

UNIVERSIDAD PERUANA UNIÓN

FACULTAD DE INGENIERÍA Y ARQUITECTURA

Escuela Profesional de Ingeniería de Sistemas



Una Institución Adventista

Aplicativo Web para la Identificación de Deficiencia de Zinc en naranjos mediante Redes Neuronales Convolucionales

Tesis para obtener el Título Profesional de Ingeniero de Sistemas

Por:

Shiane Lizceth Farfan Vergara

Asesor:

Mg. Abel Ángel Sullon Macalupu

Juliaca, abril de 2021

DECLARACIÓN JURADA DE AUTORÍA DEL INFORME DE TESIS


Mg. Abel Angel Sullon Macalupu, de la Facultad de Ingeniería y Arquitectura, Escuela Profesional de Ingeniería de Sistemas, de la Universidad Peruana Unión.

DECLARO:

Que el presente informe de investigación titulado: **“APLICATIVO WEB PARA LA IDENTIFICACIÓN DE DEFICIENCIA DE ZINC EN NARANJOS MEDIANTE REDES NEURONALES CONVOLUCIONALES”** constituye la memoria que presenta la Bachiller Shiane Lizceth Farfan Vergara para obtener el título de Profesional de Ingeniero de Sistemas, cuya tesis ha sido realizada en la Universidad Peruana Unión bajo mi dirección.

Las opiniones y declaraciones en este informe son de entera responsabilidad del autor, sin comprometer a la institución.

Y estando de acuerdo, firmo la presente declaración en Juliaca, a los 27 días del mes de abril del año 2021


Mg. Abel Angel Sullon Macalupu



ACTA DE SUSTENTACIÓN DE TESIS

En Puno, Juliaca, Villa Chullunquiari, a 27 día(s) del mes de abril del año 2021, siendo las 10:30 horas, se reunieron en el Salón de Grados y Títulos de la Universidad Peruana Unión, Filial Juliaca, bajo la dirección del Señor Presidente del jurado: MSc. Benazir Francis Henera Yucra el secretario: Mtro. Roel Dante Gómez Apaza y los demás miembros: Ing. David Mamani Pari Ing. Angel Rosendo Cendori Coaguira y el asesor: Mg. Abel Angel Sullon Macalupu

con el propósito de administrar el acto académico de sustentación de la tesis titulada: "Aplicativo Web para la Identificación de Deficiencia de Zinc en naranjos mediante Redes Neuronales Convolucionales"

de el(los)/la(las) bachiller(es): a) Shiane Lizabeth Farfan Vergara

b) conducente a la obtención del título profesional de Ingeniero de Sistemas (Nombre del Título Profesional)

con mención en:

El Presidente inició el acto académico de sustentación invitando al (los)/a(la)(las) candidato(a)s hacer uso del tiempo determinado para su exposición. Concluida la exposición, el Presidente invitó a los demás miembros del jurado a efectuar las preguntas, y aclaraciones pertinentes, las cuales fueron absueltas por el(los)/la(las) candidato(a)s. Luego, se produjo un receso para las deliberaciones y la emisión del dictamen del jurado.

Posteriormente, el jurado procedió a dejar constancia escrita sobre la evaluación en la presente acta, con el dictamen siguiente:

Candidato (a): Shiane Lizabeth Farfan Vergara

Table with 5 columns: CALIFICACIÓN, ESCALAS (Vigesimal, Literal, Cualitativa), and Mérito. Row 1: Aprobado, 15, B-, Bueno, Muy bueno

Candidato (b):

Table with 5 columns: CALIFICACIÓN, ESCALAS (Vigesimal, Literal, Cualitativa), and Mérito. Row 1: (Empty)

(*) Ver parte posterior

Finalmente, el Presidente del jurado invitó al(los)/a(la)(las) candidato(a)s a ponerse de pie, para recibir la evaluación final y concluir el acto académico de sustentación procediéndose a registrar las firmas respectivas.

Signature of Presidente

Signature of Secretario

Signature of Asesor

Signature of Miembro

Signature of Miembro

Signature of Candidato/a (a)

Signature of Candidato/a (b)

DEDICATORIA

Con amor a mi querida Madre Esther Vergara de Farfán, quien es mi motivación en la vida.

Porque siempre estuvo para mi apoyándome y dándome fortaleza para seguir creciendo como persona; a mi familia y amigos por sus consejos y buenos deseos

AGRADECIMIENTOS

En primera instancia agradecer a Dios, quien es mi sustento y me da la fortaleza para afrontar las adversidades que surgen en esta vida, gracias a él puedo tener la confianza de realizar mis sueños y objetivos, una de las cuales la culminación de este proyecto de investigación; también agradezco el apoyo incondicional de mi querida Madre Esther Vergara de Farfán, a mi Asesor quien me impartió sus conocimientos y me guiaron en el desarrollo de este proyecto.

ÍNDICE GENERAL

DEDICATORIA.....	IV
AGRADECIMIENTOS.....	V
ÍNDICE GENERAL.....	VI
ÍNDICE DE FIGURAS.....	IX
ÍNDICE DE TABLAS.....	XI
ÍNDICE DE ANEXOS.....	XII
SÍMBOLOS USADOS.....	XIII
RESUMEN.....	XIV
ABSTRACT.....	XV
CAPÍTULO I. El problema.....	16
1.1 Identificación del problema.....	16
1.2 Justificación.....	17
1.3 Presunción filosófica.....	18
1.4 Objetivos.....	18
CAPÍTULO II. Revisión de la literatura.....	19
2.1 Antecedentes de la investigación.....	19
2.2 Marco teórico.....	20
2.2.1 El Naranjo.....	20
2.2.2 Servicio Nacional de Sanidad Agraria – SENASA.....	21
2.2.3 Zinc.....	22
2.2.4 Deficiencia de Zinc.....	24
2.2.5 Inteligencia Artificial.....	27
2.2.6 Lenguajes de Programación.....	38
2.2.7 Anaconda.....	39
2.2.8 Flask.....	40

2.2.9	CRISP-DM	41
2.3	Métodos y procedimientos.....	53
2.2.10	Transfer Learning	53
2.2.11	Capas de Keras	54
2.2.12	Funciones de Activación	55
CAPÍTULO III.	Materiales y métodos	58
3.1	Lugar de ejecución.....	58
3.2	Herramientas	58
3.2.1	Software	58
3.2.2	Hardware	60
3.3	Metodología de la investigación	60
3.3.1	Comprensión del negocio.....	60
3.3.2	Comprensión de los datos	60
3.3.3	Preparación de los datos	61
3.3.4	Modelado.....	61
3.3.5	Evaluación.....	61
3.3.6	Distribución.....	61
3.4	Investigación Tecnológica	61
3.4.1	Arquitectura de solución	62
3.5	Desarrollo de la investigación	63
3.5.1	Etapa 1: Adquisición de Imágenes	63
3.5.2	Etapa 2: Preprocesamiento de Imágenes	64
3.5.3	Etapa 4: Reconocimiento	66
CAPÍTULO IV.	Resultados y discusión.....	73
4.1	Resultado del objetivo 1: Caracterizar la Deficiencia de Zinc en naranjos	73
4.2	Resultado del objetivo 2: Recopilar un Data set de imágenes de hojas de naranjos	

4.3 Resultado del objetivo 3: Construir y validar el modelo de Red Neuronal Convolutiva.....	74
4.3.1 Graficas de los resultados de validación	76
4.4 Resultado del objetivo 4: Desarrollar una interfaz web para mejor visualización para el usuario.....	77
CAPÍTULO V. Conclusiones y recomendaciones.....	78
5.1 Conclusiones.....	78
5.2 Recomendaciones	78
REFERENCIAS	79
ANEXOS.....	85
.....	85

ÍNDICE DE FIGURAS

<i>Figura 1:</i> Naranja en Producción en buen estado nutricional - Naranja Valencia.....	23
<i>Figura 2:</i> Deficiencia de Zinc en cítricos.....	24
<i>Figura 3:</i> Cuajado de fruto y Caída de frutos con aplicación de Zinc en naranjas navel, Egipto	25
<i>Figura 4:</i> Rendimiento y Peso del fruto con aplicación de Zinc en naranjas navel, Egipto	25
<i>Figura 5:</i> Zinc y contenido de ácido ascórbico en Washington Navel-Egipto, Naranja Valencia-Egipto y Toronja-India.....	26
<i>Figura 6:</i> Mortalidad de ramas en mandarina kinnow - India	26
<i>Figura 7:</i> Esquema de Visión Artificial.....	28
<i>Figura 8:</i> Componentes principales de una neurona.....	29
<i>Figura 9:</i> Capas de una Red Neuronal Artificial.....	30
<i>Figura 10:</i> Esquema de una Red Neuronal Convolutiva.....	31
<i>Figura 11:</i> Ejemplo de Convolución en 2 dimensiones	32
<i>Figura 12:</i> Arquitectura de un perceptrón Multicapa. Compuesta por 3 capas: capas de entrada, capas ocultas y capas de salida	32
<i>Figura 13:</i> Funcionamiento de Convolución	33
<i>Figura 14:</i> Convolución y Pooling en una Red Neuronal.....	34
<i>Figura 15:</i> Arquitectura de modelo pre entrenado.....	35
<i>Figura 16:</i> Arquitectura de VGG16.....	37
<i>Figura 17:</i> Tabla de resultados de ILSVRC-2013	37
<i>Figura 18:</i> Lenguajes de programación más utilizados	38
<i>Figura 19:</i> Logo Anaconda.....	39
<i>Figura 20:</i> Logo Jupyter	40
<i>Figura 21:</i> Diagrama de proceso de CRISP-DM.....	42
<i>Figura 22:</i> Metodologías más usadas en Minería de Datos/Ciencia de Datos.....	43
<i>Figura 23:</i> Fase de Comprensión del negocio	44
<i>Figura 24:</i> Fase Comprensión de los datos.....	45
<i>Figura 25:</i> Fase Preparación de datos	47
<i>Figura 27:</i> Fase de Modelado	49
<i>Figura 28:</i> Fase de Evaluación	51
<i>Figura 29:</i> Fase de Despliegue o Implantación	52

Figura 30: Arquitectura de Transfer Learning.....	54
Figura 31: Capa Softmax en una red neuronal	56
Figura 32: Función Sigmoide	57
Figura 33: Arquitectura de solución	62
Figura 34: Recolección de imágenes de hojas de naranjo	64
Figura 35: Redimensionando las imágenes con la herramienta Image Resizer	64
Figura 36: Clasificación de hojas por penetración de deficiencia de zinc.....	65
Figura 37: Clasificación de hojas por nivel de penetración de la deficiencia de Manganeso	65
Figura 38: Pagina de descarga de Anaconda	66
Figura 39: Interfaz principal de Anaconda Navigator	67
Figura 40: Configuración de parámetros para el entrenamiento	68
Figura 41: Importación para construir interfaz web con Flask.....	72
Figura 42: Clasificación de imágenes de hojas de naranjo.....	73
Figura 43: Etiquetando y clasificando el Data Set	74
Figura 44: Data recolectada por cada directorio.....	74
Figura 45: Matriz de confusión, datos de precisión del modelo de red neuronal convolucional	74
Figura 46: Matriz de confusión - validación del modelo.....	75
Figura 47: Datos de perdida.....	76
Figura 48: Datos de Precisión.....	76
Figura 49: Resultados de testing y validación del modelo por consola.....	77
Figura 50: Interfaz web de la predicción de deficiencia de Zinc.....	77

ÍNDICE DE TABLAS

Tabla 1: Lista de Software usados	58
Tabla 2: Lista de Hardware usados.....	60

ÍNDICE DE ANEXOS

Anexo A: Pantalla principal del aplicativo web	85
Anexo B: Pantalla de selección de archivo a identificar o predecir.	85
Anexo C: Interfaz para la identificación de la imagen ingresada.	86
Anexo D: Interfaz en el que se muestra los resultados de la identificación que corresponde a una hoja con deficiencia de zinc.	86
Anexo E: Interfaz en el que se muestra los resultados de la identificación que corresponde a una hoja sana.	86
Anexo F: Interfaz en el que se muestra los resultados de la identificación que corresponde a una hoja con deficiencia de Manganeso.	86
Anexo G: Trabajo de campo con el Ingeniero Agrónomo en la identificación visual de hojas con deficiencias nutricionales.	86

SÍMBOLOS USADOS

- ML: Machine Learning (Aprendizaje Automático)
- PC: Computadora Personal.
- SENASA: Servicio Nacional de Sanidad Agraria
- CNN: Convolutional Neural Network (Red Neuronal Convolutacional)
- Zn: Zinc
- Tn: Toneladas
- MINAGRI: Ministerio de Agricultura y Riego
- HLB: Huanglongbing
- INTA: Instituto Nacional de Tecnología Agropecuaria (Argentina)
- IA: Inteligencia Artificial
- IDE: Entorno de Desarrollo Integrado
- BSD: Berkeley Software Distribución
- MP: Mega pixeles
- ILSVRC: ImageNet Large Scale Visual Recognition Challenge
- WSGI: Web Server Gateway Interface
- CRISP-DM: Cross Industry Standard Process for Data Mining
- DM: Data Mining
- Ha: Hectareas

RESUMEN

La presente investigación nace con la intención de ofrecer como ayuda una herramienta de fácil uso a todos los citricultores que día a día velan por el cuidado de sus cultivos, dicha herramienta permitirá al usuario identificar la deficiencia de Zinc en los naranjos ya que esta deficiencia nutricional es un causante de una serie de daños a la planta en general reduciendo en gran manera su productividad.

Para el desarrollo de la investigación, se utilizó la metodología CrispDM, así mismo se siguieron 4 etapas: 1) Adquisición de Imagen, 2) Preprocesamiento de Imagen, 3) Extracción de Características, 4) Reconocimiento; La identificación de la deficiencia fue realizada mediante Redes Neuronales Convolucionales (siglas en inglés - CNN), tomando como datos de entrenamiento imágenes de las hojas de los naranjos y para su clasificación e identificación, se hizo Transfer Learning haciendo reuso del modelo preentrenado VGG16.

La aplicación de este proyecto fue realizada en una parcela ubicada en el distrito de Quellouno, Provincia La Convención, en el Departamento Cusco, en la cual se recopiló un DataSet de imágenes de hojas de naranjo de dicha zona, para después entrenarlos mediante el modelo VGG16 antes mencionado, el cual fue implementado en una interfaz web donde se realizó la identificación ingresando una imagen de hoja de naranjo cuyo resultado identificó si es una hoja sana o con deficiencia de zinc exitosamente contando con un 81.12% de precisión.

El desarrollo de esta herramienta fue útil para el agricultor, ya que le permite tener un mejor control de sus cultivos frente a la deficiencia de zinc. Así mismo como trabajo futuro se propone añadir datos para cubrir mayor cantidad de deficiencias nutricionales e implementar un módulo de diagnóstico y tratamiento para cada una de ellas.

Palabras clave: Convolución, Deficiencia, Identificación, Redes Neuronales, Zinc.

ABSTRACT

This research was born with the intention of offering as an aid an easy-to-use tool to all citrus growers who day by day watch over the care of their crops, this tool will allow the user to identify the deficiency of Zinc in orange trees since this nutritional deficiency It is a cause of a series of damages to the plant in general, greatly reducing its productivity.

For the development of the research, the CrispDM methodology was used, likewise 4 stages were followed: 1) Image Acquisition, 2) Image Preprocessing, 3) Characteristics Extraction, 4) Recognition; The identification of the deficiency was carried out by means of Convolutional Neural Networks (CNN), taking as training data images of the leaves of the orange trees and for their classification and identification, Transfer Learning was carried out by reusing the pretrained VGG16 model.

The application of this project was carried out in a plot located in the district of Quellouno, La Convencion Province, in the Cusco Department, in which a DataSet of images of orange leaves from that area was compiled, and then trained using the VGG16 model. aforementioned, which was implemented in a web interface where the identification was made by entering an image of an orange leaf, the result of which was successfully identified if it is a healthy leaf or with zinc deficiency, Counting with 81.12% of precision.

The development of this tool was useful for the farmer, since it allows him to have a better control of his crops against zinc deficiency. Likewise, as future work, it is proposed to add data to cover a greater number of nutritional deficiencies and implement a diagnosis and treatment module for each of them.

