBRE
EVALUADOR
IDPLANTILLA
IDOPERACION
FECHA
EDAD
VALOR
FUNDO
IDFILTRADO
FILTRADO
IDTURNO
TURNO
CAMPANIA
IDLOTE
LOTE
SUPERVISOR
PARADAS
SUBSECOTR
PLANTILLA
OPERACION
FECHAINICREA
FECHAFINCREA

Figura 7.

Función para consolidar todas las evaluaciones en la tabla QM_LISTA_EVALUACIONES

```
DECLARE @FechaBucle as date
SET @FechaBucle = '2019-01-01'
WHILE @FechaBucle < CAST('2020-12-31' AS DATE)
BEGIN
    IF EXISTS(select IdEvaluacion
              from QM_EVALUACION
              WHERE CAST(FechaCrea AS DATE) = @FechaBucle
              AND IdPlantilla = 1 AND IDOPERACION = 2)
    BEGIN
        INSERT INTO QM_LISTA_EVALUACIONES
        exec QM_EVALUACION_GETBYOPERACION_2 @idOperacion= 2,@fecha= @FechaBucle,@idCentro= 5568
        PRINT('EVALUACIÓN ENCONTRADA PARA LA FECHA' + CAST(@FechaBucle AS VARCHAR))
    END
    ELSE
    BEGIN
        PRINT('NO HAY EVALUACIÓN PARA LA FECHA' + CAST(@FechaBucle AS VARCHAR))
    END
    SET @FechaBucle = DATEADD(DAY,1, @FechaBucle)
END
```

2. Se creó el procedimiento para consolidar todas las evaluaciones de las tablas de la data warehouse y su almacenamiento en la tabla QM_CONSOL_RPT_EVAL, Figura 8.

Figura 8
Procedimiento que guardar los datos consolidados en la tabla QM_CONSOL_RPT_EVAL

```
DECLARE @IDOPERACION AS int
DECLARE @Fecha AS date
Declare @Evaluador as varchar(20)
Declare @IdLote int
DECLARE RptInfo CURSOR FOR SELECT IDOPERACION, Fecha, EVALUADOR, IdLOTE
FROM QM_LISTA_EVALUACIONES
WHERE FECHA >= '2019-01-01'
AND IDOPERACION = 2
OPEN RptInfo
FETCH NEXT FROM RptInfo INTO @IDOPERACION, @Fecha, @Evaluador, @IdLote
WHILE @@fetch_status = 0
BEGIN
PRINT CAST(@Fecha AS VARCHAR) + ' ' + @Evaluador

INSERT INTO QM_CONSOL_RPT_EVAL(NIVEL1,des_nivel1,nivel2,des_nivel2,IdCarasteristica,Caracteristica,
IdDetalle,Valor,IdEvaluacion,Cabecera,IdOperacion,Fecha,Evaluador,IdLote)
EXEC RPT_QM_PALTO_FITO_PROD @IDOPERACION,@Fecha,@Evaluador,@IdLote,1

FETCH NEXT FROM RptInfo INTO @IDOPERACION, @Fecha, @Evaluador, @IdLote
END
CLOSE RptInfo
DEALLOCATE RptInfo
```

b) Limpieza de datos

La limpieza de datos se trabajó usando el entorno de desarrollo Jupyter Lab y el lenguaje de programación Python, tal como se muestra en las Figuras 9; 10 y 11.

Figura 9.
Tratamiento de datos según las librerías de pandas y numpy de Python

```
# Tratamiento de datos
# =====
import pandas as pd
import numpy as np
```

Figura 10
Librería pyodbc para conectar a base de datos y obtener resultados de la tabla QM_RPT_CONSOL_EVAL

```
# Conexión a BD
# =====
import pyodbc
```


Figura 11 Procedimiento almacenado*, SP_OBTENER_TOTALIZADO_PLAGAS para obtener las evaluaciones de Fitosanitaria en Instalación–Palto

```
try:
    with conexion.cursor() as cursor:
        consulta = "exec STP_OBTENER_TOTALIZADO_PLAGAS ?,?,?,?"
        cursor.execute(consulta, (dFechaInicio, dFechaFin, 1,0))

        rows = cursor.fetchall()

        cols = []

        for i,_ in enumerate(cursor.description):
            cols.append(cursor.description[i][0])

        pd.DataFrame(np.array(rows), columns = cols)

        df = pd.DataFrame(columns = ['Evaluador', 'Fecha', 'Fundo', 'Filtrado', 'Turno', 'Lote', 'Grupo_Plaga',
            'Plaga', 'Caracteristica', 'Suma', 'Grado', 'Promedio', 'Porcentaje'])

        for i in range(len(rows)):
            df.loc[i] = list(rows[i])
except Exception as e:
    print(e)
```

*desarrollado por los autores

Una vez obtenido toda la información, se creó un algoritmo para poder recorrer los datos de la tabla y graficar las plagas por Filtrado y Lote, tal como muestra la Figura 12.

Figura 12 Algoritmo para el filtrado de datos

```
arrPlagas = df["Plaga"].unique()
arrFiltrado = df["Filtrado"].unique()

from pathlib import Path

for filtrado in arrFiltrado:
    dfFiltrado = df[df["Filtrado"] == filtrado]
    arrLote = dfFiltrado["Lote"].unique()
    for lote in arrLote:
        dfLote = dfFiltrado[dfFiltrado["Lote"] == lote]
        arrPlagaxLote = dfLote["Plaga"].unique()
        for plaga in arrPlagaxLote:
            dfPlaga = dfLote[dfLote["Plaga"] == plaga]
            arrPlagaxCarac = dfPlaga["Caracteristica"].unique()
            for caracteristica in arrPlagaxCarac:
                dfCarac = dfPlaga[dfPlaga["Caracteristica"] == caracteristica]
                dfCarac = dfCarac.sort_values(by=['Fecha'])

                if lote == "1053" and dfCarac.shape[0] > 10:

                    dfCarac = dfCarac[dfCarac["Suma"] > 0]

                    x = dfCarac["Fecha"]
                    y = dfCarac["Suma"]
                    title = "F()- L() - {} - {}".format(filtrado, lote, plaga, caracteristica)

                    pathCarac = Path('{}').format('img', plaga.replace('/', ''))
                    pathCarac.mkdir(parents=True, exist_ok=True)

                    fig = plt.figure(figsize=(12, 6))
                    plt.plot(x,y)
                    plt.title(title)
                    plt.savefig('{}\{}.png'.format('img', plaga.replace('/', ''), caracteristica.replace('/', '')))
                    plt.show()
```

2. Para elaborar un diagnóstico del comportamiento de las variables climatológicas en 2019-2020.

a) Recolección de datos

La empresa Viru S.A. nos proporcionó la data sobre las variables climatológicas, data proveniente de las estaciones meteorológicas Davis Weather. Esta data se organizó en un Excel, Figura 13.

Figura 13

Data sobre variables climatológicas, 2019-2020

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA
Año	Semana	Mes	Fecha	ET(mm)	T° MIN/DIA (°C)	T° MAX/DIA (°C)	Dif. Térmico	T° Prom/Día (°C)	Rad. Solar Prom.	Rad. Solar Max.	HUMEDAD PROM.	HUMEDAD MIN.	HUMEDAD MAX.	Nº Hrs Rocio Día	Humedad Relativa Min.(%)	Humedad Relativa Max.(%)	Velocidad del Viento Promedio (km/hr)	Dirección del Viento (07:00 pr)	LR Máx. (MJ/ha/Día)	Precipit. MM						
2020	1	Enero	01-Ene	4	19.1	26.2	7.1	22.3	244	882	86.0	73.0	94.0	2.5	73	94	3.1	estesuroeste	50	0.0						
2020	1	Enero	02-Ene	3.7	19.9	27.9	8.0	23.0	214	1118	82.0	66.0	94.0	0.0	66	91	2.6	este	50	0.0						
2020	1	Enero	03-Ene	4.2	18.3	27.2	8.9	22.6	249	932	81.0	66.0	93.0	1.5	68	92	3.7	estenortocoste	50	0.0						
2020	1	Enero	04-Ene	3.9	18.3	26.8	8.5	22.6	240	1092	80.0	69.0	91.0	24.0	72	92	2.6	suroeste	50	0.0						
2020	2	Enero	05-Ene	3.9	19.8	27.4	7.6	22.8	240	1014	81.0	66.0	93.0	24.0	69	94	2.5	suroeste	50	0.0						
2020	2	Enero	06-Ene	3.7	19.1	26.7	7.6	21.9	229	896	83.0	68.0	88.0	6.0	71	94	3.2	oeste	50	0.0						
2020	2	Enero	07-Ene	4.1	18.1	27.1	9.0	22.1	253	1020	78.0	65.0	88.0	2.0	69	94	2.5	suroeste	50	0.0						
2020	2	Enero	08-Ene	4.4	17.6	27.3	9.7	22.7	251	886	74.0	56.0	90.0	0.0	68	93	2.8	suroeste	50	0.0						
2020	2	Enero	09-Ene	4.1	19.2	26.7	7.5	22.6	298	949	86.0	72.0	91.0	0.0	72	93	2.9	suroeste	50	0.0						
2020	2	Enero	10-Ene	3.4	19.3	26.6	7.3	21.7	216	1053	86.0	74.0	93.0	4.0	73	95	3.1	oeste	50	0.0						
2020	2	Enero	11-Ene	2.3	19.1	25.7	6.6	22.0	135	621	88.0	78.0	94.0	7.0	74	95	2.4	suroeste	50	0.0						
2020	3	Enero	12-Ene	3.7	18.8	26.1	7.3	21.8	238	932	82.0	68.0	93.0	2.5	73	95	3.1	oeste	50	0.0						
2020	3	Enero	13-Ene	4.1	17.7	26.4	8.7	22.1	255	877	82.0	70.0	90.0	1.0	70	94	3.0	oeste	50	0.0						
2020	3	Enero	14-Ene	3.8	18.4	27.1	8.7	22.2	239	1048	85.0	71.0	93.0	1.0	70	94	2.4	suroeste	50	0.0						
2020	3	Enero	15-Ene	4.3	18.7	28.0	9.3	23.1	255	893	86.0	71.0	93.0	0.0	69	93	2.4	suroeste	50	0.0						
2020	3	Enero	16-Ene	4.2	19.1	28.2	9.1	22.8	250	884	85.0	73.0	93.0	1.0	66	94	3.0	oeste	50	0.0						
2020	3	Enero	17-Ene	3.8	19.2	26.3	7.1	22.1	235	868	85.0	71.0	94.0	4.5	73	94	3.1	oeste	50	0.0						
2020	3	Enero	18-Ene	3.7	19.2	28.2	9.0	23.0	221	1063	85.0	71.0	93.0	2.0	66	94	2.2	oeste	50	0.0						
2020	4	Enero	19-Ene	4.1	18.4	27.8	9.4	22.8	241	1069	86.0	73.0	93.0	0.0	66	93	2.4	estesuroeste	50	0.0						
2020	4	Enero	20-Ene	4.1	19.7	27.5	7.8	23.4	244	923	83.0	70.0	93.0	0.0	69	91	2.6	estesuroeste	50	0.0						
2020	4	Enero	21-Ene	3.9	18.7	28.1	9.5	22.5	232	893	82.0	68.0	93.0	0.0	66	93	2.3	estesuroeste	50	0.0						
2020	4	Enero	22-Ene	2.6	21.3	28.9	7.5	24.5	136	1027	84.0	71.0	92.0	0.0	68	88	2.8	estesuroeste	50	0.0						
2020	4	Enero	23-Ene	2.9	23.2	29.2	6.0	25.4	156	821	87.0	80.0	92.0	0.0	65	88	1.9	estesuroeste	50	0.0						
2020	4	Enero	24-Ene	2.7	22.2	30.1	7.9	22.5	149	1018	84.0	70.0	94.0	0.0	56	90	1.6	suroeste	50	0.0						

b) Limpieza de datos

La limpieza de estos datos se realizó a través del entorno de desarrollo Jupyter Lab y el lenguaje de programación Python.

Figura 14 Importación de data desde Excel a dataframe con la librería pandas.

```
exClima = pd.ExcelFile('D:/Proyectos GitHub/Python/Datos/Datos Climaticos Viru Palto.xlsx')
```

```
dfClima = exClima.parse('TABLA')
```

	Año	Semana	Mes	Fecha	ET(mm)	T° MIN/DIA (°C)	T° MAX/DIA (°C)	Dif. Térmico	T° Prom <15 °C	T° Prom 15 a 17 °C	HR > 85%	HR > 90%	HR > 95%	Nº Hrs Rocio Día	Humedad Relativa Min.(%)	Humedad Relativa Max.(%)	Velocidad del Viento Promedio (km/hr)	Dirección del Vient (07:00 pr)
1096	2019	1	Enero	2019-01-01	4.0	19.0	26.4	7.4	0.0	0.0	12.5	5.5	0.0	0.0	NaN	92.0	3.4	norest
1097	2019	1	Enero	2019-01-02	4.2	19.1	26.8	7.7	0.0	0.0	13.0	8.0	0.0	0.0	NaN	92.0	4.2	norest
1098	2019	1	Enero	2019-01-03	3.2	20.4	27.4	7.0	0.0	0.0	12.0	5.5	0.0	0.0	NaN	92.0	2.5	norest
1099	2019	1	Enero	2019-01-04	4.3	18.6	28.2	9.6	0.0	0.0	12.0	4.5	0.0	0.0	NaN	92.0	3.4	estenorest
1100	2019	1	Enero	2019-01-05	3.6	20.8	27.4	6.6	0.0	0.0	13.5	5.5	0.0	0.0	NaN	92.0	3.6	norest

Además, se usó la librería matplotlib y se desarrolló un algoritmo para graficar las variables climatológicas de Evapotranspiración, Temperatura mínima, Temperatura máxima, Radiación solar promedio, Humedad promedio y temperatura promedio para los años 2019 y 2020, tal como se muestran en las Figuras 15 y Figura 16, respectivamente.

Figura 15 Algoritmos para generar gráficos de evolución de las variables climatológicas, 2019

Año 2019

```
dfClima2019 = dfClima[(dfClima['Año'] == 2019)]

arrVarClima = dfClima2019.columns
for varClima in arrVarClima:
    if varClima != 'Fecha' and varClima != 'Año':

        dfVarClima = dfClima2019[dfClima2019[varClima] != 0]

        x = dfVarClima['Fecha']
        y = dfVarClima[varClima]

        plt.rcParams["figure.figsize"] = (20,5)

        plt.title(objNombClima[varClima] + " 2019", fontdict={ 'fontsize' : 30})
        plt.xlabel('Fecha')
        plt.ylabel(varClima)
        plt.plot(x,y, label = varClima)
        plt.show()

print("Fecha Max:" + str(dfVarClima[dfVarClima[varClima] == dfVarClima[varClima].max()]))
print("Máximo : " + str(dfVarClima[varClima].max()))
print("Fecha Min:" + str(dfVarClima[dfVarClima[varClima] == dfVarClima[varClima].min()]))
print("Mínimo : " + str(dfVarClima[varClima].min()))
```

Figura 16 Algoritmos para general gráficos de evolución de las variables climatológicas, 2020

Año 2020

```
dfClima2020 = dfClima[(dfClima['Año'] == 2020)]

arrVarClima = dfClima2020.columns
for varClima in arrVarClima:
    if varClima != 'Fecha' and varClima != 'Año':

        dfVarClima = dfClima2020[dfClima2020[varClima] != 0]

        x = dfVarClima['Fecha']
        y = dfVarClima[varClima]

        plt.rcParams["figure.figsize"] = (20,5)

        plt.title(objNombClima[varClima] + " 2020", fontdict={ 'fontsize' : 30})
        plt.xlabel('Fecha')
        plt.ylabel(varClima)
        plt.plot(x,y, label = varClima)
        plt.show()

print("Fecha Max:" + str(dfVarClima[dfVarClima[varClima] == dfVarClima[varClima].max()]))
print("Máximo : " + str(dfVarClima[varClima].max()))
print("Fecha Min:" + str(dfVarClima[dfVarClima[varClima] == dfVarClima[varClima].min()]))
print("Mínimo : " + str(dfVarClima[varClima].min()))
```

3. Realizar un análisis relacional entre el tipo de plagas en el cultivo de palto y las variables climatológicas para el año 2019-2020.

Para realizar el análisis relacional entre el tipo de plagas en el cultivo de palto y las variables climatológicas hemos hecho uso de las librerías *pandas* y *numpy* para el tratamiento de datos, también hemos usado *matplotlib* para graficar y *sklearn* para implementar nuestro modelo.

Figura 17

Importación de paquetes para tratamiento de datos

```
# Tratamiento de datos
# =====
import pandas as pd
import numpy as np
```

Figura 18

Importación de paquetes para graficar las matrices

```
# Gráficos
# =====
import matplotlib.pyplot as plt
from matplotlib import style
import seaborn as sns
```

Figura 19

Importación de paquetes para preprocesado y modelado

```
# Preprocesado y modelado
# =====
from scipy.stats import pearsonr
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score
from sklearn.metrics import mean_squared_error
import statsmodels.api as sm
import statsmodels.formula.api as smf
```

- a) *Olygonichus punicae*, *oligonychus yothersi* – G^o Infestación (Ninfas Adultas)

Esta plaga durante nuestro análisis preliminar cuenta con bastante información durante todo el año, debido a esto es un buen candidato para poder realizar nuestro modelo de predicción.

- Paso 1: Primero buscamos dentro de nuestros Filtrados, aquel que cuente con más cantidad de evaluaciones durante el año 2019.

Figura 20

Bucle para revisar la mayor cantidad de evaluaciones por Filtrado

```
for filtrado in df["Filtrado"].unique():
    print("Filtrado: " + filtrado)
    nCantidadFiltrado = df[df["Filtrado"] == filtrado].shape[0]
    print("Cantidad: " + str(nCantidadFiltrado))
    print("*****")
```

Figura 21

Resultado del bucle de búsqueda de evaluaciones por Filtrado

```
Filtrado: 10N
Cantidad: 1854
*****
Filtrado: 11N
Cantidad: 2320
*****
Filtrado: 13
Cantidad: 2032
*****
Filtrado: 15
Cantidad: 511
*****
Filtrado: 16
Cantidad: 666
*****
Filtrado: 17
Cantidad: 1059
*****
Filtrado: 18
Cantidad: 376
*****
Filtrado: 20
Cantidad: 1000
*****
Filtrado: 22
Cantidad: 617
*****
Filtrado: 29
Cantidad: 3529
*****
Filtrado: 30
Cantidad: 2962
*****
Filtrado: 9N
Cantidad: 51
*****
```

- Paso 2: Del resultado encontrado nos damos cuenta que los Filtrados 17,20 y 20N cuentan con bastantes evaluaciones, por lo tanto, estos Filtrados serán los escogidos para realizar nuestro modelo.

Figura 22

Los 3 Filtrados que tienen mayor cantidad de evaluaciones

```
filtradosEleg = ["17", "20", "10N"]
dfFilEleg = df[df["Filtrado"].isin(filtradosEleg)]
```

```
dfFilEleg.shape[0]
```

3913

- Paso 3: En esta parte nosotros haremos los filtros necesarios para obtener la plaga dentro del año 2019.

Figura 23

Filtrando la plaga Olygonichus Punicae, Oligonychus Yothersi para la característica G° Infestación (NINFAS-ADULTOS) y obteniendo la información del Excel sobre el clima

```
dfPlg = dfFilEleg[dfFilEleg["Plaga"] == "OLYGNICHUS PUNICAE, OLIGONYCHUS YOTHERSI"]
```

```
dfCarac = dfPlg[dfPlg["Caracteristica"] == "G° INFESTACIÓN (NINFAS-ADULTOS)"]
```

```
dtIniPoda = datetime.strptime('2019-01-01', '%Y-%m-%d')
dtFinPoda = datetime.strptime('2019-12-31', '%Y-%m-%d')
dfPoda = dfCarac[(dfCarac["Fecha"] >= dtIniPoda.date()) & (dfCarac["Fecha"] <= dtFinPoda.date())]
```

```
data_weather = pd.ExcelFile('D:/Proyectos GitHub/Python/Datos/Datos Climaticos Viru Palto.xlsx')
df_weather = data_weather.parse('TABLA')
data_weather.close()
```

```
df_weather = df_weather[df_weather['Año'] == 2019]
df_weather = df_weather[(df_weather['Fecha'] >= dFechaInicio) & (df_weather['Fecha'] <= dFechaFin)]
df_weather.reset_index(drop = True, inplace = True)
```

```
df_weather = df_weather[['Fecha', 'ET(mm)', 'T° MIN/DIA (°C)', 'T° MAX/DIA (°C)', 'Rad. Solar PROM.', 'HUMEDAD PROM.', 'T° Prom/DIA']
df_weather = df_weather.rename(columns = {'ET(mm)': 'ET',
                                          'T° MIN/DIA (°C)': 'T_MIN',
                                          'T° MAX/DIA (°C)': 'T_MAX',
                                          'Rad. Solar PROM.': 'RS_PROM',
                                          'HUMEDAD PROM.': 'HUM_PROM',
                                          'T° Prom/DIA (°C)': 'TMP_PROM',
                                          'Semana': 'Semana'})
```

Figura 24

Algoritmo para imprimir las correlaciones, distribuciones de variables y gráficos.

```
arrPlagas = []
dfPlagasElegidas = dfPoda[dfPoda['Plaga'] == 'OLYGNICHUS PUNICAE, OLIGONYCHUS YOTHERSI']
dffilter = dfPlagasElegidas
arrFiltrados = dfPlagasElegidas['Filtrado'].unique()
#dffilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dffiltrado = dffilter[dffilter['Filtrado'] == filtrado]
    arrTurno = dffiltrado['Turno'].unique()
    for turno in arrTurno:
        dfTurno = dffiltrado[dffiltrado['Turno'] == turno]
        arrLote = dfTurno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfTurno[dfTurno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Caracteristica'])['Grado'].sum().reset_index()

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by='Fecha')
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)
                    # Filtrar el dataset por las variables que se usarán
                    #df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'T_MIN', 'T_MAX', 'RS_PROM', 'HM_PROM', 'Grado']]
                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']]

                    df_union[['Grado']] = df_union[['Grado']].apply(pd.to_numeric)
                    #print(df_union)

                    dfCorrelacion = df_union.corr().abs()

                    dfCorrelacion_index = dfCorrelacion[dfCorrelacion['Grado'] > 0.60]

                    if dfCorrelacion_index.shape[0] > 1 and df_union.shape[0] > 5:

                        dfCorrexLote = dfCorrexLote.append({'Filtrado': filtrado, 'Turno': turno, 'Lote': lote, 'Plaga': plaga, 'Caracteristica': caracteristica})
                        arrPlagas.append(plaga + ' ' + caracteristica)
                        #Creando Mapa de Calor
                        sns.set()

                        print('-----')
                        print('Lugar: Filtrado {} - Turno {} - Lote {}'.format(filtrado, turno, lote))
                        print('Plaga: ', plaga)
                        print('Caracteristica: ', caracteristica)

                        print('-----')

                        print(df_union)

                        ax = sns.heatmap(dfCorrelacion, annot = True)
                        iContador = iContador + 1
                        plt.title('{}'.format(caracteristica), fontdict = {'fontsize' : '15'})
                        #plt.show()

                        # Gráfico de distribución para cada variable numérica
                        # =====
                        # Ajustar número de subplots en función del número de columnas
                        fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(11, 5))
                        axes = axes.flat
                        columnas_numeric = df_union[['ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']].select_dtypes(include=['float64', 'int64'])

                        for i, column in enumerate(columnas_numeric):
                            sns.histplot(
                                data = df_union[['ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']],
                                x = column,
                                stat = "count",
                                kde = True,
                                color = (list(plt.rcParams['axes.prop_cycle'])*2)[i]["color"],
                                line_kws= {'linewidth': 2},
                                alpha = 0.3,
                                ax = axes[i]
                            )
                            axes[i].set_title(column, fontsize = 10, fontweight = "bold")
                            axes[i].tick_params(labelsize = 8)
                            axes[i].set_xlabel("")

                        fig.tight_layout()
                        plt.subplots_adjust(top = 0.9)
                        fig.suptitle('Distribución variables numéricas', fontsize = 10, fontweight = "bold");

                        plt.show()
```

b) *Olygonichus punicae*, *Oligonychus yothersi* – G⁰ Infestación (Huevos)

Esta plaga durante nuestro análisis preliminar cuenta con bastante información durante todo el año, debido a esto es un buen candidato para poder realizar nuestro modelo de predicción.

- Paso 1: Primero buscamos dentro de nuestros Filtrados, aquel que cuenta con más cantidad de evaluaciones durante el año 2020

Figura 25

Bucle para revisar la mayor cantidad de evaluaciones por Filtrado

```
for filtrado in df["Filtrado"].unique():
    print("Filtrado: " + filtrado)
    nCantidadFiltrado = df[df["Filtrado"] == filtrado].shape[0]
    print("Cantidad: " + str(nCantidadFiltrado))
    print("*****")
```

Figura 26

Resultado de bucle de búsqueda de evaluaciones por filtrado

```
Filtrado: 10
Cantidad: 197
Filtrado: 10N
Cantidad: 875
Filtrado: 11N
Cantidad: 151
Filtrado: 17
Cantidad: 3763
Filtrado: 20
Cantidad: 3269
Filtrado: 28
Cantidad: 461
Filtrado: 29
Cantidad: 261
Filtrado: 9N
Cantidad: 181
```

- Paso 2: Del resultado encontrado nos damos cuenta que los Filtrados 17, 20 y 10N cuentan con bastantes evaluaciones,

por lo tanto, estos Filtrados serán los escogidos para realizar nuestro modelo.

Figura 27

Selección de filtrados con mayor número de evaluaciones

```
filtradosEleg = ["17", "20", "10N"]  
dfFilEleg = dfPlaga[dfPlaga["Filtrado"].isin(filtradosEleg)]
```

- Paso 3: En esta parte nosotros haremos los filtros necesarios para obtener la plaga dentro del año 2020.

Figura 28

Filtrando los datos de la plaga OLYGONICHUS PUNICAE, OLIGONYCHUS YOTHERSI y obteniendo la información del Excel sobre el clima

```
data_weather = pd.ExcelFile('D:/Proyectos Github/Python/Datos/Datos Climaticos Viru Palto.xlsx')  
df_weather = data_weather.parse('TABLA')  
data_weather.close()  
  
df_weather = df_weather[df_weather['Año'] == 2020]  
df_weather = df_weather[(df_weather['Fecha'] >= dFechaInicio) & (df_weather['Fecha'] <= dFechaFin)]  
df_weather.reset_index(drop = True, inplace = True)  
  
df_weather = df_weather[['Fecha', 'ET(mm)', 'Tº MIN/DIA (°C)', 'Tº MAX/DIA (°C)', 'Rad. Solar Prom.', 'HUMEDAD PROM.', 'Tº Prom/Día (°C)']  
df_weather = df_weather.rename(columns = {'ET(mm)': 'ET',  
                                          'Tº MIN/DIA (°C)': 'T_MIN',  
                                          'Tº MAX/DIA (°C)': 'T_MAX',  
                                          'Rad. Solar Prom.': 'RS_PROM',  
                                          'HUMEDAD PROM.': 'HM_PROM',  
                                          'Tº Prom/Día (°C)': 'TMP_PROM',  
                                          'Semana': 'Semana'})
```

- Paso 4: Con los filtrados escogidos procederemos a evaluar los modelos de cada uno de estos.