Keywords: Convolution, Deficiency, Identification, Neuronal Nets, Zinc.

CAPÍTULO I. El problema

1.1 Identificación del problema

Alrededor del mundo las enfermedades de las plantas son el principal problema que reduce directamente la calidad de la producción agrícola; dentro de las causas más frecuentes para que una planta sea atacada por enfermedades esta la falta de nutrientes, ya que estos son necesarios para que la planta se encuentre fortalecida y en total vitalidad.

El Micronutriente Zinc (Zn) es un elemento muy importante en la producción de la naranja. Después de Nitrógeno, sin embargo su deficiencia es la más común en este cultivo y ocurre bajo un amplio rango de suelos por lo que resulta ser un problema a nivel mundial; es así que trabajos desarrollados en Venezuela (V. A. Rodríguez et al., 2014) consideran al Zn como el elemento más limitante para la producción de naranja. Ya que la deficiencia de este nutriente reduce significativamente el crecimiento y el potencial de productividad, los niveles bajos de zinc disminuyen el número de frutas por árbol y, en menor medida, el tamaño de la fruta, lo que resulta en una baja producción. El zinc también es el más pobre del mundo, incluso si las necesidades de las culturas son muy bajas. Actualmente, hay una deficiencia de Zn en el 40% de los pisos inundados en todo el mundo. (Intagri S.C, 2014).

El Ministerio de Agricultura y Riego, a través del Servicio Nacional de Agricultura - Senasa, certificó 1.616 toneladas de naranja que se exportaron a Costa Rica, confirmando la provincia de Satipo, en la región de Junín, como importante productor Citrus. (SENASA, 2017); Así mismo datos estadísticos (MINAGRI, 2018), reporta a los departamentos con mayor producción de naranjas encontrándose a Junín con (283,224 Tn), San Martín (56,629 Tn), Lima (33,710 Tn), Puno (27,432 Tn), Ica (26,571 Tn), Sin embargo Cusco y Huánuco solo produce (18,274 Tn y 11,731 Tn), esto convierte a estos dos departamentos con menos producción y por ende no hay mucho crecimiento económico. Entre los factores que influyen en este decrecimiento de producción se encuentran las enfermedades, plagas y las deficiencias nutricionales como el Zinc.

En el distrito de Quellouno, provincia de la Convención en el departamento Cusco, la población se dedica mayormente a la citricultura, específicamente la producción de naranja. Sin embargo, para que este producto se comercialice en más regiones del país y hasta se exporte a nivel internacional, se debe tener un fruto de buena calidad, tomando en cuenta la guía de buenas prácticas para el cultivo de cítricos recomendado por SENASA, dentro de los cuales para tener un producto de buena calidad el cultivo debe encontrarse con un eficiente abonamiento para evitar deficiencias nutricionales, ya que esto es el principal problema para que se reduzca la producción y el tamaño del fruto, por lo que esta zona del país solo se comercializa dentro de la región, adoptando los costos definidos por la misma, las cuales por ser bajas favorecen al decrecimiento económico

Por ello la detección oportuna y temprana de enfermedades y deficiencias nutricionales en este cultivo es un factor determinante para una eficiente producción de cítricos. Por esta razón, en este proyecto desarrollaremos un Aplicativo Web para la Identificación de Deficiencia de Zinc en naranjos mediante Redes Neuronales Convolucionales donde se tomarán como datos para el entrenamiento imágenes de las hojas del naranjo.

1.2 Justificación

Este proyecto procura dar al usuario agricultor una ruta accesible para el diagnóstico de la deficiencia nutricional del Zinc en sus cultivos; dado que esta deficiencia afecta tanto al fruto como a la planta en si, por lo que, los daños que ocasiona son considerables ya que reduce en gran manera la producción por árbol y esto genera pérdidas económicas al agricultor. Por lo que este proyecto tiene la intención de ofrecer una herramienta de fácil uso en el que el usuario pueda realizar el monitoreo de sus cultivos por sí mismo.

Además, los beneficios que obtendrán los citricultores del sector, al considerar los resultados de la presente investigación serán: información sobre el estado nutricional de Zinc en el naranjo; de manera que puedan realizar una adecuada planificación y organización de su cultivo, garantizando su productividad efectiva que beneficie al agricultor y a la sociedad. Esta tecnología será de ayuda y facilitará al agricultor a poder realizar la identificación de esta deficiencia en su cultivo de cítricos, de manera que no será necesario invertir en la

contratación de un especialista en Agronomía, por lo tanto, el agricultor podrá realizar el diagnóstico respectivo sin realizar muchos gastos.

Por esto, más que una necesidad es una obligación que los cultivos de cítricos estén bajo supervisión y control de calidad haciendo uso de las nuevas tecnologías que permitan identificar las deficiencias que podría tener una planta. De esta manera es posible mejorar la productividad y el rendimiento de la planta, ayudando al crecimiento económico y la comercialización de cítricos en esta zona del País.

Este proyecto implementa un modelo automático de Redes Neuronales Convolucionales en el que identificaremos la deficiencia de Zinc en las plantas del naranjo a través de sus hojas, el cual será de mucha ayuda para las siguientes investigaciones en esta rama, dado que se utilizó Transfer Learning con un modelo preentrenado.

1.3 Presunción filosófica

En el periodo académico desarrollado en la Universidad Peruana Unión, los estudiantes adquieren una serie de conocimientos, hábitos, aptitudes y enseñanzas basadas en los principios cristianos; así como los conocimientos adquiridos para ser un buen profesional al servicio de la humanidad, también nos enseñan a cuidar el medio donde vivimos; Porque Dios creó este mundo, la naturaleza y plantas para que el hombre pueda administrarlo y cuidarlo ya que fue creado para nuestro sustento.

Salmos 104:14, “Haced producir el pasto para los animales y la vegetación para el servicio del hombre, a fin de sacar la tierra el alimento”.

1.4 Objetivos

- **Objetivo general.**

Desarrollar un Aplicativo Web para la Identificación de Deficiencia de Zinc en naranjos mediante Redes Neuronales Convolucionales

- **Objetivos específicos.**

- ✓ Caracterizar la Deficiencia de Zinc en naranjos
- ✓ Recopilar un Data set de imágenes de hojas de naranjos
- ✓ Construir y validar el modelo de Red Neuronal Convolutiva
- ✓ Desarrollar una interfaz web para mejor visualización para el usuario

CAPÍTULO II. Revisión de la literatura

2.1 Antecedentes de la investigación.

En la investigación de (Mehdipour Ghazi et al., 2017), Se utilizaron redes neuronales profundas para distinguir las especies de plantas capturadas en una foto y evaluar varias variables que influyen en la exhibición de estas organizaciones. Se evaluaron tres estructuras sólidas y bien conocidas de CNN, que fueron GoogLeNet, Alexnet y VGGNet. Además, se familiarizaron con el intercambio para desarrollar aún más los modelos previos a la guía utilizando los datos de LifeFlef 2015, dando lugar a GoogLeNet y VGGNet que, al examinar la exposición comparativa con otras organizaciones, logran una mejor ejecución y una mayor precisión.

Según la Revista de Investigación Agropecuaria (RIA) Argentina, investigadores del INTA usaron técnicas de Deep Learning para identificar síntomas de enfermedades y carencias nutricionales en arboles de cítricos, enfocándose en la huanglongbing (HLB) conocida mundialmente una de las enfermedades amenazadoras para la citricultura teniendo impacto en Asia, Sudáfrica y Brasil, siendo esta una amenaza para las plantas que sufran deficiencias nutricionales. (*Aplican Inteligencia Artificial En La Detección de HLB En Cítricos / Revista RIA*, n.d.), Así mismo en el sector Agrícola se han realizado investigaciones de implementación de herramientas computacionales dirigidas con gran intensidad a la identificación de esta enfermedad HLB en cítricos; sin embargo, no se le ha dado importancia relevante a la deficiencia de nutrientes, dado que es un factor de suma importancia, ya que pone en riesgo a la producción, y al igual que el HLB tiene el mismo impacto en pérdidas económicas. (P-salazar et al., 2018)

El trabajo realizado por Robles-Camarillo et al (2016) muestra un examen entre dos estructuras utilizadas en el desafío de reconocimiento de imágenes llamado ImageNet en un desafío de colección visual de gran alcance (ILVRC). El uso de las redes cerebrales convolucionales de Alexnet y VGGNet desdeña la caracterización de las imágenes oculares y depende de cuál de las dos organizaciones obtenga mejores expectativas. En total, la red

Alexnet obtuvo la mejor precisión de estas imágenes anticipadas con una exactitud del 75% en comparación con la organización VGGNet, que obtuvo la mitad.

En el estudio de (Cifuentes et al., 2019), uso redes neuronales convolucionales para el reconocimiento del modelo de imagen de criatura para la producción de la organización cerebral convolucional (CNN), las bibliotecas de flujo tensor se utilizaron en lenguaje python. Para el diseño de la organización se trabajó con una organización VGG. La organización se preparó con 1.500 fotografías obtenidas de Internet, coordinadas en fichas por clasificaciones y diseño en JPG. Para valorar la exposición de la organización se valoraron los 30 nuevos cuadros, de los cuales 10 eran elefantes, 10 leones y 10 pandas. Logra más del 90% de precisión.

En la investigación de (Alejandro Reeatui Pezo, 2018), hicieron una aplicación tecnológica a través de redes de neuronas convolutivas, que permiten el reconocimiento de los caminos de sus hojas, teniendo en cuenta 2800 imágenes para procesos de capacitación, validación. Y el uso de la prueba, que consta de 1400 imágenes de Camu Camu y 1400 imágenes de Camu Camu. El software tiene la oportunidad de reconocer el 100% de las imágenes que realmente corresponden a la hoja de especies de Camu e indican al mismo tiempo al 97%, es otra especie.

2.2 Marco teórico.

2.2.1 El Naranja

Los cítricos, especialmente la naranja, el limón y la mandarina, se encuentran entre los árboles frutales más importantes del mundo. Su cultura y consumo también se llevan a cabo en cinco continentes, también se explota comercialmente en todos los países donde las condiciones climáticas son ideales para su desarrollo en el estudio (Alejandro Reategui Pezo, 2018) hizo una aplicación tecnológica a través de redes de redes neuronales, Permite el reconocimiento de los caminos de sus hojas, teniendo en cuenta 2800 imágenes para procesos de entrenamiento, validación y prueba, que consisten en 1400 imágenes de Camu Camu y 1400 imágenes diferentes de Camu Camu. El software tiene la oportunidad de reconocer el 100% de las imágenes que realmente corresponden a la hoja de especies de Camu e indican al mismo tiempo al 97%, es otra especie. (Restrepo Salazar, Juan Camilo;

Sanchez Lopez, Ricardo; Gallego Beltran, Juan Fernando; Beltrán Ospina, Teresita; Soto Rave, Carlos Alberto; Nieto Solorzano, 2012)

En nuestro país las exportaciones de naranja crecieron 11% durante el 2019, registrando 16,744 toneladas equivalentes a (US\$ 6.6 millones) destinados al Reino Unido teniendo como participación 42% y Países Bajos con 41%, así mismo los países donde tuvo mejor acogida y mejores precios fueron Estados Unidos (US\$ 0.90 por kilo), Colombia (US\$ 1 por kilo), y Ecuador (US\$ 1.14 por kilo). (Peru, n.d.)

Los cultivos del naranjo son permanentes, con una longevidad de 30 y 40 años. Se desarrollan en climas sub-tropicales, debido a este clima existe nivel de humedad que provoca la aparición de algunos hongos, plagas y enfermedades que podrían atacar a la planta, Por ello es recomendable realizar la inspección y verificación ante posibles síntomas de deficiencias nutricionales, ya que una deficiencia podría poner en riesgo a la planta frente a los ataques de distintas enfermedades.

2.2.2 Servicio Nacional de Sanidad Agraria – SENASA

SENASA - El Servicio Nacional Agropecuario es una asociación pública particular adscrita al Ministerio de Agricultura con la Autoridad Oficial de Sanidad Agropecuaria, otorga calidad, creación orgánica y seguridad rural.(Gob.pe, 2020)

Mantiene un marco de vigilancia fitosanitaria y zoonosanitaria que resguarda al país de la sección de molestias y enfermedades que no son detectadas en el Perú. También tiene un marco de cuarentena para problemas de plantas y animales donde hay tareas de importación. Con motivo del Programa Nacional de Control Biológico, el Senasa busca una agroindustria sin pulir que genere interés de mercado para los reguladores naturales, avanzando en la preparación de instalaciones privadas de investigación de control orgánico; a través de modalidades de participación y ayuda especializada.(Senasa, 2018)

Por lo tanto, Senasa en su papel de autoridad nacional desarrolló un conjunto de guías con buenas prácticas agrícolas para diferentes culturas y / o exportaciones locales. Estas guías fueron desarrolladas para ser implementadas por productores agrícolas a través de recomendaciones ecológicas, higiénicamente aceptables y económicamente aplicables. (Insumos & Inocuidad, n.d.)

2.2.2.1 Guía Para La Implementación De Buenas Prácticas Agrícolas para el cultivo de naranja

Su objetivo principal es proporcionar las directivas necesarias para la implementación de buenas prácticas agrícolas (BPA) para pequeños productores de naranja.

Uno de los principales es la selección del campo, es importante considerar todos los requisitos de cultivo, como el agua, el clima, el tipo de suelo, la disponibilidad del equipo de campo, así como la accesibilidad al sitio seleccionado. El naranja es una cosecha muy sensible de bajas temperaturas, se desarrolla mejor entre 13 y 30 ° C. La temperatura es decisiva en la producción de vegetación y volumen de floración de los árboles.

Del mismo modo, la evaluación del tipo de suelo es útil para el uso y la gestión de los fertilizantes porque BPA menciona el Capítulo IV:

Es aconsejable analizar las hojas para saber cuántos nutrientes deberían contribuir a la planta. Las muestras deben retirarse de las plantas homogéneas, que no están enfermas, las hojas de las epidemias se tomaron antes de las frutas. El análisis del suelo, por otro lado, facilita el conocimiento de la disponibilidad de nutrientes en el suelo (suministros y seguridad, S.D.)

Los cítricos cítricos son cultivos muy fertilizados, el comienzo de la fertilización se realiza hasta el comienzo de la segunda germinación. El microcrock genera cambios en el crecimiento y la cantidad de frutas recolectadas. La necesidad nutricional de cultivo naranja varía según la edad estatal y fenológica; Por otro lado, cuando las temperaturas comienzan a aumentar, la necesidad de nutrientes también es mayor. (Insumos & Inocuidad, n.d.)

2.2.3 Zinc

El Zinc está catalogado como un micronutriente debido a que la cantidad de Zinc que necesita una planta para su crecimiento y desarrollo es pequeña, Amezcua Romero & Lara Flores,(2017) menciona que dicha cantidad varía entre 15 y 20 miligramos por

kilogramo de tejido seco; Estos valores representan menos del 0.1% del peso total del tejido seco. Sin embargo, aunque son pequeñas cantidades, este elemento es esencial para las plantas porque participan en el metabolismo celular, ya que ningún otro elemento puede llevar a cabo esta función específica.

Una de sus funciones más importantes es promover el crecimiento celular; Al gobernar la producción de auxinas en la planta, estimula el desarrollo de nuevas hojas, la formación de brotes florales, el desarrollo del tamaño de la fruta y un buen sistema de raíces. Además, contribuye a la viabilidad de los órganos reproductivos de órganos, a la formación de aminoácidos, proteínas y clorofila. (Terralia, 2018)

Además, Zn activa sustancias químicas responsables de la fusión de proteínas específicas. Se utiliza en el desarrollo de clorofila y ciertos carbohidratos y en la transformación de almidones en azúcar; su presencia en el tejido de la hoja ayuda a las plantas a soportar las bajas temperaturas. Es fundamental en la disposición de las auxinas, lo que se suma a la pauta de avance y extensión del tronco. (Terralia, 2018)



Figura 1: Naranjo en Producción en buen estado nutricional - Naranja Valencia
Fuente: (DANE, 2016)

En la investigación de licenciatura como ingeniero agrónomo por (I. Rodríguez, 2018), menciona la importancia del Zinc en una planta por ser una de sus principales funciones la formación de la clorofila que interviene como activador de algunas funciones importantes participando en la formación de las auxinas. Además, en frutales interviene como metal componente de la estructura de las enzimas interviniendo en el metabolismo y formación de

los pigmentos que como resultado darían un fruto de buen color y tamaño adecuado. Por el contrario, la deficiencia de este nutriente llevaría a la manifestación de un retraso de crecimiento en las hojas, retoños tupidos y cortos poniendo en peligro a la formación de nuevos frutos.