Figura 29

Algoritmo para imprimir las correlaciones, distribuciones de variables y gráficos.

```
arrPlagas = []
dfFilter = dfFileEleg
arrFiltrados = dfFileEleg['Filtrado'].unique()
#dfFilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dfFiltrado = dfFilter[dfFilter['Filtrado'] == filtrado]
    arrTurno = dfFiltrado['Turno'].unique()
    for turno in arrTurno:
        dfTurno = dfFiltrado[dfFiltrado['Turno'] == turno]
        arrLote = dfTurno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfTurno[dfTurno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Caracteristica'])['Grado'].sum().reset_index()

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)

                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HMM_PROM', 'Grado']]

                    df_union[["Grado"]] = df_union[["Grado"]].apply(pd.to_numeric)

dfCorrelacion = df_union.corr().abs()
```

c) Bemisia Tabaci – G° Infestación y Adultos/Inflorescencia

- Paso 1: Primero buscamos dentro de nuestros Filtrados, aquel que cuenta con más cantidad de evaluaciones durante el año 2020

Figura 30

Bucle para revisar la mayor cantidad de evaluaciones por Filtrado

```
for filtrado in df["Filtrado"].unique():
    print("Filtrado: " + filtrado)
    nCantidadFiltrado = df[df["Filtrado"] == filtrado].shape[0]
    print("Cantidad: " + str(nCantidadFiltrado))
    print("*****")
```

Figura 31

Resultado de bucle de búsqueda de evaluaciones por filtrado

```
Filtrado: 10
Cantidad: 197
Filtrado: 10N
Cantidad: 875
Filtrado: 11N
Cantidad: 151
Filtrado: 17
Cantidad: 3763
Filtrado: 20
Cantidad: 3269
Filtrado: 28
Cantidad: 461
Filtrado: 29
Cantidad: 261
Filtrado: 9N
Cantidad: 181
```

- Paso 2: Del resultado encontrado nos damos cuenta que los Filtrados 17, 20 y 10N cuentan con bastantes evaluaciones, por lo tanto, estos Filtrados serán los escogidos para realizar nuestro modelo.

Figura 32

Selección de filtrados con mayor número de evaluaciones

```
filtradosEleg = ["17", "20", "10N"]
dfFilEleg = dfPlaga[dfPlaga["Filtrado"].isin(filtradosEleg)]
```

- Paso 3: En esta parte nosotros haremos los filtros necesarios para obtener la plaga dentro del año 2020.

Figura 33

Filtrando los datos de la plaga Bemisia Tabaci – G° Infestación (Ninfas-Adultos) y obteniendo la información del Excel sobre el clima

```
data_weather = pd.ExcelFile('D:/Proyectos Github/Python/Datos/Datos Climaticos Viru Palto.xlsx')
df_weather = data_weather.parse('TABLA')
data_weather.close()

df_weather = df_weather[df_weather['Año'] == 2020]
df_weather = df_weather[(df_weather['Fecha'] >= dFechaInicio) & (df_weather['Fecha'] <= dFechaFin)]
df_weather.reset_index(drop = True, inplace = True)

df_weather = df_weather[['Fecha', 'ET(mm)', 'Tº MIN/DIA (°C)', 'Tº MAX/DIA (°C)', 'Rad. Solar Prom.', 'HUMEDAD PROM.', 'Tº Prom/Día (°C)']]
df_weather = df_weather.rename(columns = {'ET(mm)': 'ET',
                                          'Tº MIN/DIA (°C)': 'T_MIN',
                                          'Tº MAX/DIA (°C)': 'T_MAX',
                                          'Rad. Solar Prom.': 'RS_PROM',
                                          'HUMEDAD PROM.': 'HM_PROM',
                                          'Tº Prom/Día (°C)': 'TMP_PROM',
                                          'Semana': 'Semana'})
```

- Paso 4: Con los filtrados escogidos procederemos a evaluar los modelos de cada uno de estos.

Figura 34

Algoritmo para imprimir las correlaciones, distribuciones de variables y gráficos.

```
arrPlagas = []
dffilter = dfFileleg
arrFiltrados = dfFileleg['Filtrado'].unique()
#dffilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dffiltrado = dffilter[dffilter['Filtrado'] == filtrado]
    arrTurno = dffiltrado['Turno'].unique()
    for turno in arrTurno:
        dfturno = dffiltrado[dffiltrado['Turno'] == turno]
        arrLote = dfturno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfturno[dfturno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by='Fecha')

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Caracteristica'])['Grado'].sum().reset_index()

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by='Fecha')
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha': 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)

                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']]

                    df_union[['Grado']] = df_union[['Grado']].apply(pd.to_numeric)

                    dfCorrelacion = df_union.corr().abs()
```

d) Trips Tabaci – G° Ninfas y adultos/ inflorescencia

- Paso 1: Primero buscamos dentro de nuestros Filtrados, aquel que cuenta con más cantidad de evaluaciones durante el año 2020

Figura 35

Bucle para revisar la mayor cantidad de evaluaciones por Filtrado

```
for filtrado in df["Filtrado"].unique():
    print("Filtrado: " + filtrado)
    nCantidadFiltrado = df[df["Filtrado"] == filtrado].shape[0]
    print("Cantidad: " + str(nCantidadFiltrado))
    print("*****")
```

Figura 36

Resultado de bucle de búsqueda de evaluaciones por filtrado

```
Filtrado: 10
Cantidad: 197
Filtrado: 10N
Cantidad: 875
Filtrado: 11N
Cantidad: 151
Filtrado: 17
Cantidad: 3763
Filtrado: 20
Cantidad: 3269
Filtrado: 28
Cantidad: 461
Filtrado: 29
Cantidad: 261
Filtrado: 9N
Cantidad: 181
```

- Paso 2: Del resultado encontrado nos damos cuenta que los Filtrados 17, 20 y 10N cuentan con bastantes evaluaciones, por lo tanto, estos Filtrados fueron los escogidos para realizar nuestro modelo.

Figura 37

Selección de filtrados con mayor número de evaluaciones

```
filtradosEleg = ["17", "20", "10N"]
dfFilEleg = dfPlaga[dfPlaga["Filtrado"].isin(filtradosEleg)]
```

- Paso 3: En esta parte nosotros haremos los filtros necesarios para obtener la plaga dentro del año 2020.

Figura 38

Filtrando los datos de la plaga G° Ninfas y Adultos/ inflorescencia y obteniendo la información del Excel sobre el clima

```
data_weather = pd.ExcelFile('D:/Proyectos Github/Python/Datos/Datos Climaticos Viru Palto.xlsx')
df_weather = data_weather.parse('TABLA')
data_weather.close()

df_weather = df_weather[df_weather['Año'] == 2020]
df_weather = df_weather[(df_weather['Fecha'] >= dFechaInicio) & (df_weather['Fecha'] <= dFechaFin)]
df_weather.reset_index(drop = True, inplace = True)

df_weather = df_weather[['Fecha', 'ET(mm)', 'Tº MIN/DIA (°C)', 'Tº MAX/DIA (°C)', 'Rad. Solar Prom.', 'HUMEDAD PROM.', 'Tº Prom/Día (°C)', 'Semana']]
df_weather.rename(columns = {'ET(mm)' : 'ET',
                              'Tº MIN/DIA (°C)' : 'T_MIN',
                              'Tº MAX/DIA (°C)' : 'T_MAX',
                              'Rad. Solar Prom.' : 'RS_PROM',
                              'HUMEDAD PROM.' : 'HM_PROM',
                              'Tº Prom/Día (°C)' : 'TMP_PROM',
                              'Semana' : 'Semana'})
```

- Paso 4: Con los filtrados escogidos procederemos a evaluar los modelos de cada uno de estos.

Figura 39

Algoritmo para imprimir las correlaciones, distribuciones de variables y gráficos.

```
arrPlagas = []
dffilter = dffileleg
arrFiltrados = dffileleg['Filtrado'].unique()
#dffilter = df
dfcorrexlote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
icontador = 0
for filtrado in arrFiltrados:
    dffiltrado = dffilter[dffilter['Filtrado'] == filtrado]
    arrturno = dffiltrado['Turno'].unique()
    for turno in arrturno:
        dfturno = dffiltrado[dffiltrado['Turno'] == turno]
        arrlote = dfturno['Lote'].unique()
        for lote in arrlote:
            dflote = dfturno[dfturno['Lote'] == lote]
            arrplagaxlote = dflote['Plaga'].unique()
            for plaga in arrplagaxlote:
                dfplaga = dflote[dflote['Plaga'] == plaga]
                arrplagaxcarac = dfplaga['Caracteristica'].unique()
                for caracteristica in arrplagaxcarac:
                    dfcarac = dfplaga[dfplaga['Caracteristica'] == caracteristica]
                    dfcarac = dfcarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Caracteristica'])['Grado'].sum().reset_index()

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfcarac)

                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']]

                    df_union[['Grado']] = df_union[['Grado']].apply(pd.to_numeric)

                    dfCorrelacion = df_union.corr().abs()
```

e) *Dagbertus minensis*, *dagbertus peruanus* - N° Inflorescencia. Infestadas

- Paso 1: Primero buscamos dentro de nuestros Filtrados, aquel que cuente con más cantidad de evaluaciones durante el año 2020.

Figura 40

Bucle para revisar la mayor cantidad de evaluaciones por Filtrado y resultado del bucle de búsqueda de evaluaciones por filtrado

```
for filtrado in df["Filtrado"].unique():
    print("Filtrado: " + filtrado)
    nCantidadFiltrado = df[df["Filtrado"] == filtrado].shape[0]
    print("Cantidad: " + str(nCantidadFiltrado))
    print("*****")
```

```
Filtrado: 10N
Cantidad: 2286
*****
Filtrado: 11N
Cantidad: 3009
*****
Filtrado: 13
Cantidad: 2599
*****
Filtrado: 15
Cantidad: 575
*****
Filtrado: 16
Cantidad: 615
*****
Filtrado: 17
Cantidad: 1487
*****
Filtrado: 18
Cantidad: 419
*****
Filtrado: 20
Cantidad: 1360
*****
Filtrado: 22
Cantidad: 739
*****
Filtrado: 29
Cantidad: 4239
*****
Filtrado: 30
Cantidad: 4050
*****
Filtrado: 9N
Cantidad: 59
*****
```

- Paso 2: Del resultado encontrado nos damos cuenta que los Filtrados 17 y 20 cuentan con bastantes evaluaciones, por lo tanto, estos Filtrados serán los escogidos para realizar nuestro modelo.

Figura 41

Selección de filtrados con mayor número de evaluaciones

```
filtradosEleg = ["17","20"]
dfFilEleg = df[df["Filtrado"].isin(filtradosEleg)]
```

- Paso 3: En esta parte nosotros haremos los filtros necesarios para obtener la plaga dentro del año 2020.

Figura 42

Filtrando los datos de la plaga *Dagbertus minensis*, *dagbertus peruanus* y obteniendo la información del Excel sobre el clima

```
data_weather = pd.ExcelFile('D:/Proyectos GitHub/Python/Datos/Datos Climaticos Viru Palto.xlsx')
df_weather = data_weather.parse('TABLA')
data_weather.close()
```

```
df_weather = df_weather[df_weather['Año'] == 2020]
df_weather = df_weather[(df_weather['Fecha'] >= fechaInicio) & (df_weather['Fecha'] <= fechaFin)]
df_weather.reset_index(drop = True, inplace = True)
```

```
df_weather = df_weather[['Fecha', 'ET(mm)', 'Tº MIN/DIA (°C)', 'Tº MAX/DIA (°C)', 'Rad. Solar Prom.', 'HUMEDAD PROM.', 'Tº Prom/Día (°C)']]
df_weather = df_weather.rename(columns = {'ET(mm)': 'ET',
                                          'Tº MIN/DIA (°C)': 'T_MIN',
                                          'Tº MAX/DIA (°C)': 'T_MAX',
                                          'Rad. Solar Prom.': 'RS_PROM',
                                          'HUMEDAD PROM.': 'HM_PROM',
                                          'Tº Prom/Día (°C)': 'TMP_PROM',
                                          'Semana': 'Semana'})
```

- Paso 4: Con los filtrados escogidos procederemos a evaluar los modelos de cada uno de estos

Figura 43

Algoritmo para imprimir las correlaciones, distribuciones de variables y gráficos.

```
arrPlagas = []
dffilter = dffileg
arrFiltrados = dffileg['Filtrado'].unique()
#dffilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dffiltrado = dffilter[dffilter['Filtrado'] == filtrado]
    arrTurno = dffiltrado['Turno'].unique()
    for turno in arrTurno:
        dfturno = dffiltrado[dffiltrado['Turno'] == turno]
        arrLote = dfturno['Lote'].unique()
        for lote in arrLote:
            dflote = dfturno[dfturno['Lote'] == lote]
            arrPlagaxLote = dflote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfplaga = dflote[dflote['Plaga'] == plaga]
                arrPlagaxCarac = dfplaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfplaga[dfplaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Caracteristica'])['Porcentaje'].sum()

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)

                    # Filtrar el dataset por las variables que se usarán
                    #df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'T_MIN', 'T_MAX', 'RS_PROM', 'HM_PROM', 'Grado']]
                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Porcentaje']]

                    df_union[['Porcentaje']] = df_union[['Porcentaje']].apply(pd.to_numeric)
                    #print(df_union)

                    dfCorrelacion = df_union.corr().abs()

                    dfCorrelacion_index = dfCorrelacion[dfCorrelacion['Porcentaje'] > 0.60]

                    if dfCorrelacion_index.shape[0] > 1 and df_union.shape[0] > 5:

                        dfCorrexLote = dfCorrexLote.append({'Filtrado': filtrado, 'Turno': turno, 'Lote': lote, 'Plaga': plaga, 'C
                        arrPlagas.append(plaga + ' ' + caracteristica)
                        #Creando Mapa de Calor
                        sns.set()
```

4. Entrenar y validar el modelos de predicción de plagas en el cultivo de palto a partir del comportamiento de las variables climatológicas, mediante metodología de aprendizaje automático supervisado.

a) *Olygonichus punicae*, *Oligonychus yothersi* - G⁰ Infestación (Ninfas Adultas)

Una vez encontrado nuestras correlaciones que están representadas por los mapas de calor, escogeremos aquellos Filtrados – Turno – Lote que tengan una correlación > 0.90 a través de un algoritmo implementado.