2.2.4 Deficiencia de Zinc

Se caracteriza por la formación de áreas amarillentas alrededor de los nervios secundarios de las hojas que se distinguen en un verdoso, que se vuelve estrecho. En estados serios, las hojas, especialmente las mujeres jóvenes, alcanzan un tamaño más bajo que la normalidad. Además, la cosecha se reduce y las frutas son más pequeñas, con la corteza delgada, el pequeño jugo y una baja concentración de soluble sólido. (*Deficiencias Nutritivas En Los Cítricos*, 2016)



Figura 2: Deficiencia de Zinc en cítricos.

Fuente: (2-6 . *Síntomas Visuales de Deficiencias Nutricionales (Diagnóstico Visual)*, 2015)

Los elementos principales del zinc son la actividad como cofactor catalizador y la cooperación en la creación de controladores de crecimiento responsables del aumento de la aplicación y el desarrollo de los cloroplastos. La insuficiencia de Zn esencialmente disminuye el potencial de desarrollo y eficiencia. (*Zinc En La Producción de Cítricos / Yara Perú*, 2019)

➤ Zinc y el número de frutos

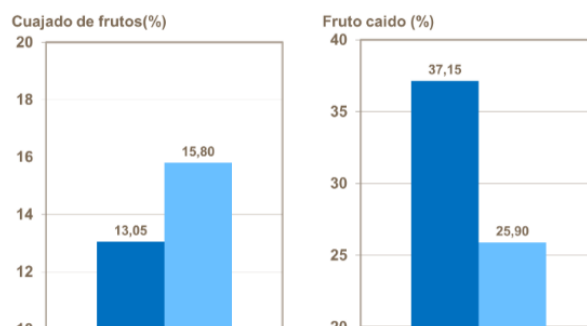


Figura 3: Cuajado de fruto y Caída de frutos con aplicación de Zinc en naranjas navel, Egipto

Fuente: (*Zinc En La Producción de Cítricos* / Yara Perú, 2019)

En la Figura 3. La deficiencia de zinc reduce considerablemente el crecimiento y el potencial de rendimiento. Los niveles bajos de zinc reducen el número de frutas por árbol porque mostraron pruebas con naranjas navel Egipto.

➤ Zinc y el peso del fruto

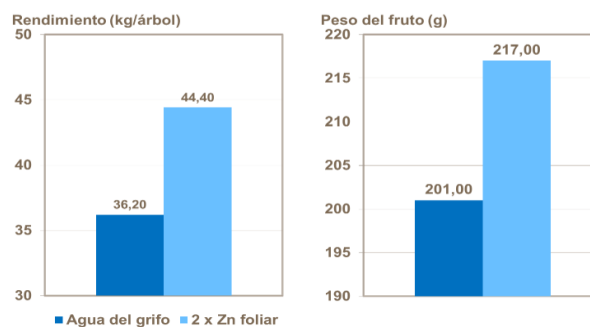


Figura 4: Rendimiento y Peso del fruto con aplicación de Zinc en naranjas navel, Egipto

Fuente: (*Zinc En La Producción de Cítricos* / Yara Perú, 2019)

La figura 4 muestra niveles bajos de zinc, aunque no son tan graves como el número de frutas, reduce el tamaño de la fruta resultante.

➤ **Zinc y vitamina C**

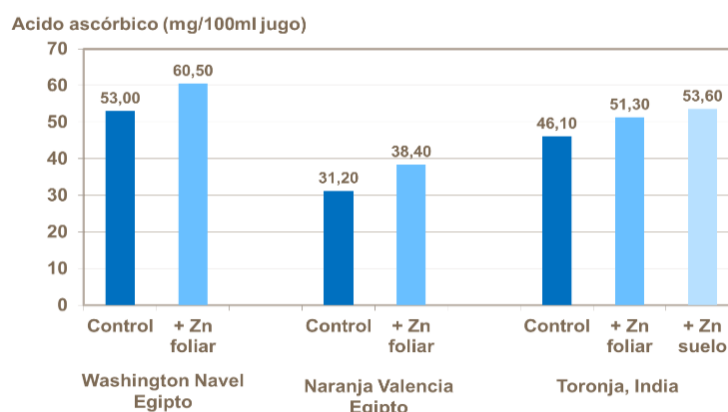


Figura 5: Zinc y contenido de ácido ascórbico en Washington Navel-Egipto, Naranja Valencia-Egipto y Toronja-India.

Fuente: (Zinc En La Producción de Cítricos / Yara Perú, 2019)

El zinc también aumenta el contenido de ácido ascórbico de la fruta. En las circunstancias de una deficiencia severa de Zn, las frutas pueden estar poco entrenadas y tener bajo contenido de jugo, y el regalo no sabrá a ella. Figura 5.

➤ **Zinc y mortalidad de ramas**

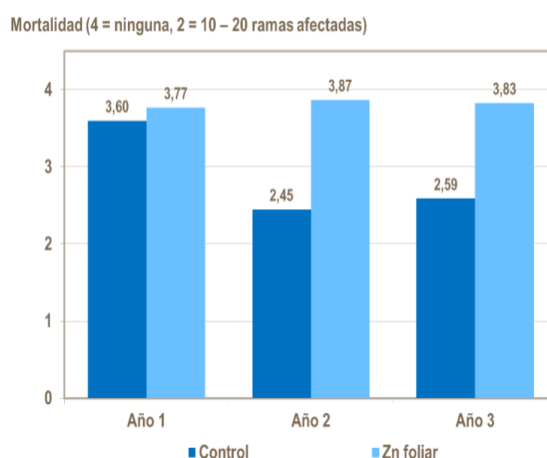


Figura 6: Mortalidad de ramas en mandarina kinnow - India

Fuente: (Zinc En La Producción de Cítricos / Yara Perú, 2019)

Según la gráfica de la Figura 6, Los síntomas de la deficiencia de zinc cítrico aparecen primero como puntos cloróticos en las hojas amarillas y la superficie de la superficie con venas verdes. Hojas jóvenes atrofiadas y en muchos casos, como las rosetas, porque las ramas están cortadas. Las ramas se pueden corregir con aplicaciones del folleto, como se indica en el gráfico.

2.2.5 Inteligencia Artificial

La inteligencia artificial creada por el hombre es el esfuerzo por hacer que una PC sea tan inteligente como una persona; facultándolo para pensar o razonar en vista de la información que se le da.

En ingeniería de software, una "máquina sabia" ideal es un especialista sensato adaptable que puede ver el clima y hacer que los movimientos aumenten sus posibilidades de salir victorioso frente a un objetivo o empresa. La expresión "razonamiento hecho por el hombre" se aplica cuando una máquina se hace pasar por las capacidades mentales que las personas realizan, por ejemplo, aprender, pensar críticamente y volverse más brillantes y astutas para realizar actividades, por ejemplo, el reconocimiento óptico de personas que hacen que esta percepción se convierta en innovación mecánica. (Tesis Inteligencia Artificial, 2017)

Así mismo Nils J. Nilsson, uno de los pioneros de la inteligencia artificial (IA), establece 4 pilares básicos en los que se apoya la IA.

- Búsqueda del estado requerido en el conjunto de los estados producidos por las acciones posibles.
- Algoritmos Genéticos
- Redes Neuronales Artificiales.
- Razonamiento mediante una lógica formal.

2.2.5.1 Aprendizaje Máquina (*Machine Learning*)

Es la manera de hacer algo inteligente artificialmente, mediante una serie de algoritmos que le puedan dar estabilidad. Conocida también como aprendizaje automático o aprendizaje máquina.

Según (García Gazabón, 2014) La IA es un conjunto de procedimientos que son importantes para el razonamiento hecho por el hombre, a la luz de los cálculos que buscan aprender sobre grandes colecciones de información. Un elemento vital de estos cálculos es

la expectativa de nuevos casos a la luz de la experiencia obtenida del conjunto de datos utilizado para la preparación, esto se denomina especulación en el escrito.

2.2.5.2 Vision Computacional (Computer Vision)

La Computer Vision, también llamada visión computacional o visión especializada, es una disciplina lógica que incluye estrategias para obtener, manejar, desglosar y comprender imágenes de esta realidad presente para entregar datos computarizados o representativos para que puedan ser manejados por una PC. Mientras que las personas utilizan nuestros ojos y mentes para comprender nuestro entorno general, la visión artificial planea crear un resultado similar con el objetivo de que las PC puedan ver y captar una imagen o grupo de imágenes y actuar de la misma manera en una circunstancia específica. Esta comprensión se obtiene en varios campos, como el cálculo, las mediciones, las ciencias físicas y diferentes disciplinas. La adquisición de información se obtiene a través de diferentes medios, como agrupaciones de imágenes, viendo diferentes videocámaras o información multifacética de un escáner clínico. (Wikipedia Org, 2020)

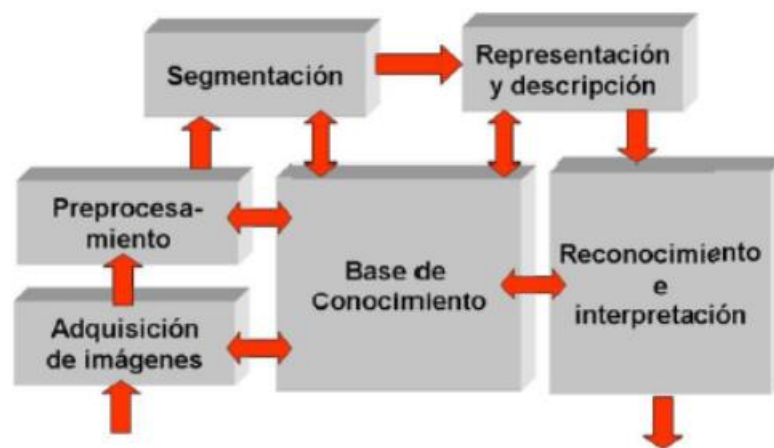


Figura 7: Esquema de Visión Artificial
Fuente: (AVALOS, 2018)

La visión Computacional o visión por computadoras, es la disciplina bajo un área amplia de inteligencia artificial que enseña a las maquinas a ver. Su objetivo es extraer el significado de los pixeles. También pretende idear modelos computacionales del sistema visual humano

La visión Computacional se divide en 3 etapas:

1. Procesamiento de nivel bajo: en el que se extraen propiedades como orillas, gradiente, profundidad, textura, color y otras características de la imagen.
2. Procesamiento de nivel intermedio: se agrupan elementos de nivel bajo para obtener contornos y regiones con el propósito de segmentar las imágenes.
3. Procesamiento de alto nivel: basado en la interpretación utilizando modelos y conocimiento del dominio del problema.

➤ ***Visión Profunda (Deep Visión)***

El aprendizaje profundo ha despegado desde 2012. El aprendizaje profundo es un subconjunto del aprendizaje automático donde las redes neuronales artificiales, algoritmos inspirados en el cerebro humano, aprenden de grandes cantidades de datos. Al impulsar sistemas de recomendación, identificar y etiquetar amigos en fotos, traducir su voz a texto, traducir texto a diferentes idiomas, Deep Learning (Aprendizaje Profundo) ha transformado la visión por computadora que conduce a un rendimiento superior. (Singh Ranjeet, 2019)

Los algoritmos de visión por computadora basados en aprendizaje profundo, como las redes neuronales convolucionales, han comenzado a dar resultados prometedores con precisiones superiores, incluso superando la precisión del nivel humano en algunas tareas.

2.2.5.3 Redes Neuronales

Las Redes Neuronales son una representación inspirada en la Red Neuronal de un Ser Humano.




Figura 8: Componentes principales de una neurona.
Fuente: (Requena et al., 2017)

Como se muestra en la figura 8, los elementos básicos que componen una neurona humana son tres: Dendritas, cuerpo celular o soma y axón. La conexión se llama sinapsis. Las dendritas son los destinatarios de la red que lleva el cuerpo celular con señales eléctricas, el cuerpo celular hace la suma de estos signos de entrada. Axon es una fibra larga que lleva la señal del cuerpo del cuerpo a otras neuronas.

Se llama Red Neuronal a la comunicación entre neuronas interconectadas, en el que estas son capaces de resolver problemas complejos. Según (Montes, 2018), Las redes neuronales tienen forma de surtidos de neuronas conectadas a un gráfico no cíclico; de esta manera, los resultados de neuronas específicas se convierten en diferentes fuentes de datos. Estas organizaciones están coordinadas en varias capas de neuronas, las más conocidas están completamente asociadas, donde las neuronas entre dos capas vecinas están asociadas y las neuronas que tienen un lugar con una capa no comparten asociaciones.




Figura 9: Capas de una Red Neuronal Artificial
Fuente: (Requena et al., 2017)

Una red neuronal está compuesta de neuronas interconectadas y se organiza en tres capas. Los datos penetran a través de la "capa de entrada" (entrada), que pasa la "capa oculta" (capa1, capa2) y deja la "capa de salida" (output). Figura 8.

Las redes neuronales se utilizan para: clasificación de correo electrónico, reconocimiento de voz, reconocimiento de caracteres, caras e imágenes de reconocimiento.

2.2.5.4 Redes Neuronales Convolucionales (CNN)

Una Red Neuronal Convolutiva se puede definir como una red multicapa (Red Neuronal Jerárquica). Una red neuronal convolutiva es un tipo de red multicamada compuesta por varias capas convolutivas y de agrupación (subnumbiles) y, al final, tiene una

serie de capas completas como una red de perptrones multicopa. La entrada de una capa convolutiva suele ser una imagen $M \times M \times R$, donde M es la altura y la imagen amplia y R es el número de canales. La composición de esta red se puede ver en la siguiente figura.

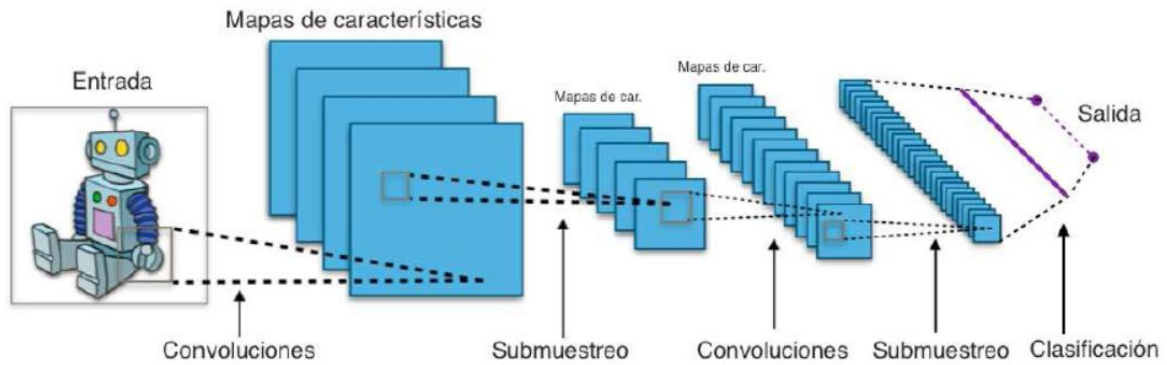


Figura 10: Esquema de una Red Neuronal Convolutiva

Fuente: (Durán Suárez & Del Real Torres, 2017)

Las redes neuronales convolucionales son un tipo de red neuronal para el manejo de información, específicamente el manejo de imágenes. Su nombre proviene de una actividad numérica llamada convolución. La convolución es un tipo específico de actividad directa como la que utilizan las redes convolucionales en al menos una de sus capas. Según (Montes, 2018) se define por la siguiente formula y se denota con un asterisco:

$$s = (t) = (x * x)(t)$$

La función X se conoce como nombre de entrada, la función W es el núcleo y la salida se llama mapa característico. Discreto:

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t - a)$$

En aplicaciones de aprendizaje automático, la entrada suele ser una disposición multidimensional de datos o tensores y el núcleo es una disposición de los parámetros adaptados por el algoritmo de aprendizaje.