Figura 44

Algoritmo para encontrar las correlaciones de la plaga *Olygonichus punicae*, *Olygonichus Yotersi* - G⁰ Infestación (Ninfas Adultas)

```
arrPlagas = []
dfPlagasElegidas = dfPoda[dfPoda['Plaga'] == 'OLYGNICHUS PUNICAE, OLYGNICHUS YOTHERSI']
dffilter = dfPlagasElegidas
arrFiltrados = dfPlagasElegidas['Filtrado'].unique()
#dffilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dffiltrado = dffilter[dffilter['Filtrado'] == filtrado]
    arrTurno = dffiltrado['Turno'].unique()
    for turno in arrTurno:
        dfTurno = dffiltrado[dffiltrado['Turno'] == turno]
        arrLote = dfTurno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfTurno[dfTurno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Caracteristica'])['Grado'].sum().reset_index()

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha': 'Fecha[lim]'})
                    df_union = fl_df_weather.join(dfCarac)

                    # Filtrar el dataset por las variables que se usarán
                    #df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'T_MIN', 'T_MAX', 'RS_PROM', 'HM_PROM', 'Grado']]
                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']]

                    df_union[['Grado']] = df_union[['Grado']].apply(pd.to_numeric)
                    #print(df_union)

                    dfCorrelacion = df_union.corr().abs()

                    dfCorrelacion_index = dfCorrelacion[dfCorrelacion['Grado'] > 0.60]

                    if dfCorrelacion_index.shape[0] > 1 and df_union.shape[0] > 5:

                        dfCorrexLote = dfCorrexLote.append({'Filtrado': filtrado, 'Turno': turno, 'Lote': lote, 'Plaga': plaga, 'Caracteristica': caracteristica, ignore_index=True})
                        arrPlagas.append(plaga + ' ' + caracteristica)
                        #Creando Mapa de Color
                        sns.set()
```

b) *Olygonichus punicae*, *Olygonichus yothersi* – G⁰ Infestación (Huevos)

Una vez encontrado nuestras correlaciones que están representadas por los mapas de calor, escogeremos aquellos Filtrados – Turno – Lote que tengan una correlación > 0.60 a través de un algoritmo implementado.

Figura 45

**Algoritmo para encontrar las correlaciones de la plaga
Olygonichus punicae, Olygonichus Yothersi - G^o
Infestación (Huevos)**

```
arrPlagas = []
dfFilter = dfFilEleg
arrFiltrados = dfFilEleg['Filtrado'].unique()
#dfFilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dfFiltrado = dfFilter[dfFilter['Filtrado'] == filtrado]
    arrTurno = dfFiltrado['Turno'].unique()
    for turno in arrTurno:
        dfTurno = dfFiltrado[dfFiltrado['Turno'] == turno]
        arrLote = dfTurno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfTurno[dfTurno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Carac

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)

                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']]

                    df_union[["Grado"]] = df_union[["Grado"]].apply(pd.to_numeric)

                    dfCorrelacion = df_union.corr().abs()

                    dfCorrelacion_index = dfCorrelacion[dfCorrelacion['Grado'] > 0.60]
```

c) Bemisia Tabaci – G^o Infestación y Adultos/Inflorescencia

Una vez encontrado nuestras correlaciones que están representadas por los mapas de calor, escogeremos aquellos Filtrados – Turno – Lote que tengan una correlación > 0.60 a través de un algoritmo implementado.

Figura 46

Algoritmo para encontrar las correlaciones de la plaga Bemisia Tabaci – G° Infestación y Adultos/Inflorescencia

```
arrPlagas = []
dfFilter = dfFilEleg
arrFiltrados = dfFilEleg['Filtrado'].unique()
#dfFilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dfFiltrado = dfFilter[dfFilter['Filtrado'] == filtrado]
    arrTurno = dfFiltrado['Turno'].unique()
    for turno in arrTurno:
        dfTurno = dfFiltrado[dfFiltrado['Turno'] == turno]
        arrLote = dfTurno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfTurno[dfTurno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Carac

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)

                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']]

                    df_union[["Grado"]] = df_union[["Grado"]].apply(pd.to_numeric)

                    dfCorrelacion = df_union.corr().abs()

                    dfCorrelacion_index = dfCorrelacion[dfCorrelacion['Grado'] > 0.60]
```

d) Trips Tabaci – G° Ninfas y adultos/ inflorescencia

Una vez encontrado nuestras correlaciones que están representadas por los mapas de calor, escogeremos aquellos Filtrados – Turno – Lote que tengan una correlación > 0.60 a través de un algoritmo implementado.

Figura 47

**Algoritmo para encontrar las correlaciones de la plaga
Trips Tabaci – G° Ninfas y adultos/ inflorescencia**

```
arrPlagas = []
dfFilter = dfFilEleg
arrFiltrados = dfFilEleg['Filtrado'].unique()
#dfFilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dfFiltrado = dfFilter[dfFilter['Filtrado'] == filtrado]
    arrTurno = dfFiltrado['Turno'].unique()
    for turno in arrTurno:
        dfTurno = dfFiltrado[dfFiltrado['Turno'] == turno]
        arrLote = dfTurno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfTurno[dfTurno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Carac

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)

                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Grado']]

                    df_union[["Grado"]] = df_union[["Grado"]].apply(pd.to_numeric)

                    dfCorrelacion = df_union.corr().abs()

                    dfCorrelacion_index = dfCorrelacion[dfCorrelacion['Grado'] > 0.60]
```

e) *Dagbertus minensis*, *Dagbertus peruanus*

Una vez encontrado nuestras correlaciones que están representadas por los mapas de calor, escogeremos aquellos Filtrados – Turno – Lote que tengan una correlación > 0.80 a través de un algoritmo implementado.

Figura 48

Algoritmo para encontrar las correlaciones DAGBERTUS MINENSIS, DAGBERTUS PERUANUS

```
arrPlagas = []
dfFilter = dfFileEleg
arrFiltrados = dfFileEleg['Filtrado'].unique()
#dfFilter = df
dfCorrexLote = pd.DataFrame(columns=['Filtrado', 'Turno', 'Lote', 'Plaga', 'Caracteristica'])
iContador = 0
for filtrado in arrFiltrados:
    dfFiltrado = dfFilter[dfFilter['Filtrado'] == filtrado]
    arrTurno = dfFiltrado['Turno'].unique()
    for turno in arrTurno:
        dfTurno = dfFiltrado[dfFiltrado['Turno'] == turno]
        arrLote = dfTurno['Lote'].unique()
        for lote in arrLote:
            dfLote = dfTurno[dfTurno['Lote'] == lote]
            arrPlagaxLote = dfLote['Plaga'].unique()
            for plaga in arrPlagaxLote:
                dfPlaga = dfLote[dfLote['Plaga'] == plaga]
                arrPlagaxCarac = dfPlaga['Caracteristica'].unique()
                for caracteristica in arrPlagaxCarac:
                    dfCarac = dfPlaga[dfPlaga['Caracteristica'] == caracteristica]
                    dfCarac = dfCarac.sort_values(by=['Fecha'])

                    dfCarac = dfCarac.groupby(['Fecha', 'Fundo', 'Filtrado', 'Turno', 'Plaga', 'Caracteristica'])['Porcentaje'].sum()

                    fl_df_weather = df_weather[df_weather['Fecha'].isin(dfCarac['Fecha'])]
                    fl_df_weather = fl_df_weather.sort_values(by=['Fecha'])
                    fl_df_weather.reset_index(drop = True, inplace = True)
                    fl_df_weather = fl_df_weather.rename(columns = {'Fecha' : 'FechaClima'})
                    df_union = fl_df_weather.join(dfCarac)

                    # Filtrar el dataset por las variables que se usarán
                    #df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'T_MIN', 'T_MAX', 'RS_PROM', 'HM_PROM', 'Grado']]
                    df_union = df_union[['Fecha', 'ET', 'TMP_PROM', 'RS_PROM', 'HM_PROM', 'Porcentaje']]
```

4.2. Análisis e interpretación de resultados

Los resultados se presentan considerando los objetivos específicos:

Objetivo 1. Elaborar un diagnóstico situacional del tipo de plaga en el cultivo de palto por lote según año 2019-2020.

En el fundo Virú, según el uso de Cartillas Fitosanitarias, las evaluaciones para detectar la presencia de plagas se realizaron a nivel de lotes y se evaluaron 25 veces en diferentes puntos. La caracterización de la presencia de plagas se determinó en relación al número de hojas infectadas y el grado de infestación (Ninfas- adultas), tal como se resume en la Tabla 3.

Tabla 3
Tipos de plagas detectadas en el fundo de la Agroindustrial Viru, 2019-2020

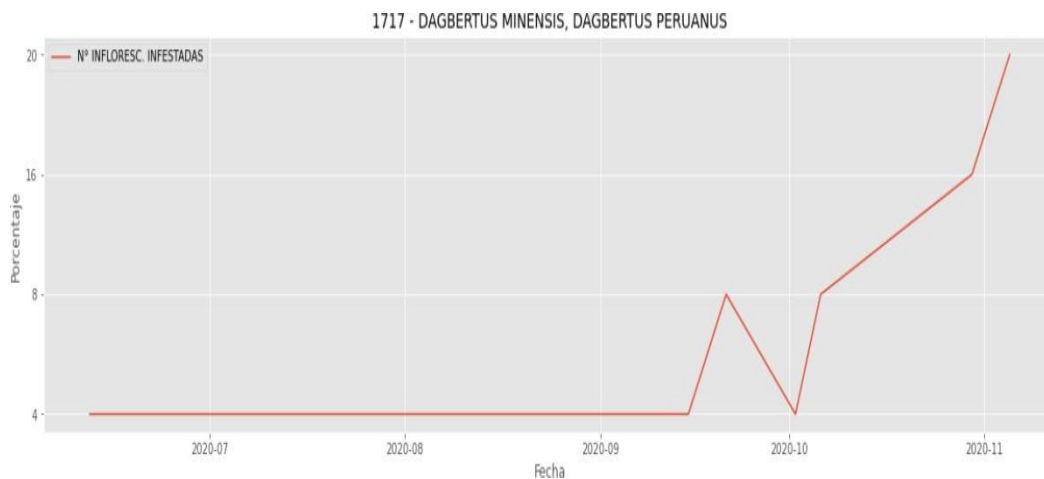
Plaga	Característica observada	Unidad de medida
OLYGNICHUS PUNICAE, OLIGONYCHUS YOTHERSI	N° hojas infestadas G° infestación (ninfas-adultas) G° infestación (huevos)	Porcentaje Grado Grado
ALEURODICUS COCOIS, ALEURODICUS JULEIKAE	N° hojas infestadas G° infestación (ninfas-adultas) G° de fumagina	Porcentaje Grado Grado
BEMISIA TABACI	N° hojas infestadas G° infestación (ninfas-adultas)	Porcentaje Grado
DAGBERTUS MINENSIS, DAGBERTUS PERUANUS	N° infloresc. infestadas N° ninfas/infloresc N° adultos/infloresc	Porcentaje Porcentaje Porcentaje
TRIPS TABACI	N° infloresc. infestadas G° ninfas y adultos/ inflor	Porcentaje Grado

Fuente: Bases de datos de Cartillas fitosanitarias

De la evaluación en 319 lotes del fundo Virú para detectar qué plagas son las que aparecen en cada lote, se encontró que fueron 4 las plagas con mayor incidencia en este periodo, para describir el comportamiento de cada una de estas plagas se construyó gráficos, los cuales se presentan a continuación:

Figura 49


Evolución de la plaga *Dagbertus Minensis*, *Dagbertus Peruanus*, según N° inflorescencias infestadas, año 2020



En la Figura 49, se observa que la plaga *Dagbertus Minensis*, *Dagbertus Peruanus* – N.º inflorescencias infestadas presentó un ciclo epidémico con tendencia ascendente durante los meses de setiembre, octubre y noviembre.


Figura 50

Evolución de la plaga *Olygonchus Punicae*, *Oligonychus Yothersi* según G° Infestación-huevos, año 2020



La plaga *Olygoncihus Punicae*, *Oligonychus Yothersi*, presenta un comportamiento ascendente pero periódico con ciertos picos tal como se muestra en la Figura 50. Así mismo, se observó que el comportamiento de la plaga *Trips Tabaci* difiere completamente de las otras dos mencionadas, presenta un descenso para luego lograr la estabilidad baja durante largo periodo de tiempo, Figura 51.


Figura 51
Evolución de la plaga *Trips Tabaci*, según G° de inflorescencia, ninfas-adultos, año 2020



Por último, tenemos a la plaga *Bemisia Tabaci* – G° Infestación (Ninfas-adultos) que presenta altibajos constantes en los meses de enero, febrero y marzo luego presentan un aumento considerable desde marzo hasta abril para caer y mantenerse hasta setiembre, donde volverá a presentar una subida y luego descender en noviembre tal y como lo muestra la figura 52.

Figura 52

Evolución de la plaga Bemisia Tabaci – G° Infestación (Ninfas-Adultos)



Objetivo 2. Elaborar un diagnóstico del comportamiento de las variables climatológicas en 2019-2020.

De la revisión y análisis de la base de datos sobre variables climatológicas que la empresa Agroindustrial Virú almacena a través de estaciones meteorológicas, se encontró que:

La evapotranspiración durante los años 2019-2020 en el cultivo de palto en Virú es mayor en los meses de enero a abril, llegando a su punto máximo en marzo. Durante los meses de mayo a diciembre se mantiene bajo teniendo su punto mínimo en agosto, el comportamiento de esta variable se presenta en la Figura 53-54 y Tablas 3 y 4.