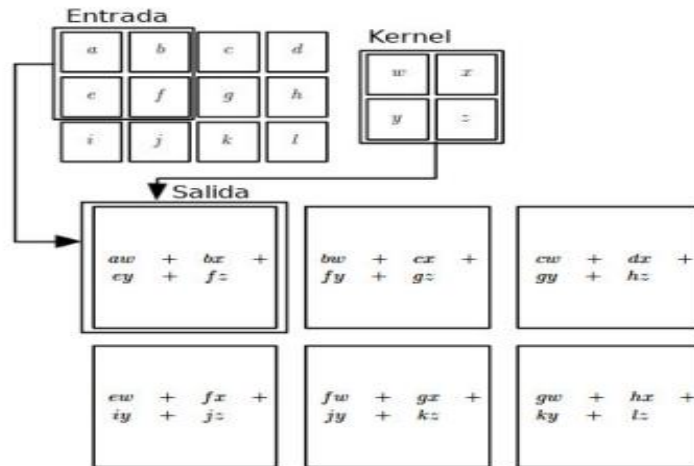


Figura 11: Ejemplo de Convolución en 2 dimensiones
Fuente: (Montes, 2018)

Una Red Neuronal Convolutiva, está compuesta de capas Convolucionales, reducción alternadas y capas de conexión total a esto se le conoce como una Red Perceptrón Multicapa. Esta Red consiste en una capa de partida, capas ocultas y una capa clasificadora que corresponde a la salida; con el perceptrón multicapa que incorpora capas de neuronas ocultas para presentar funciones no lineales. Se caracteriza por tener salidas disjuntas pero relacionadas entre sí, de tal manera que la salida de una neurona sea la entrada de la siguiente.




Figura 12: Arquitectura de un perceptrón Multicapa. Compuesta por 3 capas: capas de entrada, capas ocultas y capas de salida

Este perceptrón está compuesto de 3 capas, como se muestra en la siguiente figura:

Fuente: (Bendemra, 2018)

➤ **Funcionamiento de Convolución.**

En la convolución, se realizan productos y sumas entre la capa inicial y los filtros N (o núcleo) que generan un mapa de funcionalidad. Las características extraídas corresponden a cada ubicación posible del filtro en la imagen original.

La ventaja es que se utiliza un canal similar (= neurona) para separar una utilidad similar en cualquier parte de la información, lo que reduce la cantidad de asociaciones y la cantidad de límites que se deben preparar en comparación con una organización de asociación multifacética completa. (*Red Neuronal Convolutiva CNN - Diego Calvo, 2017*).

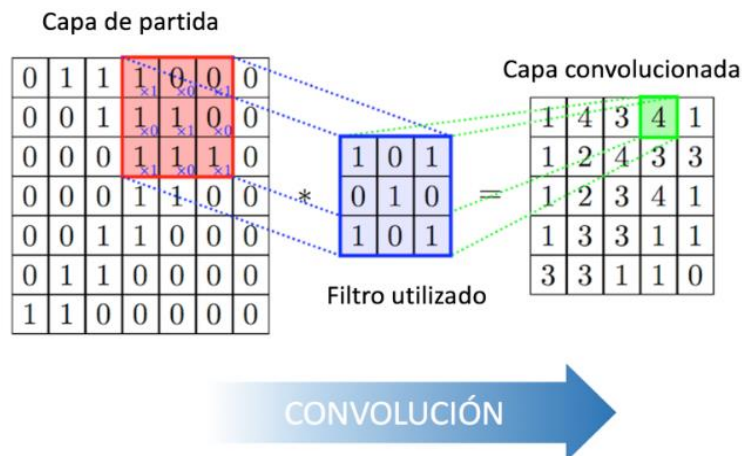


Figura 13: Funcionamiento de Convolución
Fuente: (*Red Neuronal Convolutiva CNN - Diego Calvo, 2017*)

La convolución consiste en tamizar una imagen a través de una capa. Varias capas producen varios resultados. Las capas abordan las asociaciones entre neuronas en las capas anteriores.

Estas capas, paso a paso, ganan puntos destacados de mayor demanda a partir de la entrada de experiencia. Esta experiencia de crecimiento destacada programada es el elemento fundamental del modelo de aprendizaje profundo llamado divulgación de inclusión.

Las redes cerebrales convolucionales están enmarcadas a través de dos tipos de capas: convolutiva y agrupada. La capa de convolución cambia la información a través de la actividad numérica de la convolución. La actividad de convolución describe cómo consolidar dos arreglos únicos de datos.

Después de la(s) capa(s) de convolución, se utiliza una capa de agrupación. La capacidad de las capas de agrupación es sumar las reacciones de las visitas contiguas. Hay 2 elementos principales de la capa de agrupación, primero, la capa de agrupación lógicamente disminuye el tamaño espacial de la información y, en segundo lugar, la agrupación ayuda a obtener una representación invariable en una pequeña interpretación de la información.

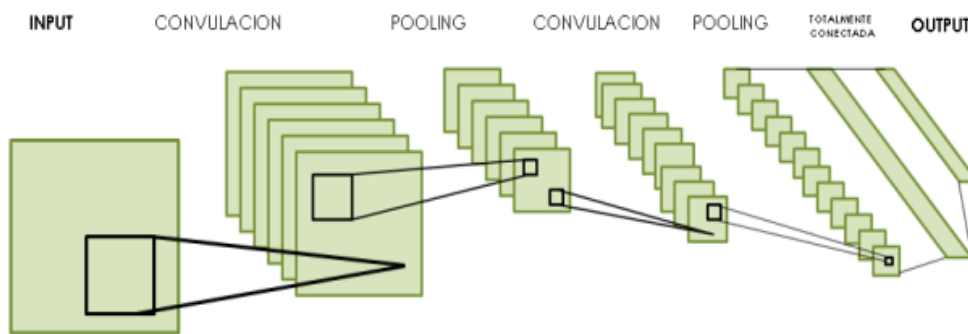


Figura 14: Convolución y Pooling en una Red Neuronal
Fuente:(Intelligent, 2018)

En la actualidad existen muchos entornos y herramientas de desarrollo que permiten trabajar con redes Neuronales convolucionales, tales como:

- ✓ Caffe → Desarrollado por la Universidad de Berkeley
- ✓ Caffe2 → Sucesor de Caffe soportado por Facebook
- ✓ TensorFlow → Soportado por Google.
- ✓ Torch → Soportado por ingenieros de Facebook. Twitter y google, desarrollado en el lenguaje Lua.
- ✓ PyTorch → Una versión de Torch para Python soportada por Facebook
- ✓ CNTK → Soportado por Microsoft.
- ✓ DSSTNE → Soportado por Amazon.

2.2.5.5 Redes Convolucionales para clasificación y detección

Existen varios modelos preentrenados para reconocimiento, tales como se muestra en la siguiente figura:

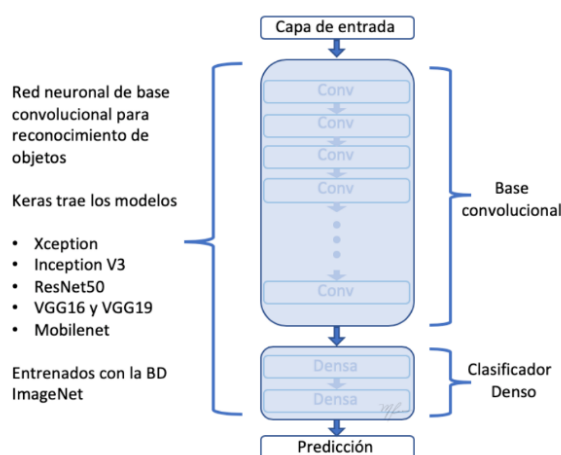


Figura 15: Arquitectura de modelo pre entrenado
Fuente: (Rivera, 2019)

2.2.5.5.1 AlexNET

AlexNet es el nombre de una red neuronal convolucional (CNN), diseñada por Alex Krizhevsky en colaboración con Ilya Sutskever y Geoffrey Hinton, quien fue el Ph.D. de Krizhevsky. Asesor; AlexNet compitió en el ImageNet Large Scale Visual Recognition Challenge el 30 de septiembre de 2012. La red obtuvo error de cinco de 15,3 %, o más de 10,8 puntos porcentuales por debajo del segundo lugar. El efecto secundario principal del primer artículo fue que la profundidad del modelo fue fundamental para su visualización superior, lo cual fue computacionalmente costoso, pero se logró gracias al uso de unidades de procesamiento de diseños (GPU) durante la preparación.

Según (Wei, 2019), la arquitectura consta de ocho capas: cinco capas convolucionales y tres capas completamente conectadas. Pero esto no es lo que hace especial a AlexNet.

2.2.5.5.2 ImageNet

ImageNet es un conjunto de datos de más de 15 millones de imágenes marcadas de alta resolución que pertenecen a aproximadamente 22,000 categorías. Las imágenes fueron recolectadas en la red y etiquetadas por personas que utilizan la herramienta de investigación colectiva de Amazon Mechanical Turk. A partir de 2010, como parte del Pascal Visual Object Challenge, se llevó a cabo una competencia anual llamada ImageNet Large-Scale Visual Recognition Challenge (ILSVRC). ILSVRC involucra un

subconjunto de ImageNet con aproximadamente 1000 imágenes en cada una de las 1000 clasificaciones. En total, hay aproximadamente 1,2 millones de imágenes de preparación, 50 000 imágenes de aprobación y 150 000 imágenes de prueba. ImageNet se compone de imágenes de objetivos fluctuantes. En consecuencia, las imágenes se han reducido a un objetivo decente de 256×256 . Dada una imagen rectangular, la imagen se vuelve a escalar y se edita la fijación focal de 256×256 de la imagen posterior.(Muneeb ul Hassan, 2018).

2.2.5.5.2.1 ImageNet desafío de reconocimiento visual a gran escala de ImageNet (ILSVRC)

El desafío del reconocimiento visual (ILVRC) evalúa los algoritmos para detectar y clasificar objetos de imagen a gran escala. La motivación de alto nivel es permitir a los investigadores comparar el progreso de la detección en una mayor variedad de objetos, aprovechando el esfuerzo de etiquetado muy costoso. Otra motivación es medir la progresión de la visión computacional para la indexación de imágenes grandes en una escala de recuperación y anotación. (Imagenet ILSVRC, 2015)

2.2.5.5.3 VGG16

VGG16 es un modelo de red neuronal convolucional propuesto por K. Simonyan y A. Zisserman de la Universidad de Oxford en el artículo "Organizaciones de nombres excepcionalmente profundas para reconocimiento de imágenes de alcance enorme". El modelo logra una precisión del 92,7 % de las cinco pruebas principales en Imagenet, que es un conjunto de datos de más de 14 millones de imágenes que contienen 1000 categorías. Fue uno de los modelos populares presentados en ILIVRC-2014. Realice la actualización de Alexnet para reemplazar canales de piezas grandes (11 y 5 en la primera y segunda capa convolucional, por separado) con unos pocos canales de piezas de 3×3 uno tras otro. VGG16 se preparó durante mucho tiempo y utilizó la GPU Nvidia Titan Black. (Muneeb ul Hassan, 2018)




Figura 16: Arquitectura de VGG16

Fuente:(Muneeb ul Hassan, 2018)

VGG16 excede considerablemente la generación anterior de modelos en las habilidades ILVRC-2012 e ILVRC-2013. El resultado VGG16 también compite por el ganador de la tarea de calificación (Googlenet con un error del 6,7%) y supera significativamente la presentación ganadora de ILIVRC-2013, Clarifai, que alcanzó el 11,2% con los datos de capacitación externa y 11, 7% sin ella. En términos de rendimiento de una sola red, la arquitectura VGG16 obtiene el mejor resultado (error de prueba de 7.0%), superando a googlenet en un 0.9%.

Method	top-1 val. error (%)	top-5 val. error (%)	top-5 test error (%)
VGG (2 nets, multi-crop & dense eval.)	23.7	6.8	6.8
VGG (1 net, multi-crop & dense eval.)	24.4	7.1	7.0
VGG (ILSVRC submission, 7 nets, dense eval.)	24.7	7.5	7.3
GoogLeNet (Szegedy et al., 2014) (1 net)	-	-	7.9
GoogLeNet (Szegedy et al., 2014) (7 nets)	-	-	6.7
MSRA (He et al., 2014) (11 nets)	-	-	8.1
MSRA (He et al., 2014) (1 net)	27.9	9.1	9.1
Clarifai (Russakovsky et al., 2014) (multiple nets)	-	-	11.7
Clarifai (Russakovsky et al., 2014) (1 net)	-	-	12.5
Zeiler & Fergus (Zeiler & Fergus, 2013) (6 nets)	36.0	14.7	14.8
Zeiler & Fergus (Zeiler & Fergus, 2013) (1 net)	37.5	16.0	16.1
OverFeat (Sermanet et al., 2014) (7 nets)	34.0	13.2	13.6
OverFeat (Sermanet et al., 2014) (1 net)	35.7	14.2	-
Krizhevsky et al. (Krizhevsky et al., 2012) (5 nets)	38.1	16.4	16.4
Krizhevsky et al. (Krizhevsky et al., 2012) (1 net)	40.7	18.2	-

Figura 17: Tabla de resultados de ILSVRC-2013

Fuente: (Muneeb ul Hassan, 2018)

Se demostró que la profundidad de representación es beneficiosa para la precisión de la clasificación y que se puede lograr un rendimiento de vanguardia en el conjunto de datos de desafío de ImageNet utilizando una arquitectura ConvNet convencional con una profundidad sustancialmente mayor.(Muneeb ul Hassan, 2018)

Según la investigación de (VALDERRAMA MOLANO, 2017), Clasificación De Objetos Usando Aprendizaje Profundo Implementado En Un Sistema Embebido, Concluye que la red que menos tiempo tomo en clasificación de objetos fue la red VGG16, en comparación con las demás redes preentrenadas.

2.2.6 Lenguajes de Programación

Elegir el Lenguaje de programación puede ser una tarea un tanto difícil debido a muchos factores y sobre todo a las exigencias del tipo de proyecto que queramos realizar, entre ellas podrían ser la facilidad de aprendizaje, el tamaño que ocupa para sus funciones, el tiempo de instalación del IDE, el más moderno, etc. A continuación, veremos un gráfico de la posición de los 20 lenguajes de programación más usados a nivel mundial.




Figura 18: Lenguajes de programación más utilizados
Fuente: (Lopez Mendoza Marvin, 2020)

Según la clasificación de este proyecto, se decidió usar el lenguaje de programación de Python, porque enfatiza que es un lenguaje de programación fácil y útil. Es de código abierto y se utiliza en muchas áreas, como el aprendizaje automático, la automatización y la científica. Ganó popularidad que incluso venció a Java en la clasificación de Gitub en 2019. (Lopez Mendoza Marvin, 2020)

2.2.6.1 Python

Python es un lenguaje de programación de código abierto poderoso y rápido, es amigable y fácil de aprender.

Recientemente, se ha vuelto extremadamente popular en los mundos de la ciencia de datos y el aprendizaje automático. Si desea conseguir un trabajo de programación bien remunerado en un área interesante, Python es una buena opción ahora. Y si está contratando, hay un grupo creciente de desarrolladores experimentados de Python. Python es un buen lenguaje de uso general y de alto nivel. Su diseño lo hace muy legible, lo que es más importante de lo que parece. Cada programa de computadora se escribe solo una vez, pero se lee y revisa muchas veces, a menudo por muchas personas. Ser legible también hace que sea más fácil de aprender y recordar; por lo tanto, más escribible. En comparación con otros lenguajes populares, Python tiene una curva de aprendizaje suave que lo hace productivo antes, pero tiene profundidades que puede explorar a medida que adquiere experiencia. (Bill, 2019)

2.2.7 Anaconda

Con más de 20 millones de usuarios, Anaconda es la plataforma de ciencia de datos más popular del mundo y la base del aprendizaje automático moderno. Siendo pioneros en el uso de Python para la ciencia de datos, dirigen proyectos de código abierto que hacen posibles las innovaciones del mañana. (Anaconda Inc, 2020)

Anaconda es una distribución open-source para el desarrollo de Machine Learning, dicha tecnología será usada en este proyecto junto con las librerías y herramientas de Inteligencia Artificial como que serán descritas a continuación.



Figura 19: Logo Anaconda

Fuente: (Anaconda Inc, 2020)

2.2.7.1 Jupiter Notebook

Es un proyecto sin fines de lucro, nacido del proyecto Ipython en 2014, porque ha evolucionado para apoyar los datos interactivos y la ciencia científica en todos los lenguajes

de programación. Jupyter siempre será un software de código abierto al 100%, gratis para todos y publicado en los términos liberales de la licencia BSD modificada. (Jupyter Org, 2020)



Figura 20: Logo Jupyter
Fuente: (Jupyter Org, 2020)

2.2.8 Flask

Flask es un microframework de Python con licencia BSD basado en Werkzeug y Jinja2. Ser un microframe no lo hace menos funcional; Flask es un marco muy simple pero altamente extensible. Esto les da a los desarrolladores el poder de elegir la configuración que desean, lo que facilita la escritura de aplicaciones o complementos. Flask fue creado originalmente por Poccoo, un equipo de desarrolladores de código abierto en 2010, y ahora es desarrollado y mantenido por The Pallets Project, que impulsa todos los componentes detrás de Flask. (Kunal, 2019)

Flask tiene dos componentes principales, Werkzeug y Jinja2. Si perfectamente Werkzeug es responsable de proporcionar enrutamiento, depuración e interfaz de ventana de asociación del cuidador web (WSGI), Flask aprovecha Jinja2 como motor de modelo. De manera nativa, Flask no admite el borde a la almohadilla de datos, la autenticación de usuarios o cualquier otro adorno de holgado grado, sin embargo, sí brinda soporte para la integración de extensiones para adicionar todas esas funcionalidades, lo que convierte a Flask en un escenario de responsabilidad acicalado para la fabricación y microempresas para idear aplicaciones web y servicios. Una aplicación ingenua de Flask puede contener en un solo fichero de Python o puede modularizarse para difundir una tenacidad franja para elaboración. La idealización antes de Flask es urbanizar una buena colchoneta para todas las aplicaciones dejando todo lo demás en extensiones.

La sociedad de Flask es justo enorme y activa con cientos de extensiones de estatuto franco. El equipo central de Flask revisa continuamente las extensiones y se garantiza de que las extensiones aprobadas sean compatibles con las versiones futuras. El matraz, que es un microframe, proporciona elasticidad a los desarrolladores para elegir las decisiones de

diseño adecuadas para su programa. Mantiene una nómina de extensiones que se actualiza periódicamente y se mantiene continuamente.

Según (Muñoz, 2017), existen varios motivos por cual usar este Frame work, como:

- **Micro Framework:** Para desarrollar una App básica o que se quiera desarrollar de una forma ágil y rápida Flask puede ser muy conveniente, para determinadas aplicaciones no se necesitan muchas extensiones y es suficiente.
- **Servidor web de desarrollo:** No se necesita una infraestructura con un servidor web para probar las aplicaciones sino de una manera sencilla se puede correr un servidor web para ir viendo los resultados que se van obteniendo.
- **Depurador y soporte integrado:** Si tenemos algún error en el código que se está construyendo se puede depurar ese error y se puede ver los valores de las variables. Además, está la posibilidad de integrar pruebas unitarias.
- **Compatibilidad:** Es compatible con Python3 y Wsi. Wsig es un protocolo que utiliza los servidores web para servir las páginas web escritas en Python.
- **Manejo de rutas:** Cuando se trabaja con Apps Web hechas en Python se tiene el controlador que recibe todas las peticiones que hacen los clientes y se tienen que determinar que ruta está accediendo el cliente para ejecutar el código necesario.
- Soporta de manera nativa el uso de cookies seguras.
- Se pueden usar sesiones.
- Sirve para construir servicios web (como APIs REST) o aplicaciones de contenido estático.
- Flask es Open Source y está amparado bajo una licencia BSD.
- Buena documentación, al alcance de todos, código de GitHub y lista de correos.

2.2.9 CRISP-DM

Es uno de los procesos más populares y ampliamente utilizados para proyectos de análisis y minería de datos. CRISP-DM proporciona el marco requerido, que describe claramente los pasos y flujos de trabajo necesarios para ejecutar un proyecto de análisis y minería de datos, desde los requisitos comerciales hasta las etapas finales de implementación y todo lo demás. La ciencia de datos, la minería de datos y el aprendizaje automático se tratan de intentar ejecutar múltiples procesos iterativos para extraer conocimientos e información de los

datos. Por lo tanto, podemos decir que analizar datos es realmente tanto un arte como una ciencia, porque no siempre se trata de ejecutar algoritmos sin razón; Gran parte del esfuerzo principal implica comprender el negocio, el valor real de los esfuerzos que se invierten y los métodos adecuados para articular los resultados finales y los conocimientos.(Dipanjan, 2018)

Al igual que los proyectos de ingeniería de software, que tienen diferentes modelos de ciclo de vida, CRISP-DM nos ayuda a rastrear un proyecto de análisis y minería de datos de principio a fin. Según (M. Reese, 2017), este modelo se divide en seis pasos principales que abarcan desde los aspectos del negocio y la comprensión de los datos hasta la evaluación y finalmente la implementación, todos los cuales son de naturaleza iterativa.




Figura 21: Diagrama de proceso de CRISP-DM
Fuente: (M. Reese, 2017)

Como hemos podido ver, la metodología CRISP-DM ha recibido gran acogida en los proyectos de implementación de Minería de Datos, así como se muestra en la figura 22 donde muestran los resultados del Ranking de metodologías usadas para Minería de Datos o Proyectos de Ciencia de Datos.

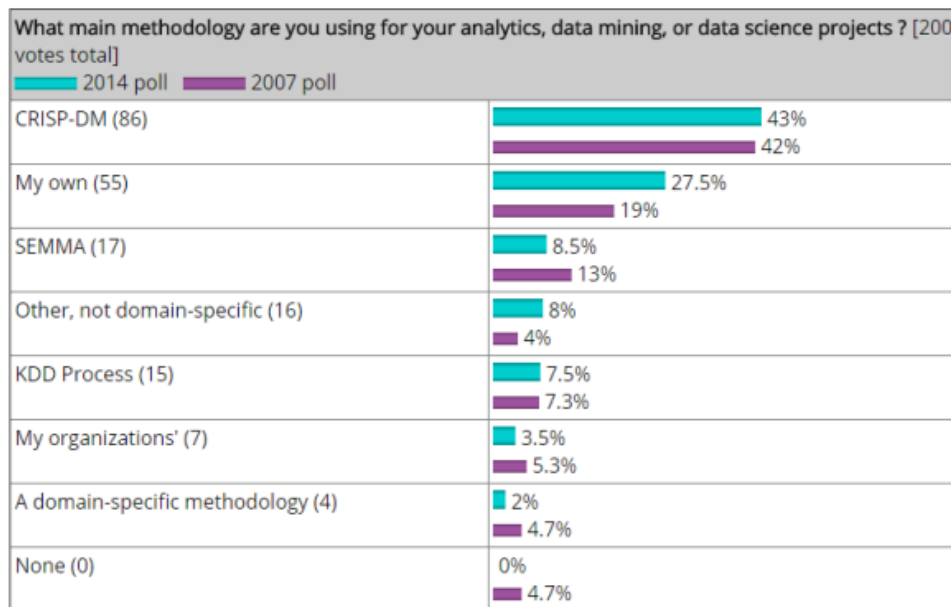


Figura 22: Metodologías más usadas en Minería de Datos/Ciencia de Datos
Fuente: (Digg Data, 2015)

2.2.9.1 Comprensión del negocio

Esta primera fase probablemente es la más importante y reúne las tareas de comprender los objetivos y requisitos de las empresas desde el punto de vista de las empresas, para convertirlos en objetivos técnicos y un plan de proyecto. Sin comprender estos objetivos, ningún algoritmo, tan sofisticado, permitirá resultados confiables. Para obtener la mejor ventaja de la exploración de datos, debe comprender la forma más completa del problema que desea resolver, esto recopilará datos correctos e interpretará adecuadamente los resultados. En esta fase, la capacidad de convertir el conocimiento adquirido de la empresa en un problema de exploración de datos y un plan anterior para lograr objetivos comerciales es muy importante para lograr objetivos comerciales. (Melo Chura, 2018). Esta fase tiene como objetivo determinar los objetivos y requisitos de las empresas desde el punto de vista de las empresas, para hacerlas más tarde en un punto de vista técnico y un plan de proyecto.

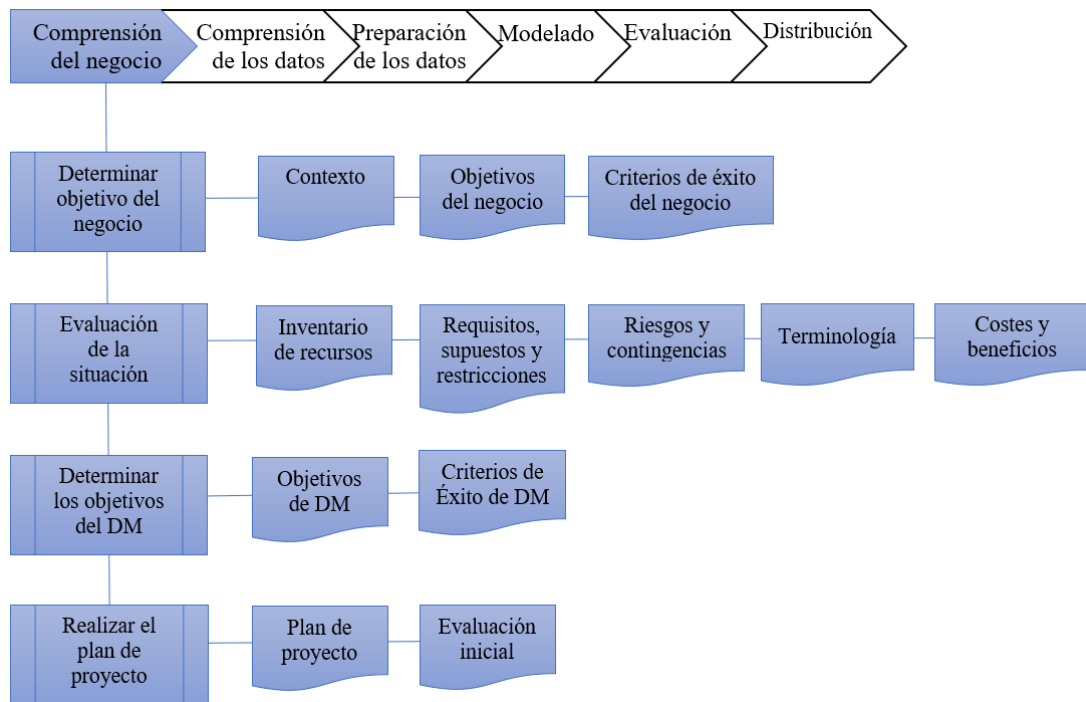


Figura 23: Fase de Comprensión del negocio
Fuente: (Melo Chura, 2018)

- a) **Determinar los objetivos del negocio.** Esta es la primera tarea que se desarrolla y tiene como objetivo determinar qué problema se debe resolver, por qué la necesidad de usar la exploración de datos y definir los criterios de éxito. Los problemas pueden diversificarse, como detectar fraude con tarjetas de crédito, detectar intentos de ingresos inadecuados para un sistema, garantizar el éxito de una cierta campaña publicitaria, etc. En términos de criterios de éxito, pueden ser cualitativos; En este caso, un especialista en dominio describe el resultado del proceso de exploración de datos, o tipo cuantitativo, por ejemplo, el número de detecciones de fraude o la respuesta del cliente a una campaña publicitaria. (Melo Chura, 2018)
- b) **Evaluación de la situación.** En esta tarea, el estado de la situación debe describirse antes de lanzar el proceso de exploración de datos, teniendo en cuenta aspectos como: ¿Qué conocimiento anterior está disponible sobre el problema? ¿La cantidad de datos necesarias para resolver para resolver el problema? ¿Cuál es el problema? ¿El costo de las ventajas de la proporción de la aplicación de la exploración de datos?, Etc. En esta fase, los requisitos del problema se definen, tanto en negocios como en términos de exploración de datos.(Melo Chura, 2018)

- c) **Determinar los objetivos de la minería de datos.** Esta tarea tiene como objetivo representar objetivos comerciales en términos de objetivos de exploración de datos, como si el objetivo comercial sea desarrollar una campaña publicitaria para aumentar la asignación de préstamos hipotecarios, el propósito de la exploración de datos determinará, por ejemplo, el perfil del cliente de su capacidad de deuda.(Melo Chura, 2018)
- d) **Realizar el plan del proyecto.** La última tarea de la primera fase de CRISP-DM es desarrollar un plan para el proyecto, que describe los siguientes pasos y las técnicas que deben usarse en cada uno de ellos.(Melo Chura, 2018)

2.2.9.2 Comprensión de los datos

En esta segunda fase de la metodología CRISP-DM, la recopilación inicial de datos se realiza para establecer un primer contacto con el problema, para familiarizar los datos y descubrir su calidad, así como identificar las relaciones más obvias en la formulación de las primeras hipótesis.(Galán Cotrina, 2015)

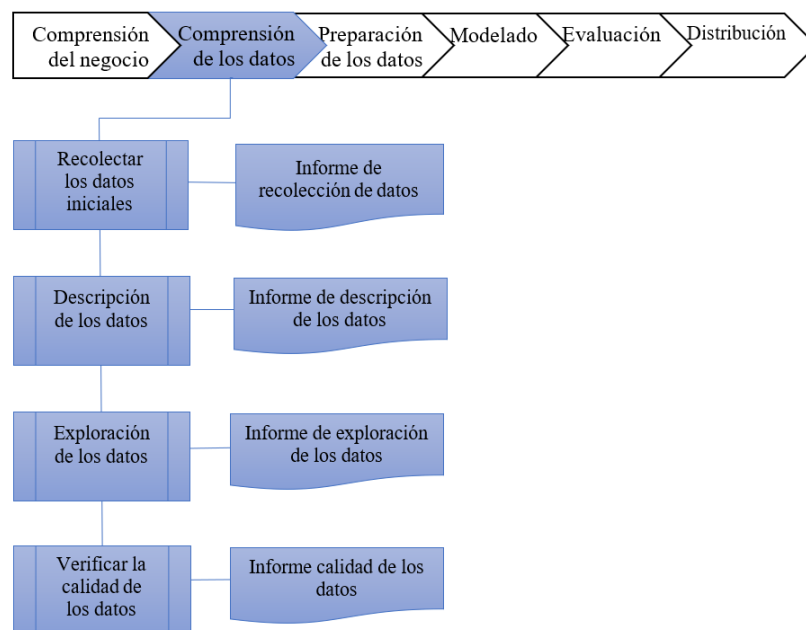


Figura 24: Fase Comprensión de los datos
Fuente: (Melo Chura, 2018)

- a) **Recolectar los datos.** La primera tarea de esta segunda fase del proceso CRISP-DM es la recogida inicial de datos y su adaptación para el futuro tratamiento. Esta tarea tiene como objetivo preparar las relaciones con una lista de datos adquiridos, su

ubicación, las técnicas utilizadas en su recogida y los problemas y soluciones inherentes a este proceso.(Melo Chura, 2018)

- b) Descripción de datos.** Una vez adquirida la información subyacente, hay que representarla. Esta interacción incluye la presentación de los volúmenes de información (número de registros y campos), su prueba reconocible, la importancia de cada campo y la representación de la disposición subyacente.(Melo Chura, 2018)

- c) Exploración de datos.** Cuando se ha realizado la representación de la información, se investiga, lo que significa rastrear un diseño general para la información. Esto incluye la utilización de pruebas medibles esenciales que descubren las propiedades de la información hasta ahora, la elaboración de tablas de recurrencia y la construcción de gráficos de transmisión. El lanzamiento de esta tarea es un informe de exploración de datos.(Melo Chura, 2018)