Figura 53

Comportamiento de la evapotranspiración en el año 2019




Tabla 4

Evapotranspiración máxima y mínima en el año 2019

Evapotranspiración máxima	
Fecha	Valor(mm)
26/02/2019	5
Evapotranspiración mínima	
Fecha	Valor(mm)
21/06/2019	0.4
18/07/2019	
29/07/2019	

Figura 54

Comportamiento de la evapotranspiración en el año 2020



Tabla 5

Evapotranspiración máxima y mínima en el 2020

Evapotranspiración máxima	
Fecha	Valor(mm)
3/03/2020	4.8
10/03/2020	
Evapotranspiración mínima	
Fecha	Valor(mm)
14/02/2020	0.1

Figura 55

Evolución de la temperatura promedio para el año 2019



Figura 56

Evolución de la temperatura promedio para el año 2020



La temperatura promedio durante los años 2019-2020 en el cultivo de palto en Virú es mayor en los meses de enero a abril, llegando a su punto máximo en febrero y marzo. Durante los meses de mayo a diciembre se mantiene bajo teniendo su punto mínimo en agosto, tal como se presenta en la Figura 55 y 56.

Según la Tabla 6, la temperatura mínima en el cultivo de palto en Virú fue de 12.9°C y 13.2°C mes octubre años 2019 y 2020 respectivamente. Mientras que la temperatura máxima fue de 31.9 y 32.2 °C para 2019 y 2020 y correspondiente a los meses de febrero y noviembre respectivamente, Tabla 6.

Tabla 6

Temperatura mínima en 2019-2020

Temperatura mínima	
Fecha	Valor(C°)
27/10/2019	12.9

Temperatura mínima	
Fecha	Valor(C°)
7/10/2020	13.2

Tabla 7

Temperatura máxima en 2019 -2020

Temperatura máxima	
Fecha	Valor(C°)
8/02/2019	31.9

Temperatura máxima	
Fecha	Valor(C°)
3/11/2020	31.2

La evolución de la radiación solar promedio durante los años 2019-2020 en el cultivo de palto en Virú, se aprecia en la Figura 57 y 58; es mayor en los meses de enero a abril, llegando a su punto máximo en febrero y marzo. Durante los meses de mayo a diciembre se mantiene bajo teniendo su punto mínimo en agosto, según Tabla 7 y 8.

Figura 57

Comportamiento de la radiación solar promedio para el año 2019




Tabla 8

Radiación solar máxima y mínima 2019

Radiación solar máxima	
Fecha	Valor(W/m2)
26/02/2019	278

Radiación solar mínima	
Fecha	Valor(W/m2)
29/07/2019	28

Figura 58

Comportamiento de la radiación solar promedio para el año 2020

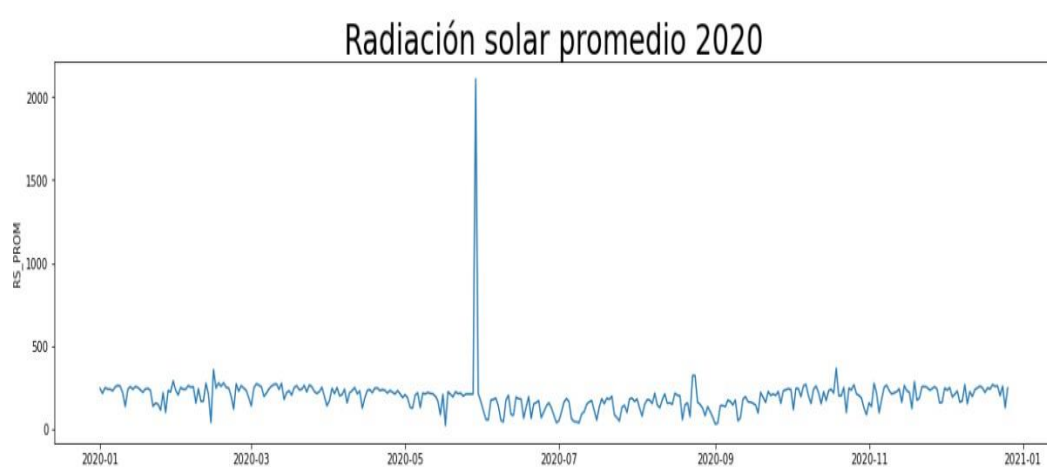


Tabla 9

Radiación solar máxima y mínima en el año 2020

Radiación solar máxima	
Fecha	Valor(W/m2)
29/05/2020	283

Radiación solar mínima	
Fecha	Valor(W/m2)
5/07/2020	19.8

La humedad promedio durante los años 20219-2020 en el cultivo de palto en Virú es mayor en los meses de junio a diciembre, teniendo picos altos de junio a setiembre. Durante los meses de enero a mayo se mantiene bajo teniendo picos mínimos en enero y febrero, tal como se observa en Figuras

59 y 60. Valores máximos y mínimos que alcanza esta variable se muestran en las Tabla 9 y 10.

Figura 59

Evolución de la humedad promedio para el año 2019




Tabla 10

Humedad máxima y mínima en el 2019

Humedad máxima	
Fecha	Valor (%)
26/06/2019	92
2/07/2019	92
10/07/2019	92
13/07/2019	92
5/09/2019	92
19/09/2019	92
Humedad mínima	
Fecha	Valor (%)
13/01/2019	76
5/02/2019	76
10/02/2019	76

Figura 60

Evolución de la humedad promedio para el año 2020




Tabla 11**Humedad promedio máxima y mínima 2020**

Humedad promedio máxima	
Fecha	Valor (%)
29/01/2020	91
26/07/2020	91
27/07/2020	91
2/09/2020	91
12/09/2020	92

Humedad promedio mínima	
Fecha	Valor (%)
24/02/2020	73

Con estos resultados, se llega a la conclusión que la evapotranspiración, temperatura promedio, temperatura máxima, temperatura mínima, humedad y radiación solar tienen el mismo comportamiento, el indicador de estas variables aumenta en los meses de verano, desde enero extendiéndose hasta abril y durante los meses de otoño-invierno-primavera se mantiene a un nivel menor. Mientras que la humedad promedio es lo contrario, durante los meses de verano existe menos humedad y en las siguientes estaciones, la humedad aumenta.

Objetivo 3. Realizar un análisis relacional entre los tipos de plagas en el cultivo de palto y las variables climatológicas para el año 2019-2020.

Se trabajó con cuatro tipos de plagas, considerando la existencia de datos suficientes para establecer relaciones entre las variables.


1°) Relación entre la plaga *Oligonychus punicae*, *Oligonychus yothersi* – G° Infestación (Ninfas - Adultas) y las variables climatológicas.

Se analizó la asociación entre el grado de infestación ninfas-adultos de la plaga y las variables climatológicas: temperatura promedio, evapotranspiración, humedad promedio y radiación solar. Se calculó los coeficientes de correlación de Pearson correspondientes y se

utilizó mapas de calor para identificar con facilidad las correlaciones más significativas, cuyos resultados se presentan en la Figura 61.

Figura 61

Datos filtrados y mapa de calor representando las correlaciones



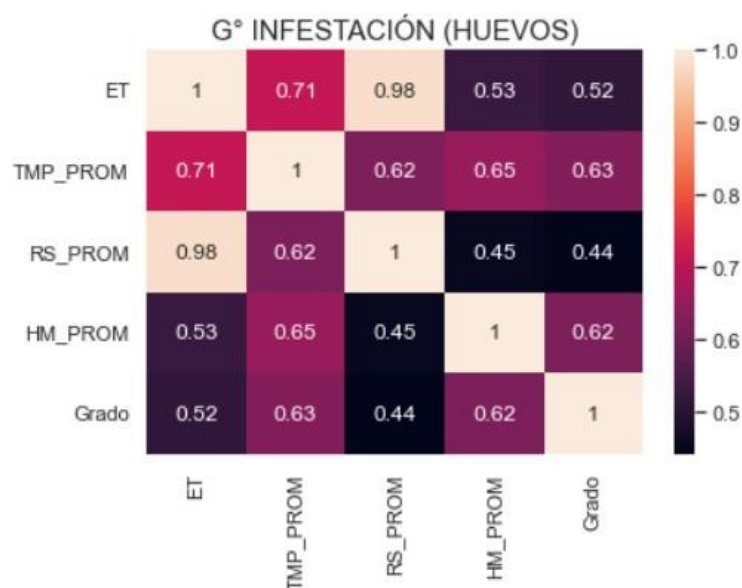
Encontramos que el Filtrado 20 Turno F20 Lote 2016 presentó correlación alta ($r=0.92$) con la Temperatura Promedio, se utilizó esto para realizar evaluación del modelo de predicción.

2°) Relación entre la plaga *Oligonychus punicae*, *Oligonychus yothersi* – G° Infestación (Huevos) y las variables climatológicas.

Se analizó la asociación entre el grado de infestación huevos de la plaga y las variables climatológicas: temperatura promedio, evapotranspiración, humedad promedio y radiación solar. Se calculó los coeficientes de correlación de Pearson correspondientes y se utilizó mapas de calor para identificar con facilidad las correlaciones más significativas, cuyos resultados se presentan en la Figura 62.

Figura 62

Datos filtrados y mapa de calor representando las correlaciones




Encontramos que el Filtrado 20 Turno F20 Lote 2019 presentó correlación significativa ($r=0.63$) con la Temperatura Promedio y también correlación significativa ($r=0.62$) con la Humedad Promedio, se utilizó esto para realizar evaluación del modelo de predicción.

3°) Relación entre la plaga Bemisia Tabaci– G° Infestación (Ninfas-Adultas) y las variables climatológicas.

Se analizó la asociación entre el grado de infestación ninfas-adultos de la plaga y las variables climatológicas: temperatura promedio, evapotranspiración, humedad promedio y radiación solar. Se calculó los coeficientes de correlación de Pearson correspondientes y se utilizó mapas de calor para identificar con facilidad las correlaciones más significativas, cuyos resultados se presentan en la Figura 63.

Figura 63

Datos filtrados y mapa de calor representando las correlaciones




Encontramos que el Filtrado 10N Turno F10N Lote 1017 presentó correlación significativa ($r=0.62$) con la Humedad Promedio, se utilizó esto para realizar evaluación del primer modelo de predicción para esta plaga.

También encontramos que el Filtrado 17 Turno F17 Lote 1719 presentó correlación significativa ($r=0.63$) con la Temperatura Promedio tal como está representada en la figura 64, se utilizó esto para realizar evaluación del segundo modelo de predicción para esta plaga.

Figura 64

Datos filtrados y mapa de calor representando las correlaciones




4°) Relación entre la plaga Trips Tabaci – G° ninfas y adultos/ inflorescencia y las variables climatológicas.

Se analizó la asociación entre el grado de infestación ninfas y adultos/inflorescencia de la plaga y las variables climatológicas: temperatura promedio, evapotranspiración, humedad promedio y radiación solar. Se calculó los coeficientes de correlación de Pearson correspondientes y se utilizó mapas de calor para identificar con facilidad las correlaciones más significativas, cuyos resultados se presentan en la Figura 65.

Figura 65

Datos filtrados y mapa de calor representando las correlaciones



Encontramos que el Filtrado 17 Turno F17 Lote 1718 presentó correlación alta ($r=0.64$) con la Temperatura promedio, se utilizó esto para realizar evaluación del modelo de predicción correspondiente a esta plaga.

Objetivo 4: Entrenar y validar el modelo de predicción de plagas en el cultivo de palto a partir del comportamiento de las variables climatológicas, mediante metodología de aprendizaje automático supervisado.

a) Modelo de predicción para la plaga *Oligonychus punicae*, *Oligonychus yothersi* – G° Infestación (Ninfas-Adultos)

Para esta plaga se escogió al Filtrado 20 Turno 20 Lote 2016 por tener los mejores resultados y las mejores correlaciones entre las variables de análisis; en comparación a los demás filtrados.

Figura 66

Resultados del análisis de Regresión lineal para la plaga Oligonychus Punicae, Oligonychus Yothersi– G° Infestación (Ninfas-Adultos)

```
.....
Lugar: Filtrado 20 - Turno F20 - Lote 2016
Plaga: OLYGONICHUS PUNICAE, OLIGONYCHUS YOTHERSI
Característica: G° INFESTACIÓN (NINFAS-ADULTOS)
Número de datos: 10
Variables X: ['TMP_PROM']

=====
                        OLS Regression Results
=====
Dep. Variable:          y      R-squared:                0.878
Model:                  OLS    Adj. R-squared:           0.858
Method:                 Least Squares   F-statistic:              43.34
Date:                   Sun, 07 Nov 2021   Prob (F-statistic):      0.000590
Time:                   16:19:08         Log-Likelihood:          -0.94251
No. Observations:      8              AIC:                     5.885
Df Residuals:          6              BIC:                     6.044
Df Model:               1
Covariance Type:       nonrobust

=====
                        coef      std err          t      P>|t|      [0.025      0.975]
-----
const                -11.8351      2.086        -5.675      0.001     -16.938     -6.732
TMP_PROM              0.6757      0.103         6.583      0.001       0.425     0.927
=====

Omnibus:                0.985    Durbin-Watson:           0.974
Prob(Omnibus):          0.611    Jarque-Bera (JB):        0.462
Skew:                   -0.535    Prob(JB):                 0.794
Kurtosis:                2.510    Cond. No.                 382.
=====

Notes:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

Coeficientes
const          -11.835118
TMP_PROM       0.675739
dtype: float64
```

Siendo el valor de la significancia estadística para la prueba F $p=0.00059 < 0.05$, se concluye que el modelo es significativo, válido. La temperatura promedio influye significativamente en el grado de infestación Ninfa- adulto de la plaga Oligonychus Punicae, Oligonychus Yothersi. Considerando el valor del coeficiente de determinación lineal para el modelo $R^2= 0.878$, el 87.8% de la variación del grado de infestación Ninfa-adulto de la plaga es explicado por la temperatura promedio. Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera es $P(JB)=0.794$, indica cumplimiento del supuesto normalidad de los residuos, por lo que, los estimadores

mínimo-cuadráticos con los que se construye el modelo son eficientes (de varianza mínima).