- d) Verificar la calidad de datos.** En esta tarea, se realizan comprobaciones de los datos para determinar la consistencia de las únicas ventajas de los campos, la suma y distribución de valores cero y para encontrar valores fuera del lado del océano, que pueden estar fuera de circulación por el ciclo. La idea lograda a partir de ahora es tener la opción de garantizar la honestidad y veracidad de la información.(Melo Chura, 2018)

2.2.9.3 Preparación de los datos

Este período del procedimiento incluye la adecuación de la información a los métodos de investigación de información que se utilizarán para ello. Incluye elegir el subconjunto de información que se utilizará, limpiarlos para trabajar en su calidad, acumular nueva información a partir de la información existente y diseñarlos como lo espera el instrumento de demostración. (Galán Cotrina, 2015)

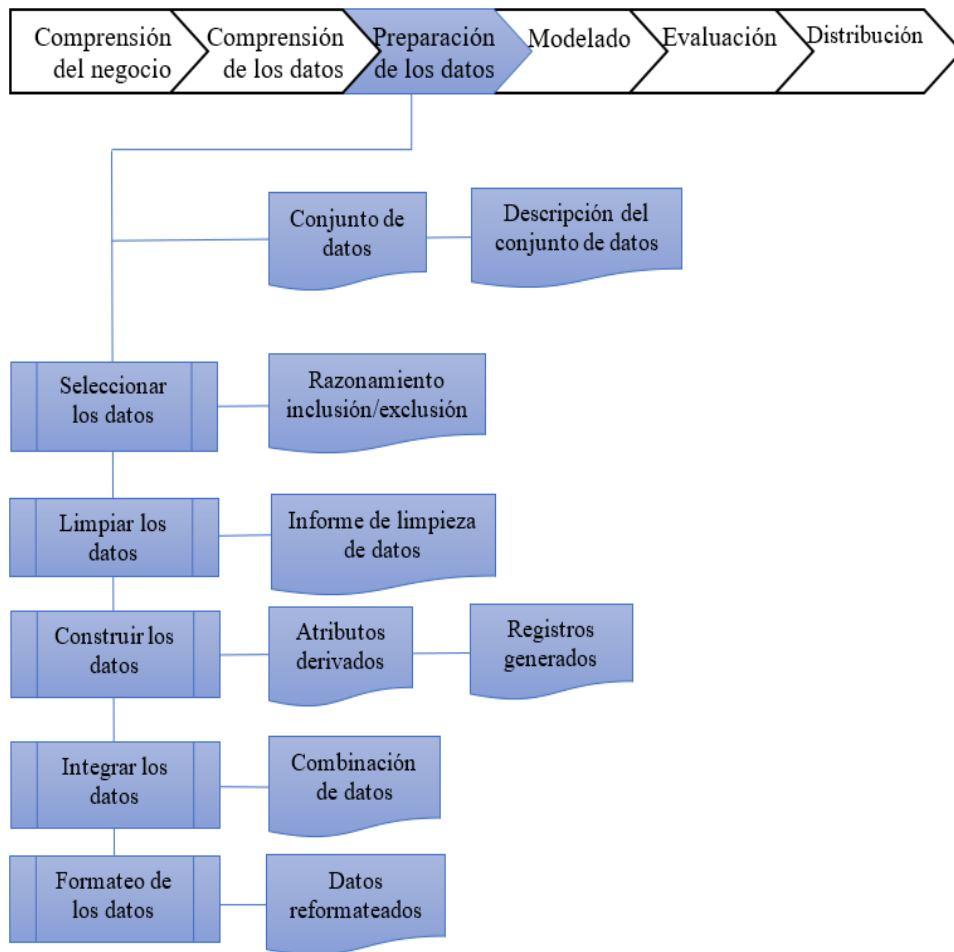


Figura 25. Fase Preparación de datos
Fuente: (Melo Chura, 2018)

- a) **Seleccionar datos.** En esta etapa, se elige un subconjunto de la información adquirida recientemente en vista de los estándares caracterizados recientemente en las etapas anteriores, por ejemplo, la calidad de la información relacionada con el cumplimiento de la información, la corrección de la información y las restricciones de volumen o tipo de información relacionadas con la información. métodos de información. (Melo Chura, 2018)
- b) **Limpiar datos.** Esta tarea cierra la anterior y es posiblemente la tarea y el esfuerzo más tedioso debido a la variedad de métodos que se pueden aplicar para agilizar la naturaleza de la información para prepararla para la etapa de visualización. Algunos de los procedimientos que deben utilizarse para este propósito son la normalización de la información, los campos informáticos discretos, las calidades faltantes, la reducción del volumen de la información, etc.(Melo Chura, 2018)

- c) **Construir datos.** Este recado incorpora tareas de preparación de información, como producir nuevas propiedades a partir de cualidades existentes, coordinar nuevos registros o cambiar cualidades por rasgos existentes. (Melo Chura, 2018)

- d) **Integrar datos.** La coordinación de la información incluye hacer nuevos diseños a la luz de la información elegida, por ejemplo, producir nuevos campos a partir de los existentes, hacer nuevos registros, combinar nuevas tablas o tablas en las que las cualidades de los atributos de diferentes registros o diferentes campos en nuevas tablas de sinopsis. (Melo Chura, 2018)

- e) **Formateo de datos.** Esta tarea es predominantemente para realizar cambios de información sintáctica sin cambiar su importancia para ser aprobado y trabajar con la utilización de una estrategia de investigación de información específica, como el rediseño de registros de campo o registro potencial o el cambio de la tabla de valores a los confines de la tabla. mostrar instrumentos (evacuación de coma, simple, extraordinario, mayor y menor para caracteres, etc.) (Melo Chura, 2018)

2.2.9.4 Modelado

En esta fase de la metodología, se elegirán las técnicas (o técnicas) más apropiadas para los increíbles objetivos de la exploración de datos. Por lo tanto, y una vez que se realizará una prueba de los modelos elegidos, estas técnicas se aplicarán al modelo para generar el modelo y finalmente debe evaluar si el modelo ha cumplido los criterios de éxito o no exitoso. (Galán Cotrina, 2015)

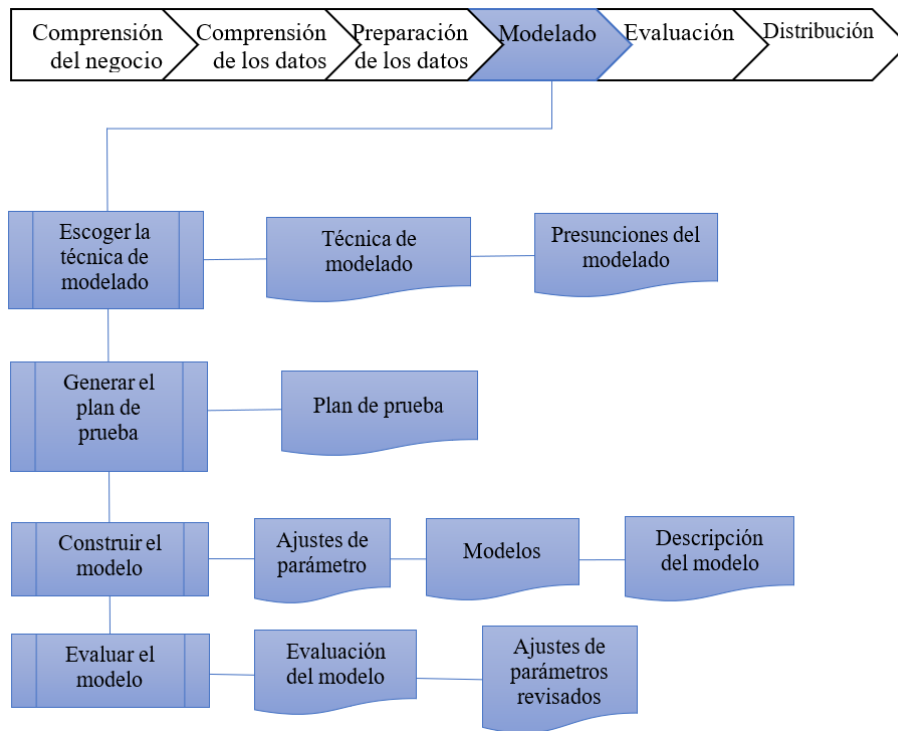


Figura 26: Fase de Modelado

Fuente: (Melo Chura, 2018)

- a) **Escoger técnica de modelado.** Esta fase consiste en elegir el procedimiento de investigación de información más adecuado para el tipo de asunto que necesita resolver. Para esta elección, se debe considerar el objetivo fundamental del emprendimiento y la relación con los instrumentos de investigación de información existentes. Por ejemplo, si el problema se está agrupando, puede elegir entre los árboles de elección, el extremo o el caso K-A, según el caso (CBR), si el problema es una evaluación, un examen de recaída o cerebro. organizaciones o por el contrario asumiendo que el tema es división, organizaciones cerebrales, procedimientos de representación, etc. (Melo Chura, 2018)

- b) **Generar plan de prueba.** Se debe producir un sistema que muestre la calidad y legitimidad del modelo elegido cuando esté en desarrollo. Por ejemplo, en una tarea de investigación de información regulada, por ejemplo, ordenar, es normal involucrar el proceso de pensamiento erróneo como una proporción de la calidad. Luego, generalmente separe la información en dos conjuntos, uno de la preparación y otro de la prueba, luego fabrique el modelo como lo indica el conjunto de preparación y mida la naturaleza del modelo creado con el conjunto de prueba.(Melo Chura, 2018)

c) **Construir modelo.** Luego, la estrategia elegida se realiza sobre la información recientemente preestablecida para producir al menos un espectáculo. Todas las estrategias de demostración tienen un montón de límites que deciden las cualidades del modelo que se va a producir. Elegir los mejores límites es una interacción iterativa y depende completamente de los resultados producidos. Deben ser descifrados y sustentada su exhibición. (Melo Chura, 2018).

d) **Evaluar modelo.**

En la última tarea de esta etapa de demostración, los ingenieros de DM descifran los modelos según la información previa sobre las reglas de progreso establecidas recientemente. Especialistas en el tema, juez de emisión y expertos en investigación de información, aplican sus propios estándares (prueba de seguridad, infortunios, etc.). (Melo Chura, 2018)

2.2.9.5 Evaluación

En este período del sistema, se esfuerzan por evaluar los modelos creados, pero esta vez la evaluación es de acuerdo con la perspectiva de los objetivos comerciales, en contraposición a los objetivos de investigación de información. Cuando se ha dirigido esta evaluación, es importante elegir si se cumplieron los objetivos y, en conjunto, se puede avanzar en la etapa de ejecución, mientras que tal vez no haya elementos que puedan desatenderse y se deba distinguir la auditoría del ciclo. (Galán Cotrina, 2015)

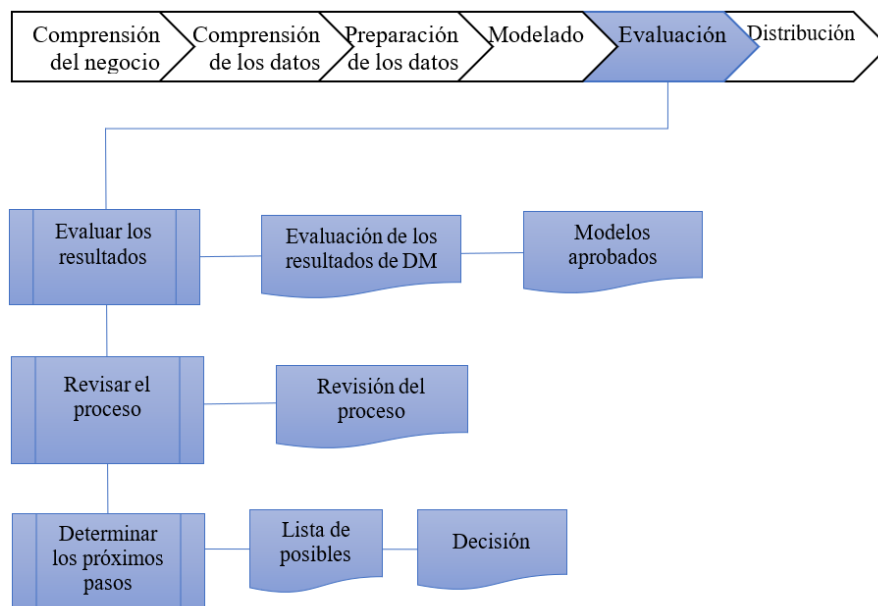


Figura 27: Fase de Evaluación

Fuente: (Melo Chura, 2018)

- a) **Evaluar resultados.** En fases previas de evaluación, se examinaron factores, por ejemplo, la exactitud y el consenso del modelo producido. Esta tarea incluye la evaluación del modelo sobre los objetivos comerciales y trata de decidir si existe una justificación comercial de por qué el modelo es malo o si es adecuado probar el modelo en un problema real si el tiempo y los requisitos lo permiten. A pesar de los resultados directamente relacionados con el objetivo de la empresa, ¿es prudente considerar el modelo en contraste con objetivos distintos a los primeros? Esto podría descubrir datos adicionales.(Melo Chura, 2018)

- b) **Revisar proceso.** Esta interacción alude a la capacidad de todo el ciclo de investigación de la información para distinguir componentes que podrían ser llevados al siguiente nivel.(Melo Chura, 2018)

- c) **Determinar próximos pasos.** Suponiendo que se haya resuelto que hasta este punto las etapas han producido resultados aceptables en la etapa siguiente, de otra manera se podría concluir hacer un ciclo más de la etapa de planificación de información o demostrar con varios límites. Puede tratarse de que en esta etapa se opte por comenzar sin preparación alguna con otro proyecto de investigación de información.(Melo Chura, 2018)

2.2.9.6 Despliegue o Implantación

Este es el último período de la metodología CRISP-DM y el objetivo es aclararle al cliente cómo organizar la tarea trabajada en las etapas anteriores, así como descubrir los resultados que obtuvo el cliente para resolverlo de manera efectiva. Otro punto a favor de esta etapa es idear un método para mantenerse al día con el proyecto y entregar un informe que incluya mejoras potenciales para el futuro y un resumen de las dificultades experimentadas. (Galán Cotrina, 2015)

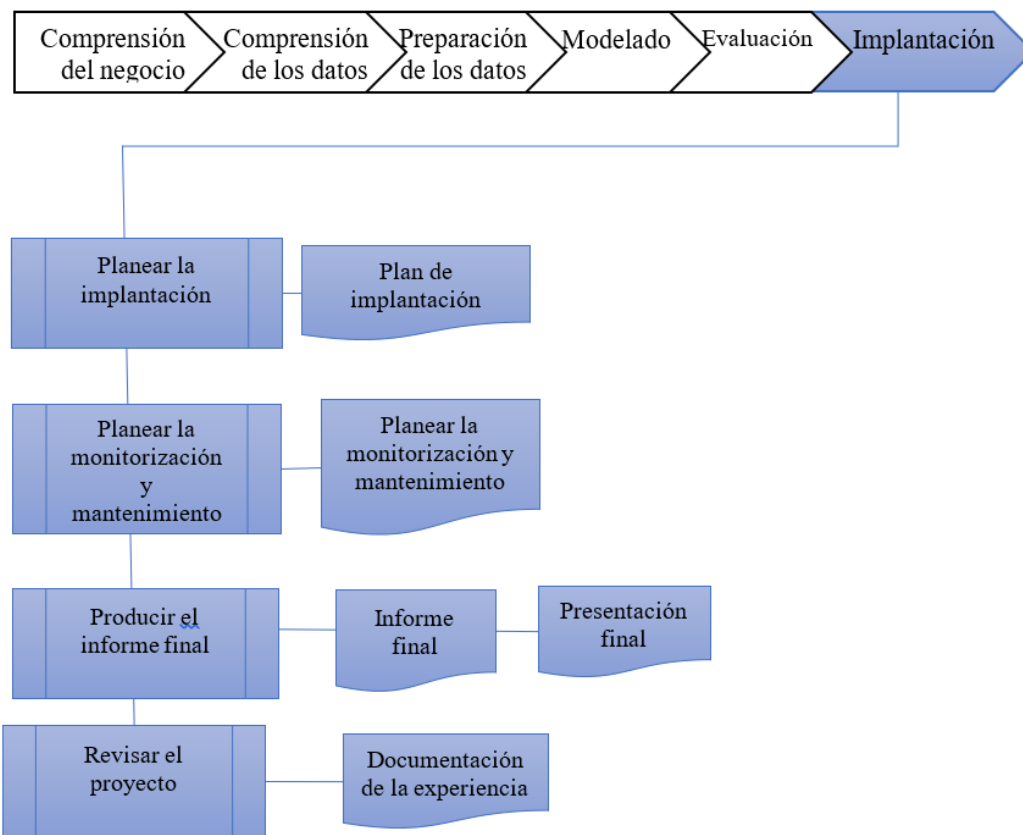


Figura 28: Fase de Despliegue o Implantación

Fuente: (Melo Chura, 2018)

- a) **Planear implantación.** Para llevar a cabo la consecuencia de la investigación de la información en la asociación, este emprendimiento obtiene las secuelas de la evaluación y cierra una metodología para su ejecución. En caso de que se haya identificado un sistema general para hacer el modelo, este método debe informarse para la ejecución resultante.(Melo Chura, 2018)

- b) **Planear monitorización y mantenimiento.** Asumiendo que los modelos obtenidos del proceso de investigación de la información se llevan a cabo en el campo del problema como parte del día a día de la práctica, es prudente preparar metodologías de observación y mantenimiento que se apliquen a los modelos. La entrada producida por la verificación y el mantenimiento puede mostrar si el modelo se está utilizando con precisión. (Melo Chura, 2018)

- c) **Producir informe final.** Esta es la culminación del proyecto de auditoría de la información. Dependiendo del plan de ejecución, este informe debe ser una sinopsis de los aspectos más importantes del proyecto y la experiencia adquirida donde tiende a ser un último espectáculo que incorpora y da sentido a los resultados obtenidos con el proyecto. (Melo Chura, 2018)
- d) **Revisar proyecto.** Esta tarea evalúa qué cosas se hicieron con precisión y qué se equivocó, así como puntos en los que se podría trabajar en la tarea. El proceso de investigación de información le permite adquirir información para que los datos trabajen en ella. Posteriormente, esto se hará a través de una estrategia CRISP DM. (Melo Chura, 2018)

2.3 Métodos y procedimientos

2.2.10 Transfer Learning

Transfer Learning es uno de los procedimientos de aprendizaje profundo. Esa es su ventaja, más que preparar una red neuronal sin ninguna preparación, puede incluir una gran cantidad de información y requiere un montón de tiempo de procesamiento (días o semanas) para preparar, vamos de una prensa. Esta estrategia nos permite descargar un modelo de código abierto que alguien preparó recientemente en un gran conjunto de datos y utilizar sus límites (miles o millones) como etapa inicial para seguir preparando el modelo más adelante con toda la información (más modesta) que tenemos sobre algún proyecto. (Torres, 2019)

Suponiendo que el primer índice de información a partir del cual se preparó la red neuronal de administración es suficientemente grande y general, el orden espacial de los elementos (destacados) avanzados mediante la búsqueda previa y, en consecuencia, sus resaltados podrían ser útiles para una amplia gama de problemas de visión de PC, aunque estos nuevos los problemas pueden incluir clases totalmente diferentes de las de la primera empresa.

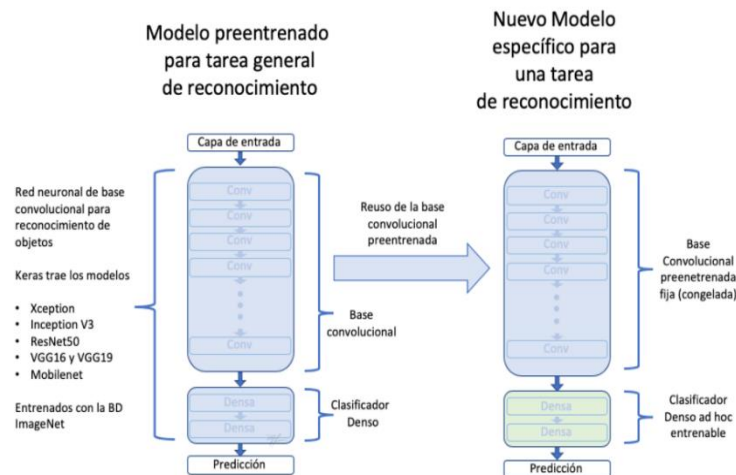


Figura 29: Arquitectura de Transfer Learning
Fuente:(Rivera, 2019)

2.2.11 Capas de Keras

2.2.11.1 Modelo Sequential

API Keras tiene dos formas de construir redes neuronales. El más simple es el modelo secuencial que solo permite agregar las capas a la secuencia.

La forma de importación es: `from keras.models import Sequential, Model`

2.2.11.2 Dense

Capa oculta en la que cada nodo está conectado a cada uno de los nodos de la capa oculta subsiguiente.

Una capa completamente conectada también se conoce como una capa densa.

2.2.11.3 Flatten

La instrucción plana convierte los elementos de la matriz de imagen de entrada en una red plana. Entonces, con la instrucción, agregamos una capa oculta (capa oculta) de la red neuronal. El primero, por ejemplo, puede tener 1000 nudos, el segundo 500 y el tercero (capa de salida) 100.

2.2.11.4 Dropout

La capa de abandono es una técnica simple y poderosa para las redes neuronales y, con el aprendizaje en profundidad, el abandono (abandono) es una técnica en la que las neuronas seleccionadas al azar se ignoran durante el entrenamiento. Ellos "se van" al azar. Esto significa que su contribución a la activación de las neuronas aguas abajo se elimina temporalmente en la parte delantera y las actualizaciones de peso no se aplican al paso hacia atrás.

Según (Browenlee, 2016), a medida que se aprende una red neuronal, las neuronas se establecen con respecto a la organización. Las cargas de las neuronas se adaptan a elementos explícitos que dan una especialización específica. Las neuronas dependen de esta especialización que, si es distante, puede generar un modelo extremadamente delicado para preparar información. Esta configuración de dependencia de una neurona durante la preparación alude a mezclas complejas.

Por lo tanto, suponiendo que las neuronas se eliminen al azar de la organización durante la preparación, otras neuronas deberían intervenir y manejar la representación esperada para generar expectativas por la ausencia de neuronas. Esto se acepta para lograr que la organización aprenda algunas representaciones internas gratuitas.

2.2.12 Funciones de Activación

La función de activación es responsable del retorno de una salida de salida, generalmente todos los valores de salida en una playa dada, como (0,1) o (-1,1).

Se buscan funciones que las derivadas sean simples, para minimizar con ello el coste computacional.

2.2.12.1 RELU

La función de reducción transforma los valores ingresados que cancelan los valores negativos y dejan lo positivo.

(Noren, 2019) menciona, Cuando procesamos una imagen, cada capa de convolución debe capturar un ejemplo en la imagen y pasarlo a la siguiente capa. Las cualidades negativas no son significativas en el manejo de la imagen y, por lo tanto, se establecen en 0. Sin embargo,

las cualidades positivas después de la convolución deben ir a la siguiente capa. Por ello se utiliza apoyándose en la función de activación.

2.2.12.2 *Softmax*

La función softmax transforma los resultados en una representación en forma de probabilidades para que la suma de todas las probabilidades de las salidas sea 1.

La función Softmax se utiliza como la capa final de clasificador basada en redes neuronales. Estas redes se forman comúnmente por una dieta de entropía cruzada, que obtuvo una variante no lineal de regresión de logística multinomial multinomial.

Softmax es ejecutado por una capa de red neuronal en poco tiempo antes de la capa de resultados. La capa Softmax debe tener una cantidad similar de concentradores que la capa de resultados. Softmax acredita probabilidades decimales a cada clase en un caso de varias clases. Estas probabilidades decimales deben sumar 1,0. Este imperativo adicional permite que la preparación hable más rápido.

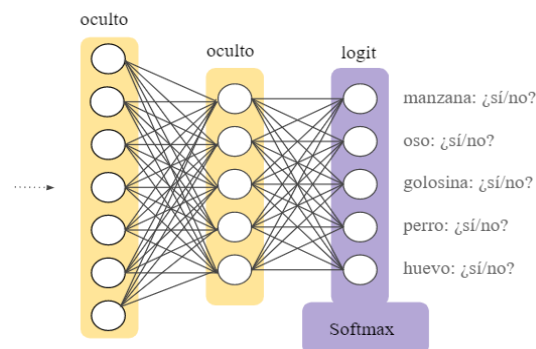



Figura 30: Capa Softmax en una red neuronal
Fuente: (Google Developers, 2020)

2.2.12.3 *Sigmoide*

La función sigmoide transforma los valores introducidos en una escala (0,1), donde los valores altos tienen asintóticamente en 1 y los valores muy débiles tienden a asintóticamente en 0.

Esta capacidad, también llamada trabajo calculado, está en los valores de resultado en algún lugar en el rango de cero y uno, con el objetivo de que el resultado se descifre como probabilidad. Si la capacidad se evalúa con valores de información muy malos, por ejemplo,

x 0, la capacidad será cero, si se estima en cero, la capacidad dará 0,5 y con calidades altas, su valor será ser aproximadamente 1. Posteriormente, se utiliza esta capacidad, por lo tanto, se utiliza esta capacidad. en la última capa y se utiliza para caracterizar la información en dos clases.



$$f(x) = \frac{1}{1 + e^{-x}}$$

Figura 31: Función Sigmoide

Fuente:(Bootcamp AI, 2019)

CAPÍTULO III. Materiales y métodos

3.1 Lugar de ejecución

El proyecto se aplicó en el fundo “Valle Encantado”, parcela de 5.8 Ha, ubicado en el Distrito de Quellouno, Provincia La Convención en el Departamento Cusco. Donde se desarrolló la recolección de datos de entrada, imágenes de hojas de naranjo para el entrenamiento y se realizaron pruebas del modelo de red neuronal.

3.2 Herramientas

3.2.1 Software

Tabla 1: Lista de Software usados

Librería/ Software	Version	Definición
Tensorflow	2.1.0	<p>Es una etapa de código abierto para la IA. Tiene un entorno total y adaptable de herramientas locales, bibliotecas y activos que permite a los científicos desarrollar inteligencia artificial inteligente y a los ingenieros solicitar y enviar aplicaciones con innovación AA sin ningún problema. (TensorFlow Org, 2020) Tensorflow es una biblioteca creada por Google Brain para sus aplicaciones de inteligencia artificial y sus organizaciones cerebrales profundas, lanzada por la programación de código abierto el 9 de noviembre de 2015. También es una biblioteca de cálculo numérico, que funciona rápidamente y realmente transmite gráficos. Un gráfico de flujo se compone de tareas numéricas dirigidas a los centros, y la información y el resultado son un vector (o tensor) de información multifacético. (Luis, 2019)</p> <p>Es una biblioteca gratuita para conocimientos de máquinas que admite Python y C ++ es para estimaciones computarizadas que utilizan un esquema de flujo de datos y gráficos de direcciones de tareas numéricas. Tiene una ingeniería adaptable y se espera que lleve a cabo una sola API, y su capacidad es para IA..</p>

Matplotlib	3.2.2	Matplotlib es una biblioteca completa para crear perspectivas estáticas, energizadas e inteligentes en Python. Es un emprendimiento apoyado por Numfocus, una asociación magnánima sin fines de lucro en los Estados Unidos. Numfocus brinda ayuda monetaria, legal y administrativa para garantizar el bienestar y la capacidad de administración de la empresa. (<i>Matplotlib: Python Plotting — Matplotlib 3.3.2 Documentation</i> , n.d.)
Numpy	1.17.0	Numpy, la abreviatura de Python Digital, ha sido una piedra angular de la informática digital en Python. Proporciona estructuras de datos, algoritmos y bibliotecas pegadas para la mayoría de las aplicaciones científicas que involucran datos digitales en Python. Numpy se suma a Python, uno de sus usos principales en el análisis de datos es un contenedor para pasar los datos entre algoritmos y bibliotecas. Para los datos digitales, las matrices numpy son más efectivas para almacenar y manipular datos que otras estructuras integradas de datos de Python. (Wes, 2017)
Pandas	1.0.5	Proporciona estructuras y funciones de alto nivel diseñadas para operar con datos estructurados o tabulares son rápidas, fáciles y expresivas. Desde su aparición en 2010, Python ha ayudado a ser un entorno poderoso y productivo de análisis de datos. Pandas combina -EN: ideas de matriz de rendimiento con funciones de manipulación de cálculo flexible y bases de datos relacionales (como SQL). Proporciona una función de indexación sofisticada para ser fácil de remodelar, cortar y cortar, agregar y seleccionar el subconjunto de datos. Desde el manejo, la preparación de datos y la limpieza son una capacidad tan importante en el análisis de datos. (Wes, 2017)
Keras	2.3.1	Keras es una librería para crear arquitecturas de aprendizaje profundas, es una capa de flujo de tensor que es una librería más compleja. Está escrito de código abierto a Python; Diseñado para permitir una experimentación temporal con redes de aprendizaje profundo. Fue creado para ser una interfaz de aprendizaje automático. Contiene implementaciones de bloques de construcción de redes neuronales, como capas, objetos, funciones de activación, optimización matemática. (Keras io, 2020)
Python	3.7.7	Lenguaje de programación de código abierto, un buen lenguaje general y de alto nivel. Su diseño lo hace muy legible, lo cual es más importante de lo que parece. Cada programa de computadora está escrito solo una vez, pero lee y revisa varias veces, generalmente para muchas personas. Ser legible también facilita el aprendizaje y la memoria; Por lo tanto, más escrito. En comparación con otros idiomas

		populares, Python tiene una curva de aprendizaje fluido que la hace productiva antes, pero tiene profundidades que pueden explorar a medida que la experiencia adquiere experiencia. (Bill, 2019)
Image Resizer	3.1.1	Es una herramienta de Windows que le permite cortar, cambiar de tamaño y compactar las imágenes, modificar el tamaño sin perder la calidad de imagen.
Windows	10	OS

Fuente: Elaboración propia (2020)

3.2.2 Hardware

Tabla 2: Lista de Hardware usados

Hardware	Características
Laptop	Procesador i7 Memoria Ram 16 GB Tarjeta grafica 4GB
Camara digital fotográfica	14 MP

Fuente: Elaboración propia (2020)

3.3 Metodología de la investigación

Según la metodología Crisp DM se procedió de la siguiente manera:

3.3.1 Comprensión del negocio

Establecimiento de los objetivos del negocio

Según la investigación se tuvo como objetivo principal:

- Desarrollar un Aplicativo Web para la Identificación de Deficiencia de Zinc en naranjos mediante Redes Neuronales Convolucionales

3.3.2 Comprensión de los datos

En esta fase para comprender los datos que se tuvieron, se procedió a la Caracterización de la deficiencia de Zinc en las plantas de naranjo. Dicha fase se realizó con la ayuda de un Ingeniero Agrónomo especializado en el área de citricultura.

Descripción de los datos. Los datos con el que se contó son fotografías de imágenes de hojas de naranjo sanas, con deficiencia de zinc y para las pruebas también se contó con imágenes de hojas con deficiencia de manganeso, dichas imágenes fueron capturadas directamente en la planta teniendo en consideración las características físicas que tienen las hojas con deficiencia de estos nutrientes según las indicaciones del ingeniero agrónomo.

3.3.3 Preparación de los datos

Esta fase nos permitió reunir y recopilar un DataSet de imágenes de hojas de naranjo, tomados con una cámara de 14MP, para lo cual se contó con un total de 3000 imágenes de las cuales se definió clase 0 =1000 datos de hojas sanas, clase 1= 1000 de hojas con deficiencia de zinc y clase 2= 500 de hojas con deficiencia de manganeso.

3.3.4 Modelado

Esta fase se buscó un modelo pre entrenado que tenga más precisión para la identificación y clasificación de imágenes, el cual después de una evaluación se decidió por el modelo VGG16. Se hizo transfer learning utilizando este modelo en la construcción del algoritmo o modelo de identificación de red neuronal.

3.3.5 Evaluación

Para la evaluación se trabajó con 50 épocas para el entrenamiento del algoritmo contando con 64 datos de entrada de cada clase por épocas, de las cuales se pudo apreciar un 81.12% de exactitud y precisión en identificar cada clase.