El modelo de predicción de plaga corresponde a un modelo lineal, cuya ecuación de regresión estimada es:

$$\hat{Y} = -11.8351 + 0.6757TMP_PM$$

Esta ecuación de estimación informa de la existencia de relación lineal positiva entre las variables, explica que por cada grado más de temperatura promedio el grado de infestación ninfas-adultos de la plaga se incrementa en 0.6757.

b) Modelo de predicción para la plaga *Oligonychus Punicae*, *Oligonychus Yothersi* – G° Infestación (Huevos)

Para esta plaga se escogió al Filtrado 20 Turno F20 Lote 2019 por tener los mejores resultados y las mejores correlaciones entre las variables de análisis; en comparación a los demás filtrados.

Figura 67

Resultados del análisis de regresión lineal para la plaga *Oligonychus Punicae*, *Oligonychus Yothersi*– G° Infestación (Huevos)

```

*****
Lugar: Filtrado 20 - Turno F20 - Lote 2019
Plaga: OLYGONICHUS PUNICAE, OLIGONYCHUS YOTHERSI
Característica: G° INFESTACIÓN (HUEVOS)
Número de datos: 42
Variables X: ['TMP_PROM', 'HM_PROM']

```

```

=====
                        OLS Regression Results
=====
Dep. Variable:          y          R-squared:                0.514
Model:                  OLS        Adj. R-squared:           0.482
Method:                 Least Squares  F-statistic:              15.89
Date:                   Mon, 22 Nov 2021  Prob (F-statistic):       1.96e-05
Time:                   14:47:50      Log-Likelihood:          -28.750
No. Observations:      33           AIC:                     63.50
Df Residuals:          30           BIC:                     67.99
Df Model:               2
Covariance Type:       nonrobust
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	6.2955	3.649	1.725	0.095	-1.157	13.748
TMP_PROM	0.1236	0.047	2.614	0.014	0.027	0.220
HM_PROM	-0.0783	0.036	-2.182	0.037	-0.151	-0.005

```

=====
Omnibus:                0.705      Durbin-Watson:           1.581
Prob(Omnibus):          0.703      Jarque-Bera (JB):        0.734
Skew:                   0.309      Prob(JB):                 0.693
Kurtosis:               2.609      Cond. No.                 2.97e+03
=====

```

```

Notes:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
[2] The condition number is large, 2.97e+03. This might indicate that there are
strong multicollinearity or other numerical problems.

```

```

Coeficientes
const          6.295487
TMP_PROM       0.123559
HM_PROM       -0.078251
dtype: float64

```

Siendo el valor de la significancia estadística para la prueba F $p=0.0000196 < 0.05$, se concluye que el modelo es significativo, válido. La temperatura promedio y la humedad promedio influyen significativamente en el grado de infestación-huevos de la plaga *Oligonychus Punicae*, *Oligonychus Yothersi*. Considerando el valor $R^2_{ajustado}=0.482$, este coeficiente de determinación múltiple informa que, el 48.2% de la variación del grado de infestación-huevos de la plaga es explicado por la temperatura y la humedad promedio.

Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera es $P(JB)=0.693$, indica cumplimiento del supuesto normalidad de los residuos, por lo que, los estimadores mínimo-cuadráticos con los que se construye el modelo son eficientes (de varianza mínima). Así mismo, con el estadístico Durbin-Watson=1.581, se comprueba que los residuos son independientes y en la Figura 68, los gráficos de residuos muestran que éstos tienen patrón simétrico, con comportamiento normalidad y una dispersión constante en todo el rango.

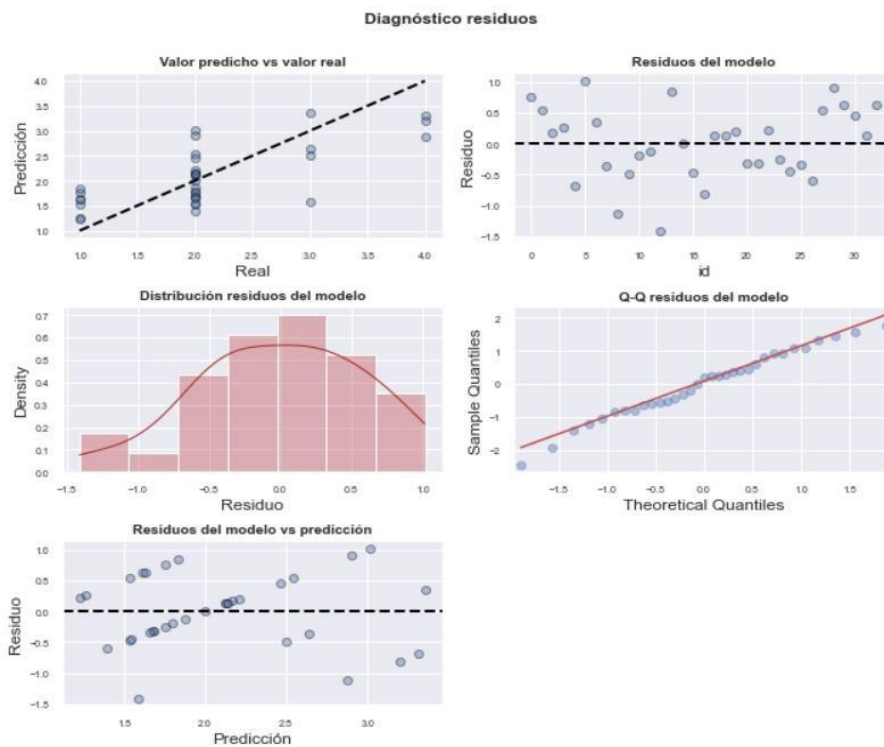
El modelo de predicción de plaga corresponde a un modelo lineal múltiple, cuya ecuación de regresión estimada es:

$$\hat{Y} = 6.295487 + 0.123559\text{TMP_PM} - 0.078251\text{HM_PROM}$$

Esta ecuación de estimación informa de la existencia de relación lineal entre las variables, explica que por cada grado más de temperatura promedio se espera que el grado de infestación huevos de la plaga se incrementa en 0.123559, con humedad constante.

Figura 68

Gráficos de residuos correspondiente al modelo de regresión de la plaga *Olygonichus punicae*, *olygonichus yothersi* (huevos)



c) Modelo de predicción para la plaga *Bemisia Tabaci*–G° Infestación (Ninfas adultos)

Para esta plaga se escogió 2 lotes que se encuentran en los mismos filtrados los cuales son: Filtrado 10N Turno 10N Lote 1017 y el Filtrado 10N Turno 10N Lote 1719 por tener los mejores resultados

y las mejores correlaciones entre las variables de análisis; en comparación a los demás filtrados.

Figura 69

Resultados del análisis de Regresión lineal para la plaga Bemisia Tabaci – G° Infestación (Ninfas adultos) para el Filtrado 10N Turno 10N Lote 1017

```
*****
Lugar: Filtrado 10N - Turno F10N - Lote 1017
Plaga: BEMISIA TABACI
Característica: G° INFESTACIÓN (NINFAS-ADULTOS)
Número de datos: 27
Variables X: ['HM_PROM']

=====
                        OLS Regression Results
=====
Dep. Variable:          y          R-squared:                0.380
Model:                 OLS        Adj. R-squared:           0.348
Method:                Least Squares  F-statistic:             11.66
Date:                  Mon, 22 Nov 2021  Prob (F-statistic):      0.00291
Time:                  14:47:34      Log-Likelihood:         0.96644
No. Observations:     21          AIC:                    2.067
Df Residuals:         19          BIC:                    4.156
Df Model:              1
Covariance Type:      nonrobust
=====
                        coef      std err          t      P>|t|      [0.025      0.975]
-----+-----
const                  6.2357      1.506         4.139      0.001       3.083       9.389
HM_PROM                -0.0607      0.018        -3.414      0.003      -0.098      -0.023
=====
Omnibus:                21.025      Durbin-Watson:           2.545
Prob(Omnibus):          0.000      Jarque-Bera (JB):        29.283
Skew:                   1.811      Prob(JB):                4.38e-07
Kurtosis:               7.511      Cond. No.:               2.41e+03
=====

Notes:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
[2] The condition number is large, 2.41e+03. This might indicate that there are strong multicollinearity or other numerical problems.

Coeficientes
const      6.235714
HM_PROM   -0.060714
dtype: float64
```

Siendo el valor de la significancia estadística para la prueba F $p=0.00291 < 0.05$, se concluye que el modelo es significativo, válido. La humedad promedio influye significativamente en el grado de infestación ninfas-adultos de la plaga Bemisia Tabaci. Considerando el valor del coeficiente de determinación lineal para el modelo $R^2 = 0.38$, el 38% de la variación del grado de infestación de la plaga es explicado por la humedad promedio.

Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera es $P(JB)=0.000$, indica no cumplimiento del supuesto normalidad de los residuos, por lo que, los estimadores mínimo-

cuadráticos con los que se construye el modelo no son eficientes (ni de varianza mínima).

El modelo de predicción de plaga corresponde a un modelo lineal, cuya ecuación de regresión estimada es:

$$\hat{Y} = 6.235714 - 0.060714HM_PROM$$

Esta ecuación de estimación informa de la existencia de relación lineal entre las variables, explica que por cada grado más de humedad promedio el grado de infestación ninfas-adultos de la plaga disminuye en 0.060714.

Figura 70

Resultados del análisis de Regresión lineal para la plaga Bemisia Tabaci – G° Infestación (Ninfas adultos) para el Filtrado 10N Turno 10N Lote 1019

```

*****
*****
Lugar: Filtrado 17 - Turno F17 - Lote 1719
Plaga: BEMISIA TABACI
Característica: G° INFESTACIÓN (NINFAS-ADULTOS)
Número de datos: 40
Variables X: ['TMP_PROM']

                                OLS Regression Results
=====
Dep. Variable:                    y      R-squared:                        0.566
Model:                            OLS      Adj. R-squared:                   0.551
Method:                            Least Squares      F-statistic:                      39.07
Date:                            Mon, 22 Nov 2021      Prob (F-statistic):               6.93e-07
Time:                            14:47:37      Log-Likelihood:                   -12.151
No. Observations:                 32      AIC:                              28.30
Df Residuals:                     30      BIC:                              31.23
Df Model:                          1
Covariance Type:                  nonrobust
=====
                                coef      std err          t      P>|t|      [0.025      0.975]
-----
const                          -1.3037      0.428        -3.043      0.005      -2.179      -0.429
TMP_PROM                         0.1382      0.022         6.251      0.000       0.093      0.183
=====
Omnibus:                          9.557      Durbin-Watson:                   1.908
Prob(Omnibus):                    0.008      Jarque-Bera (JB):                19.891
Skew:                             0.215      Prob(JB):                        4.79e-05
Kurtosis:                         6.838      Cond. No.                        129.
=====

Notes:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

Coeficientes
const          -1.30368
TMP_PROM       0.13820
dtype: float64

Intervalos de confianza:
                2.5%      97.5%
const          -2.178661 -0.428699
TMP_PROM       0.093047  0.183354

```

Siendo el valor de la significancia estadística para la prueba F $p=0.000<0.05$, se concluye que el modelo es significativo, válido. La temperatura promedio influye significativamente en el grado de infestación ninfas-adultos de la plaga Bemisia Tabaci. Considerando el valor del coeficiente de determinación lineal para el modelo $R^2 = 0.566$, el 56.6% de la variación del grado de infestación ninfas-adultos de la plaga es explicado por la temperatura promedio.

Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera es $P(JB)=0.000$, indica no cumplimiento del supuesto normalidad de los residuos, por lo que, los estimadores mínimo-cuadráticos con los que se construye el modelo no son eficientes (ni de varianza mínima).

El modelo de predicción de plaga corresponde a un modelo lineal, cuya ecuación de regresión estimada es:

$$\hat{Y} = 6.235714 - 0.060714TM_PROM$$

Esta ecuación de estimación informa de la existencia de relación lineal positiva entre las variables, explica que por cada grado más de temperatura promedio el grado de infestación ninfas-adultos de la plaga disminuye en 0.060714.

d) Modelo de predicción para la plaga Trips Tabasi - G° ninfas y adultos/ inflorescencia

Para esta plaga se escogió al Filtrado 17 Turno F17 Lote 1718 por tener los mejores resultados y las mejores correlaciones entre las variables de análisis; en comparación a los demás filtrados.

Figura 71

Resultados del análisis de Regresión lineal para la plaga Trips Tabasi – G° ninfas y adultos/inflorescencia para el Filtrado 17 Turno F17 Lote 1718

Lugar: Filtrado 17 - Turno F17 - Lote 1718
Plaga: TRIPS TABACI
Característica: G° NINFAS Y ADULTOS/ INFLORESC.
Número de datos: 26
Variables X: ['TMP_PROM']

```
=====
                        OLS Regression Results
=====
Dep. Variable:          y      R-squared:                0.332
Model:                  OLS    Adj. R-squared:           0.295
Method:                 Least Squares  F-statistic:             8.952
Date:                   Mon, 22 Nov 2021  Prob (F-statistic):      0.00782
Time:                   14:47:39  Log-Likelihood:          -26.573
No. Observations:      20      AIC:                     57.15
Df Residuals:          18      BIC:                     59.14
Df Model:              1
Covariance Type:       nonrobust
=====
                        coef      std err          t      P>|t|      [0.025      0.975]
-----
const                7.1383      1.565          4.561      0.000      3.850      10.426
TMP_PROM             -0.2543      0.085         -2.992      0.008     -0.433     -0.076
=====
Omnibus:              1.323      Durbin-Watson:          2.520
Prob(Omnibus):        0.516      Jarque-Bera (JB):       0.854
Skew:                 0.016      Prob(JB):               0.653
Kurtosis:             1.988      Cond. No.               134.
=====
```

Notes:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

```
Coeficientes
const      7.138293
TMP_PROM  -0.254299
dtype: float64
```

```
Intervalos de confianza:
                2.5%      97.5%
const      3.850115  10.426470
TMP_PROM  -0.432862  -0.075736
```

Siendo el valor de la significancia estadística para la prueba F $p=0.00782 < 0.05$, se concluye que el modelo es estadísticamente significativo y válido. La temperatura promedio influye significativamente en el número de inflorescencia infestada de la plaga Trips Tabaci. Considerando el valor del coeficiente de determinación lineal para el modelo $R^2 = 0.332$, el 33.2% de la variación del número de inflorescencia infestada de la plaga es explicado por la temperatura promedio.

Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera es $P(JB)=0.653$, indica cumplimiento del supuesto normalidad de los residuos, por lo que, los estimadores mínimo-cuadráticos con los que se construye el modelo son eficientes (de varianza mínima).

El modelo de predicción de plaga corresponde a un modelo lineal, cuya ecuación de regresión estimada es:

$$\hat{Y} = 7.138293 - 0.254299TMP_PM$$

Esta ecuación de estimación informa de la existencia de relación lineal entre las variables, explica que por cada grado más de temperatura promedio el número de ninfas y adultos/ inflorescencia disminuye en 0.254299. El modelo de predicción estimado estadísticamente es válido.

V. DISCUSIÓN DE LOS RESULTADOS

Este capítulo presenta la discusión de los resultados confrontando las fuentes primarias o antecedentes, con los resultados obtenidos del trabajo de investigación y la literatura que fundamenta la construcción del modelo de predicción. El engranaje de estos tres abordajes, conlleva a determinar y validar los modelos de predicción de plagas significativos que constituye el producto de esta investigación.

El análisis de los datos de la evaluación fitosanitaria realizado en el fundo de los cultivos de palto, detectó la presencia de las siguientes plagas: *Olygonychus punicae*/*Olygonychus yothersi*, *Aleurodicus cocois*/*Aleurodicus juleikae*, *Bemisia Tabaci*, *Dagbertus minensis*/*Dagbertus peruanus*, *Trips Tabaci*, (Tabla 3). Se identificó que las plagas con mayor incidencia durante el año 2020 son: *Olygonychus punicae*/*Olygonychus yothersi*, *Bemesia Tabaci*, *Dagbertus minensis* y *Trips Tabaci*.

El ciclo epidémico de las plagas se presentó variado, la plaga *Dagbertus Minensis*, *Dagbertus Peruanus* según el número de inflorescencias infestadas presentó un ciclo epidémico con tendencia ascendente durante los meses de setiembre, octubre y noviembre, Figura 49. La presencia de esta plaga concuerda con lo manifestado por Yarita y Cisneros (2010) “*Dagbertus minensis*, que se ha convertido en una plaga muy seria del palto en Chavimochic, La Libertad”. La plaga *Olygoncihus Punicae*, *Olygonychis Yothersi*, presentó también un comportamiento ascendente periódico y con algunos picos, tal como se observa en la Figura 50. Por otra parte, el

comportamiento de la plaga *Trips Tabaci* difiere completamente de las otras dos mencionadas anteriormente; presenta un descenso para luego lograr una estabilidad baja durante largo periodo de tiempo, Figura 51. Además, la plaga *Bemisia Tabaci* según grado de infestación (Ninfas-adultos) presenta altibajos constantes en los meses de enero, febrero y marzo, luego presenta un aumento considerable desde marzo hasta abril para caer y mantenerse constante hasta setiembre, donde vuelve a presentar una subida y luego descender en noviembre, esto se visualiza en la Figura 52. La presencia de estas plagas en el cultivo de palto en Virú, originan daño tal como pérdida de clorofila, raspado de fruto, afección a los botones florales, perjuicio en el cuajado de frutos; autores como: Yarita y Cisneros (2010); Herrera y Narrea (2011), Falconí (2013), Boletín INIA N° 129- Ministerio de agricultura, han estudiado el ciclo epidémico de estas plagas, sus explicaciones respecto al daño que causan estas plagas coinciden con lo observado en la Empresa Virú S. A.

Con respecto a las variables climatológicas asociadas al cultivo de palto en Virú, se observó que:

La evapotranspiración durante los años 2019-2020 fue mayor (5mm y 4.8mm) en los meses de enero a abril, llegando a su punto máximo en marzo. Durante los meses de mayo a diciembre se mantuvo bajo teniendo su punto mínimo (0.4mm y 0.1mm) en febrero y julio respectivamente, el comportamiento de esta variable se visualiza en las Figuras 53 y 54, así como en las Tablas 4 y 5.

La temperatura promedio durante los años 2019-2020 en el cultivo de palto en Virú fue mayor en los meses de enero a abril, llegando a su punto máximo en febrero y marzo. Durante los meses de mayo a diciembre se mantuvo bajo teniendo su punto mínimo en agosto, tal como se presenta en la Figura 54 y 55. Según la Tabla 6, la temperatura mínima en el cultivo de palto en Virú fue de 12.9°C y 13.2°C mes octubre años 2019 y 2020 respectivamente. Mientras que la temperatura máxima fue de 31.9 y 32.2 °C y correspondiente a los meses de febrero y noviembre respectivamente, Tabla 7. La temperatura es una variable climatológica con gran influencia en el cultivo de palto, la importancia de ella ha sido resaltado y considerado por autores como Tenorio (2007) quien afirmó “el palto es muy sensible a las bajas temperaturas en especial el cultivar Hass”, Heamin Lee, Aekyung Moon, Kiyeong Moon, Youngjae Lee (2017), en su tesis resaltaron la relación de la temperatura en la aparición y proliferación de plagas, afirmaron “la infección antracnosis, está estrechamente relacionada con la temperatura y la duración de la humedad” y también Matarín y Morales (2018, p.17) mencionaron: “La temperatura es el factor climático más conocido, y el que más se controla en los cultivos. La temperatura juega un papel fundamental en la regulación de los procesos metabólicos y en la nutrición de la planta”.

La evolución de la radiación solar promedio durante los años 2019-2020 en el cultivo de palto en Virú, se aprecia en la Figura 56 y 57; fue mayor en los meses de enero a abril con 278 y 283 w/m², llegando a su punto máximo en febrero y marzo. Durante los meses de mayo a diciembre se mantuvo

bajo teniendo su punto mínimo en agosto con 28 y 19.8 w/m²; según Tabla 8 y 9. La radiación solar es también un factor a considerado en el cultivo de palto en Virú, tal como lo resaltó Tarazona (2017, p. 14) quien afirmó “un exceso de radiación solar provoca lo que se denomina “golpe de sol” en madera o frutos” y Carrasco-Ríos (2009) afirmaron: “el aumento de la radiación ultravioleta-B debido a la acción antropogénica puede tener un impacto negativo en crecimiento y desarrollo de la planta; ésta provoca una disminución de la fotosíntesis y de la producción de biomasa”.

La humedad promedio, es otra de las variables climatológicas de gran influencia en el cultivo de plato, al respecto, Heamin Lee, Aekyung Moon, Kiyeong Moon, Youngjae Lee (2017), en su tesis relacionó esta variable con la aparición de plagas; así como también Gliessman (2002, p. 73), el autor agrega que, “la humedad relativa es determinante en la proliferación de plagas en este tipo de cultivo”. Durante los años 2019-2020 en el cultivo de palto en Virú fue mayor en los meses de junio a diciembre, con picos altos de junio a setiembre. Durante los meses de enero a mayo se mantuvo bajo y con picos mínimos en enero y febrero, tal como se observa en Figuras 59 y 60. Valores máximos 92 y 91% y mínimos 76 y 77% que alcanzó esta variable se muestran en las Tabla 10 y 11.

El análisis de correlación entre las curvas epidémicas de las plagas y las variables meteorológicas permitió determinar el grado de asociación entre ellas y la selección de los filtrados correspondientes para la construcción de los modelos de predicción. Teniendo en cuenta los valores más altos de

los coeficientes de correlación de Pearson (r) y los mapas de calor se identificaron 4 plagas que presentaron mayor grado de asociación con las variables climatológicas humedad y temperatura promedio, como son:

- La plaga *Oligonychus punicae*, *Oligonychus yothersi* – G° Infestación (Ninfas - Adultas), se encontró que el Filtrado 20 Turno F20 Lote 2016 presentó correlación muy alta ($r=0.92$) con la Temperatura Promedio.
- La plaga *Oligonychus punicae*, *Oligonychus yothersi* – G° Infestación (Huevos), el Filtrado 20 Turno F20 Lote 2019 presentó correlación significativa ($r=0.63$) con la Temperatura Promedio y también correlación significativa ($r=0.62$) con la Humedad Promedio.
- La plaga *Bemisia Tabaci*– G° Infestación (Ninfas- Adultas), el Filtrado 10N Turno F10N Lote 2017 presentó correlación significativa ($r=0.62$) con la Humedad Promedio, y también el Filtrado 17 Turno F17 Lote 1719 presentó correlación significativa ($r=0.63$) con la Temperatura Promedio.
- La plaga *Trips Tabaci* – G° ninfas y adultos/ inflorescencia, aquí el Filtrado 17 Turno F17 Lote 1718 presentó correlación alta ($r=0.64$) con la Temperatura promedio.

Se utilizaron estos filtrados para entrenar y validar los modelos de predicción por presentar las correlaciones más altas, al respecto la web UNIR (2020), afirma: “cuanto más relacionadas estén el conjunto de variables predictoras con la variable a predecir (correlación), más exactas

serán las predicciones”. Los modelos de predicción estimados correspondientes a cada plaga, mediante metodología de aprendizaje automático supervisado, con uso de la técnica de regresión lineal; fueron:

El modelo de predicción para la plaga *Oligonychus punicae*, *Oligonychus yothersi* según grado de infestación, ninfas-adultos, se resume en la Figura 66 y corresponde a un modelo lineal con ecuación de regresión estimada:

$\hat{Y} = -11.8351 + 0.6757T_{MP_PM}$. Este modelo resultó significativo ($p=0.00059<0.05$) e informa de la existencia de una relación lineal positiva, es decir, por cada grado más de temperatura promedio ($^{\circ}C$) el grado de infestación ninfas-adultos de la plaga se incrementa en 0.6757. Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera es $P(JB)=0.794$, indica cumplimiento del supuesto normalidad de los residuos, es decir, los estimadores mínimo-cuadráticos con los que se construye el modelo son eficientes (de varianza mínima). La precisión del modelo se evaluó mediante el coeficiente de determinación lineal ($R^2 = 0.878$), este informa que el 87.8% de la variación del grado de infestación ninfa-adultos de la plaga *Oligonychus punicae*, *Oligonychus yothersi* es explicado por la temperatura promedio. Este modelo presenta mejor precisión que lo obtenido en el trabajo de Barrantes y Vigo (2015), en su tesis “Sistema experto móvil para el diagnóstico y manejo integral de plagas en el arroz” en la que concluyó “el sistema experto móvil ayudará al agricultor a tener un diagnóstico y manejo integral a tiempo con una certeza del 80% en su diagnóstico”.

El modelo de predicción para la plaga *Oligonychus Punicae*, *Oligonychus Yothersi*, según grado de infestación, huevos; se resume en la Figura 67 y corresponde a un modelo lineal múltiple, con ecuación de regresión estimada: $\hat{Y} = 6.295487 + 0.123559 \text{TMP_PM} - 0.078251 \text{HM_PROM}$. Este modelo fue significativo ($p = 0.0000196 < 0.05$) e informa que por cada grado más de temperatura promedio se espera que el grado de infestación huevos de la plaga se incremente en 0.123559, con humedad constante. Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera ($P(\text{JB}) = 0.693$), indicó cumplimiento del supuesto normalidad de los residuos. Así mismo, como el estadístico Durbin-Watson = 1.581, es un valor que se ubica dentro del intervalo [1;3], los residuos son independientes; corroboran esto las pruebas gráficas de los residuos que se presentan en la Figura 68, en donde se observa que los residuos tienen patrón simétrico, con comportamiento normal y una dispersión constante en todo el rango. La precisión del modelo se evaluó mediante el coeficiente de determinación múltiple ajustado ($R^2_{\text{ajustado}} = 0.482$), el cual explica que, el 48.2% de la variación del grado de infestación-huevos de la plaga *Oligonychus punicae*, *Oligonychus yothersi* es debido a la influencia de la temperatura y la humedad promedio. Este modelo confirma la influencia de la temperatura y humedad en la aparición de plagas, similar a lo afirmado por Heamin Lee, Aekyung Moon, Kiyeong Moon, Youngjae Lee (2017) en su tesis, “la infección antracnosis, está estrechamente relacionada con la temperatura y la duración de la humedad”

El modelo de predicción para la plaga Bemisia Tabaci según grado de Infestación, ninfas-adultos y humedad promedio, se resume en la Figura 69 y es un modelo lineal, con ecuación de regresión estimada: $\hat{Y} = 6.235714 - 0.060714HM_PROM$. El modelo fue significativo ($p=0.00291 < 0.05$) y explica que por cada unidad más de humedad promedio el grado de infestación ninfas-adultos de la plaga disminuye en 0.060714. Sin embargo, este modelo no cumple con la normalidad de los residuos, el estadístico Jarque-Bera $P(JB)=0.000 < 0.05$, se traduce a que los estimadores mínimo-cuadráticos con los que se construye el modelo no son eficientes. Así mismo, la precisión del modelo es bajo $R^2 = 0.38$, es decir, sólo el 38% de la variación del grado de infestación de la plaga es explicado por la humedad promedio.

El modelo de predicción para la plaga Bemisia Tabaci según grado de Infestación, ninfas-adultos y temperatura promedio, se resume en la Figura 70 y corresponde a un modelo lineal, con ecuación de regresión estimada: $\hat{Y} = 6.235714 - 0.060714TM_PROM$. El modelo fue significativo ($p=0.000 < 0.05$) y explica que por cada grado más de temperatura promedio el grado de infestación ninfa-adultos de la plaga disminuye en 0.060714. Este modelo tampoco cumple con el supuesto de normalidad de los residuos, pues $P(JB)=0.000 < 0.05$, los estimadores mínimo-cuadráticos con los que se construye el modelo no son eficientes. La precisión del modelo alcanzó $R^2 = 0.566$, explica que el 56.6% de la variación del grado de infestación de la plaga Bemisia Tabaci es explicado por la temperatura promedio.

El modelo de predicción para la plaga Trips Tabasi, según grado de infestación ninfas-adultos/ inflorescencia, se resume en la Figura 71 y corresponde a un modelo lineal, con ecuación de regresión estimada: $\hat{Y} = 7.138293 - 0.254299 \text{TMP_PM}$. El modelo fue significativo ($p = 0.00782 < 0.05$) e informa que por cada grado más de temperatura promedio el número de ninfas y adultos/ inflorescencia disminuye en 0.254299. Con respecto a la normalidad la significancia estadística del estadístico Jarque-Bera es $P(\text{JB}) = 0.653$, indica cumplimiento del supuesto normalidad de los residuos. La precisión del modelo se evaluó mediante el coeficiente de determinación lineal ($R^2 = 0.332$), indicando que el 33.2% de la variación del número de inflorescencia infestada de la plaga Trips Tabasi es explicado por la temperatura promedio.

Se implementó todos los modelos en el sistema de aplicación web Virúnet, para uso por el personal del área Sanidad palto de la empresa Virú S. A.; estos modelos están siendo utilizados desde el mes de octubre del 2021, para el control y gestión de plagas.

VI. CONCLUSIONES

1. Las plagas que incidieron en mayor escala en el cultivo de palto son: Olygonychus punicae/Olygonychus yothersi, Aleurodicus cocois/Aleurodicus juleikae, Bemisia Tabaci, Dagbertus minensis/Dagbertus peruanus, Trips Tabaci.
2. Las variables climatológicas: evapotranspiración, temperatura promedio y radiación solar presentan un ciclo epidémico similar, aumentan en los meses de verano, de enero a abril, mientras que en los meses de otoño-invierno-primavera se mantienen a un nivel menor. Caso contrario sucede para la humedad promedio, en verano disminuye y en las siguientes estaciones, aumenta.
3. Las plagas Oligonychus punicae, Oligonychus yothersi, Bemisia Tabaci y Trips Tabaci presentan correlaciones significativas altas y moderadas con las variables climatológicas temperatura y humedad promedio.
4. Los modelos de predicción basados en aprendizaje automático supervisado permiten predecir la aparición de plagas en el cultivo de palto, con una precisión menor al 90%, en la Empresa Virú S.A.; tal como:
 - para la plaga Oligonychus punicae, Oligonychus yothersi según grado de infestación, ninfas-adultos y la variable climatológica temperatura promedio: $\hat{Y} = -11.8351 + 0.6757TMP_PM$; este modelo realiza estimaciones con una precisión de 87.8%.

- para la plaga *Oligonychus Punicae*, *Oligonychus Yothersi*, según grado de infestación, huevos y las variables temperatura y humedad promedio: $\hat{Y} = 6.295487 + 0.123559TMP_PM - 0.078251HM_PROM$; con una precisión de 48.2% en las estimaciones.
- para la plaga *Trips Tabasi*, según grado de infestación ninfas-adultos/ inflorescencia y la variable climatológica temperatura promedio, $\hat{Y} = 7.138293 - 0.254299TMP_PM$; con precisión de predicción del 33.2%.

VII.RECOMENDACIONES

A continuación, se presenta algunas recomendaciones, agrupadas en categorías generales:

1. En relación a la Base de datos a considerar para posteriores estudios se recomienda: considerar focalizar un lote y evaluar la aparición de plagas en él, todos los días de un año para tener datos que sean progresivos y secuenciales y no data saltante.
2. En relación al modelo de predicción de plagas para posteriores estudios se recomienda: construir otros modelos para otros tipos de plaga y compararlos entre sí, a fin de identificar si hay patrones que unificar y así poder obtener un modelo uniforme.
3. En relación a los datos de las variables climatológicas se recomienda: implementar un sistema que automáticamente guarde la información de las estaciones en Base de Datos para que las consultas sean rápidas e instantáneas.

VIII. REFERENCIAS BIBLIOGRÁFICAS

- Agraria.pe (2019). Un top de crecimiento ¿Cuáles fueron las 10 principales agroexportadoras peruanas de 2018 y a cuánto ascendieron sus ventas? <https://agraria.pe/noticias/cuales-fueron-las-10-principales-agroexportadora-18480>
- Arroyo, P., Rojas, M. y Kleeberg, F. (2016). Diversificación productiva para mejorar la competitividad en los acuerdos comerciales del sector agroindustrial en el Perú. Revista industrial N° 34. Universidad de Lima. https://revistas.ulima.edu.pe/index.php/Ingenieria_industrial/article/download/1341/1360/
- Asociación de propietarios de Can Derroca (20/09/2020). http://apcdspv.org/index.php?lang=es&secc=variables&type=index_de_calor
- Ataucusi, S. (2015). Manejo técnico del cultivo de palto. Editado por Cáritas del Perú. <http://draapurimac.gob.pe/sites/default/files/revistas/Manual%20Palta%20F.pdf>
- Avendaño, J., Mercado, M., Soriano, L. y Villamonte, R. (2018). Plan de negocios para la comercialización de la palta fuerte de los Valles de la Provincia de Lima. https://repositorio.esan.edu.pe/bitstream/handle/20.500.12640/1440/2018_MATC-17-1_2017-1_05_T.pdf?sequence=1&isAllowed=y
- Baiza, V. (2003). Guía técnica del cultivo del aguacate. Programa nacional de frutas de El Salvador. <http://repiica.iica.int/docs/B0218e/B0218e.pdf>
- Barrantes, A. y Vigo, P. (2015). Sistema experto móvil para el diagnóstico y manejo integral de plagas en el arroz. <https://1library.co/document/7q0m93gz-sistema-experto-movil-diagnostico-manejo-integral-plagas-arroz.html>
- Cartillas fitosanitarias. (2019). Evaluación fitosanitaria en instalación. Área de sanidad del palto de la Empresa agroindustrial Virú S.A.

- Carrasco-Ríos, L. (2009). Efecto de la radiación ultravioleta-B en plantas. IDESIA (Chile)
- Duque, D., Saint-Priest, Y., Segivia, P y Loaiz, D. (2017). Algoritmos y programación en pseudo códigos. <https://repository.usc.edu.co/bitstream/handle/20.500.12421/59/ALGORITMOS.pdf?sequence=1&isAllowed=y>
- EcuRed (2020). Velocidad del viento. Consultado el 20 de setiembre de 2020 https://www.ecured.cu/Velocidad_del_viento
- Falconí, J. (2013). Manejo Integrado de Plagas y enfermedades en el cultivo de Kiwicha. Anca sh. <https://docplayer.es/3052933-Manejo-integrado-de-plagas-y-enfermedades-en-el-cultivo-de-kiwicha-contenido.html>
- Gliesman, S. (2002). Agroecología: Procesos ecológicos en agricultura sostenible. <https://books.google.com.pe/books?>
- Herrera, M., Narrea, M. (2011). Manejo integrado del palto. Guía técnica. UNALM. http://www.avocadosource.com/international/peru_papers/herrerarojas_mario2011.pdf
- InfoAgro (2020) Consultado el 12 de setiembre del 2020. https://canales.hoy.es/canalagro/datos/frutas/frutas_tropicales/aguacate.htm#:~:text=En%20cuanto%20a%20precipitaci%C3%B3n%2C%20se,provoca%20la%20ca%C3%ADda%20del%20fruto.
- Jiménez, E. (2009). Métodos de control de plagas. Universidad Nacional Agraria. Managua, Nicaragua. <https://cenida.una.edu.ni/relectronicos/RENH10J61me.pdf>
- Lee, H. A. Moon, K. Moon and Y. Lee. (2017). Disease and pest prediction IoT system in orchard: A preliminary study. Ninth International Conference on Ubiquitous and Future Networks (ICUFN), Milan, 2017, pp. 525-527, doi: 10.1109/ICUFN.2017.7993840 <https://ieeexplore.ieee.org/document/7993840>

- Lemus, G., Ferreira, R., Gil, P., Sepilvera, P., Maldonado, P., Toledo, C., Barrera, C. y Celedón, J. (2010). BOLETÍN INIA -N o 129. Instituto de Investigaciones Agropecuarias.
<http://biblioteca.inia.cl/medios/biblioteca/boletines/NR36902.pdf>
- Lin Jiao, Shifeng Donga,b , Shengyu Zhanga,c , Chengjun Xiea , Hongqiang Wang a . (2020). Computers and Electronics in Agriculture. University of Science and Technology of China, Hefei 230026, China
<https://en.ustc.edu.cn/>
- Matarín, A. y Morales I. (2018). Manual Práctico para el cultivo del pimiento en agricultura protegida. Mundi-Prensa, España.
<https://books.google.com.pe/books?id>
- Ministerio de Agricultura. (2012). Plan Estratégico Sectorial Multianual del Ministerio de Agricultura, 2012-2016. Oficina de Planeamiento y Presupuesto Unidad de Política
https://www.peru.gob.pe/docs/PLANES/14282/PLAN_14282_2015_PE_SEM.PDF
- Montgomery, D., Peck, E. y Vining, G. (2005). Introducción al análisis de regresión lineal. 3ª. Edición. México. ISBN 970-24-0327-8.
- Montero, B. (2018). "Implementación de una solución de inteligencia de negocios para una empresa agroindustrial". Presentada por. Retrieved from
https://repositorio.unp.edu.pe/bitstream/handle/20.500.12676/2319/INF_O-MON-SIL-2018.pdf?sequence=1&isAllowed=y
- Peñaranda, C. (2019). Empleo formal es alto en agroindustria. Informe económico. La cámara-Agosto 5, 2019.
https://www.camaralima.org.pe/repositorioaps/0/0/par/r890_1/iedep.pdf
- Ripa, R., Vargas, R., Larral, P. y Rodríguez, S. (2007). Manejo de la principales plagas del palto. Boletín INIATierra adentro.
http://www.avocadosource.com/journals/tierraadentro/tierraadentro_2007_73_29-33.pdf

- SainlandTrip. Artículo. Presión Atmosférica: que es y cómo se mide. Apuntes (2016). Consultado el 27 junio del 2021. <https://sailandtrip.com/presion-atmosferica/>
- Salvo, J., Torres, A., Olivares, N., Riquelme, J., Leris, L., Rodriguez, F., Olivares, N. y Abarca, P. (2017). Manual del cultivo del palto. Instituto de Desarrollo Agropecuario. Boletín INIA-N° 378. Instituto de investigaciones agropecuarias. <https://biblioteca.inia.cl/handle/123456789/6709>
- sas.com. Aprendizaje automático: Qué es y por qué es importante. Consultado el 27 de junio de 2021. https://www.sas.com/es_pe/insights/analytics/machine-learning.html
- Sebastian Lindgren, Creating and Improving Machine Learning Algorithms for Plant Disease Identification. Consultado el 25 de julio del 2021. <https://www.diva-portal.org/smash/get/diva2:1434579/FULLTEXT01.pdf>
- Soriano, MD. (2020). Precipitación. <http://hdl.handle.net/10251/146445>
- Sullca, C., Molina, C., Rodríguez, C. y Fernández, T. (2018). Detección de enfermedades y plagas en las hojas de arándanos utilizando técnicas de visión artificial. <http://revistas.uigv.edu.pe/index.php/perspectiva/article/view/590>
- Tarazona, L. (2017). Comparativo de diez variedades de palto sobre patrón mexicano a nivel de vivero en Tingo María". https://agronomia.unas.edu.pe/sites/default/files/TS_LATV_2017.pdf
- Torres, A. (2017). Manual del cultivo del palto. Instituto de Investigaciones Agropecuarias (INIA). Boletín INIA / N° 13 INIA - INDAP, Santiago. <http://draapurimac.gob.pe/sites/default/files/revistas/13%20Manual%20Palto.pdf>
- Unir La universidad en internet. (2020). Análisis predictivo: ¿en qué consiste y para qué se usa? INGENIERÍA Y TECNOLOGÍA 22/05/2020 <https://www.unir.net/ingenieria/revista/analisispredictivo/#:~:text=Los%2>

[0modelos%20de%20an%C3%A1lisis%20predictivo,m%C3%A1s%20ex
actas%20ser%C3%A1n%20las%20predicciones.](#)

Prieto, J. y Trelles, R. (2021). Clasificación de hojas de tomate con plagas o enfermedades usando una máquina de soporte vectorial (SVM) <https://pirhua.udep.edu.pe/handle/11042/4940>

Silberschatz, A., Korth, H. F., & Sudarshan, S. (2006). Fundamentos de bases de datos. McGraw-Hill. http://catarina.udlap.mx/u_dl_a/tales/documentos/lis/ydirin_p_mm/capitulo2.pdf

WilliamDAssafMSFT. (f. 25/5/2021). Procedimientos almacenados (motor de base de datos) - SQL Server. Retrieved October 24, 2021, from Microsoft.com website: <https://docs.microsoft.com/es-es/sql/relational-databases/stored-procedures/stored-procedures-database-engine?view=sql-server-ver15>

Yarita Y, Cisneros F. (2010). Ciclo biológico y morfología de *Dagbertus minensis* Carv. & Fontes (Hemiptera: Miridae), en palto var. Hass, en la irrigación Chavimochic, Perú. Rev. peru. entomol. 46(1): 15 - 19. <https://sisbib.unmsm.edu.pe/BVRevistas/entomologia/v46n1/pdf/a03v46n1.pdf>

IX. ANEXOS

Anexo 2. Reunión de trabajo con el equipo del área fitosanitaria de la Empresa Virú S. A.

Equipo Virú S.A:

Gabriela Deza → Jefe de sanidad palto

Carlos Pérez → Gerente de TI

Jordan Huamán → Coordinador de proyectos en TI