3.3.6 Distribución

Como última fase se realizó y construyó una interfaz web para que el usuario tenga mejor visualización y mejor experiencia al momento de predecir.

3.4 Investigación Tecnológica

La investigación tecnológica no se limita al estudio de un fenómeno natural que existe en la naturaleza, sino a la creación de nuevas realidades que no existen, para este uso, el proceso de invención, innovación, diseño o desarrollo tecnológico. (Ingenium, 2016)

La investigación tecnológica es buscar conocimiento que pueda definirse como útil para problemas de apoyo y resolución. Esta resolución de problemas generalmente tiene la intención de mejorar la sociedad, mejorar los procesos activos y las convenciones tecnológicas.(Jonathan, 2018)

Debido a que esta investigación busca desarrollar una herramienta tecnológica que será de mucha ayuda para la sociedad en el ámbito de la citricultura, es que se optó por este tipo de investigación tecnológica.

3.4.1 Arquitectura de solución

La arquitectura se explica en la siguiente figura:

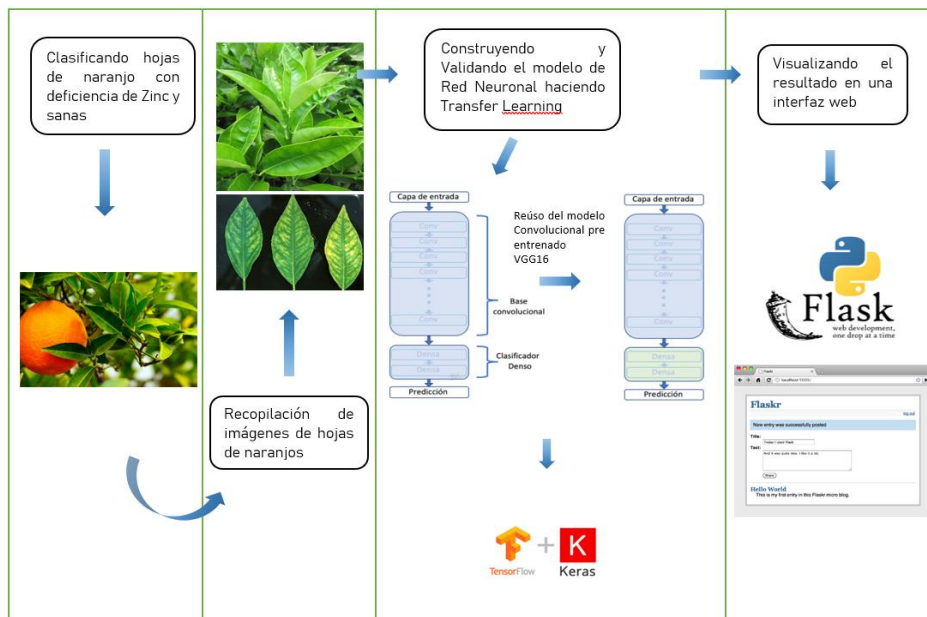


Figura 32: Arquitectura de solución
Fuente: Elaboración propia (2020).

Según la figura 32 se tiene la arquitectura de solución el cual se llevó a cabo en 4 fases:

- ✓ Como primera fase se tiene la clasificación de hojas de naranjo con deficiencia nutricional y hojas sanas, en el que se realizó un estudio de las características que presenta cada deficiencia nutricional en las plantas de naranjo.

- ✓ Después se obtuvieron los datos que fueron fotografías de hojas de naranjo con y sin deficiencias nutricionales.
- ✓ Seguidamente se construyó un modelo de red neuronal aplicando transfer learning y realizando una serie de pruebas para validar la funcionalidad del modelo.
- ✓ Finalmente se logró desarrollar una interfaz web en el que se pudo visualizar los resultados de identificación de la deficiencia de zinc mediante una imagen cualquiera de hojas de naranjo.

3.5 Desarrollo de la investigación

Parte de la investigación se desarrolló mediante la metodología basada en la investigación de (Tomas, 2019) para la clasificación de imágenes, el cual fue desarrollado para el reconocimiento automático de enfermedades foliares en cultivos de palta; se optó por esta metodología dado que tiene similitud a la presente, y además el proceso es de cómodo desarrollo para la ejecución de los objetivos.

Esta metodología consta de 4 etapas que serán descritas a continuación:

3.5.1 Etapa 1: Adquisición de Imágenes

En esta primera etapa se recolectaron las imágenes adecuadas, en buenas condiciones que nos permitan continuar con las siguientes etapas.

Una adquisición correcta de la imagen es un paso muy importante para que el proceso de reconocimiento tenga éxito. En esta etapa, hay varios factores que pertenecen directamente al proceso de captura de imágenes, formado principalmente por: el sistema de material de visión artificial (habitación, óptica, tarjeta de adquisición de imágenes, computadora y software) y el entorno y posicionamiento de elementos (iluminación, menor , posición correcta de la cámara, ruido eléctrico externo, etc.). (Tomas, 2019)

Para la adquisición de imágenes se utilizó una cámara de 14MP, y se tomaron 2500 imágenes de hojas de naranjo; 1000 de hojas sanas, 1000 con deficiencia de zinc y para realizar pruebas de validación también se contó con 500 imágenes con deficiencia de manganeso debido a que sus características físicas se parecen a la deficiencia de zinc.



Figura 33: Recolección de imágenes de hojas de naranjo
Fuente: Elaboración propia (2020)

3.5.2 Etapa 2: Preprocesamiento de Imágenes

Debido a que existen factores que podrían alterar la calidad de la imagen y además características que pueden sufrir alteraciones como, por ejemplo: ruido, pérdida de definición y fidelidad de la imagen; es necesario ajustar la imagen con el objetivo de prepararlas para el entrenamiento.

Para esta etapa también se utilizó la herramienta Image Resizer, para redimensionar las imágenes a un tamaño de 224 X 224, de tal manera se tengan todas las imágenes a un mismo tamaño.

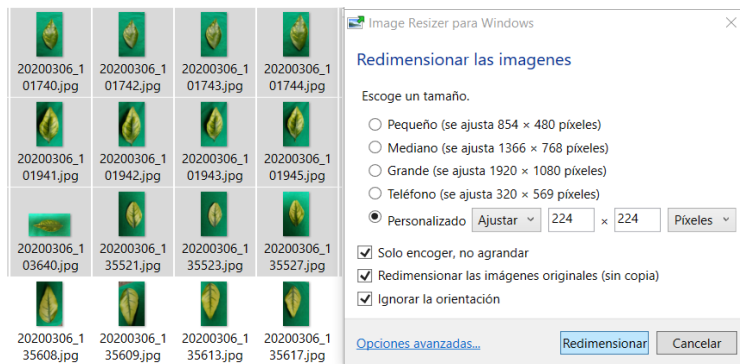


Figura 34: Redimensionando las imágenes con la herramienta Image Resizer
Fuente: Elaboración propia, 2020

3.5.2.1 Etapa 3: Extracción de características

En general, extracción de características recibe un objeto como entrada y devuelve una representación matemática del mismo en un espacio vectorial donde se conserven las

similitudes inherentes a dichos objetos. Este mismo enfoque también se aplica a las imágenes. (Tomas, 2019)

Con la ayuda de un especialista se extrajo las características de las imágenes, según los rasgos que muestra la deficiencia de zinc y manganeso; en el cual se visualiza como zonas amarillentas alrededor de los nervios secundarios de las hojas que acentúan sobre un fondo verdoso, y algunos dependiendo de la deficiencia nutricional volviéndose estrechas puntiagudas y aumentando el nivel de espesor de la hoja, Por lo que se procedió a clasificarlos por nivel de penetración de la deficiencia de zinc y manganeso respectivamente.




Figura 35: *Clasificación de hojas por penetración de deficiencia de zinc*
Fuente: Elaboración propia (2020)

En la figura 35 se muestra 5 tipos de clasificación de hojas el cual tiene el rango desde sin deficiencia hasta muy alto en deficiencia de zinc, mostrando el nivel de penetración de la deficiencia de zinc.



Figura 36: *Clasificación de hojas por nivel de penetración de la deficiencia de Manganeso*
Fuente: Elaboración propia (2020)

En la figura 36 se muestra 5 tipos de clasificación de hojas el cual tiene el rango desde sin deficiencia hasta muy alto, mostrando el nivel de penetración de la deficiencia de manganeso.

Una vez extraído las características más representativas de la imagen, se realiza el entrenamiento del algoritmo, introduciendo 1000 imágenes de hojas con deficiencia de Zinc, 500 imágenes de hojas con deficiencia de manganeso y 1000 imágenes de hojas sanas como inicio del entrenamiento para luego predecir si la imagen es una hoja sana o con alguna de estas 2 deficiencias nutricionales.

3.5.3 Etapa 4: Reconocimiento

Para realizar el reconocimiento o identificación se adiciono un modelo pre entrenado llamado VGG16 el cual mencionaremos detalladamente más adelante.

3.5.3.1 Preparación del entorno de trabajo

Para el desarrollo se hizo uso de la plataforma Anaconda. Para la instalación de esta plataforma de ciencia de datos podemos hacerlo desde su página web oficial: www.anaconda.com, en la parte de abajo visualizaremos las versiones disponibles para cada sistema operativo y procedemos a descargar; para este proyecto se utilizó la versión 1.9.12




Figura 37: Pagina de descarga de Anaconda
Fuente: (Anaconda Inc, 2020)

Ya descargado procedemos a instalar en nuestro ordenador teniendo en cuenta los permisos de usuario administrador, siguiendo los pasos de instalación donde podremos elegir la ruta donde se instalará.

Anaconda viene con una suite de herramientas graficas llamada Anaconda Navigator y trae la versión más reciente de Python. Anaconda Navigator permite trabajar con entornos virtuales independientes, en las cuales se pueden instalar librerías y complementos de diferentes versiones acorde a cada tipo de proyectos; para crear un entorno virtual y trabajar en él, desde la terminal usamos la siguiente línea de comandos:

```
$ conda create -n [ "nombre de entorno" ] anaconda python=[versión de python]
```

```
$ conda activate [ "nombre de entorno" ]
```

Así mismo fue necesario la instalación de Jupyter notebook, la cual lo hicimos desde la interfaz gráfica de anaconda o desde la terminal: `$ pip install jupyter`

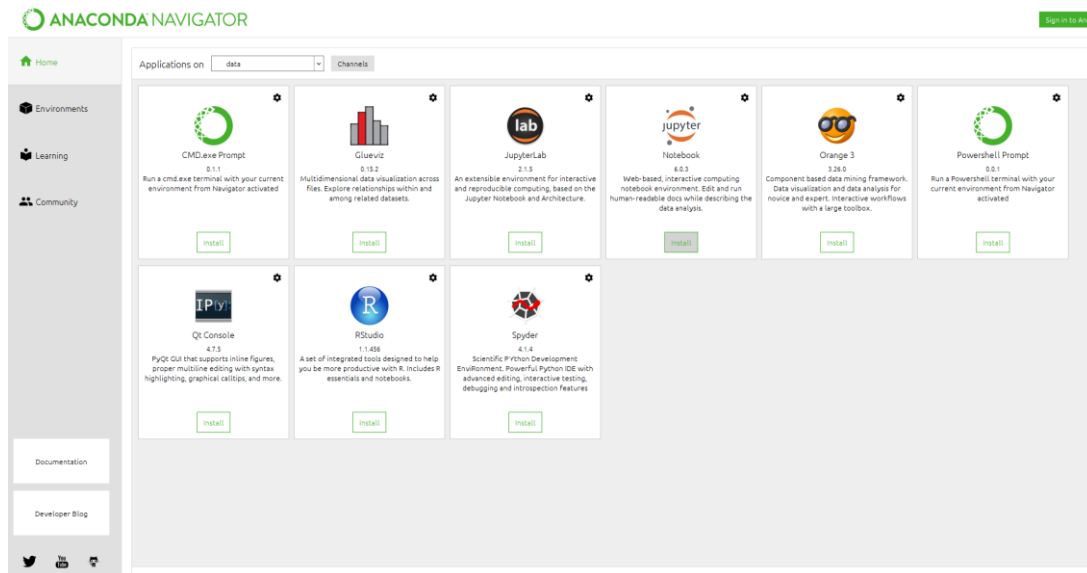


Figura 38: Interfaz principal de Anaconda Navigator

Fuente: Elaboración propia, 2020

Así mismo se instaló algunas librerías:

```
$ conda install tensorflow-gpu==2.1.0 cudatoolkit=10.1
```

```
$ pip install tensorflow==2.1.0
```

```
$ pip install keras==2.3.1
```

```
$ pip install numpy scipy Pillow cython matplotlib scikit-image opencv-python h5py imgaug IPython[all]
```

3.5.3.2 Construcción del modelo

3.5.3.2.1 Configuración de parámetros

```

width_shape = 224
height_shape = 224
num_classes = 3
epochs = 50
batch_size = 64

```

} tamaño de las imágenes
} Clase 0 =Hojas sanas
} Clase 1 =Deficiencia de Zinc
} Clase 2 = Deficiencia de manganeso
→ Épocas de entrenamiento
→ Numero de lote de entrenamiento

Figura 39: Configuración de parámetros para el entrenamiento
Fuente: Elaboración propia (2020)

Según la imagen figura 39, en los parámetros a considerar está el tamaño de imagen que como ya mencionamos es de 224x224, para esta investigación se tuvo 3 clases, donde como valor o clase 0 están las hojas con deficiencia de manganeso, clase1 las hojas que se encuentran con deficiencia de Zinc y clase 2 las hojas sanas; seguido está el número de épocas, el cual consideramos 50 donde serán entrenadas cada 64 imágenes (número de lote); Así mismo estas imágenes serán entrenadas utilizando la función ImageDataGenerator, en el que se le asignaron valores y rangos de rotación de todos los ángulos en 360°.

3.5.3.2.2 Transfer Learning

Para la transferencia de aprendizaje (Transfer Larning), utilizamos el modelo pre entrenado VGG16 dado que tiene las siguientes características a favor:

- Tiene una arquitectura fácil de comprender y, en su caso, de implementar.
- Logra un excelente resultado en la competencia ImageNet (ILSVRC-2014), entre el 96% y 97%.
- Contienen relativamente pocas capas convolucionales: 13 capas convolucionales y 3 densas, de ahí que en su nombre incluya el 16.
- La red (modelo y pesos entrenados) está disponible en Keras

Se realizo la importación en el modelo del proyecto mediante la siguiente línea:

```
model = VGG16(input_tensor=image_input, include_top=True, weights='imagenet')
```

A continuación, se muestra el entrenamiento del modelo de red neuronal convolucional:

Model: "model_1"

Layer (type)	Output Shape	Param #
=====		

input_1 (InputLayer)	(None, 224, 224, 3)	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
flatten (Flatten)	(None, 25088)	0
fc1 (Dense)	(None, 4096)	102764544
fc2 (Dense)	(None, 4096)	16781312
output (Dense)	(None, 3)	12291

=====
 Total params: 134,272,835
 Trainable params: 12,291
 Non-trainable params: 134,260,544

Epoch 1/50
 39/39 [=====] - 334s 9s/step - loss: 0.4609 - accuracy: 0.8247 - val_loss: 0.1229 - val_accuracy: 0.9688
 Epoch 2/50
 39/39 [=====] - 337s 9s/step - loss: 0.1440 - accuracy: 0.9470 - val_loss: 0.1660 - val_accuracy: 0.9435
 Epoch 3/50
 39/39 [=====] - 346s 9s/step - loss: 0.0986 - accuracy: 0.9639 - val_loss: 0.0311 - val_accuracy: 0.9848
 Epoch 4/50
 39/39 [=====] - 341s 9s/step - loss: 0.1001 - accuracy: 0.9643 - val_loss: 0.0315 - val_accuracy: 0.9907
 Epoch 5/50
 39/39 [=====] - 342s 9s/step - loss: 0.0656 - accuracy: 0.9791 - val_loss: 0.1518 - val_accuracy: 0.9562
 Epoch 6/50

39/39 [=====] - 351s 9s/step - loss: 0.0617 - accuracy:
0.9776 - val_loss: 0.1376 - val_accuracy: 0.9781
Epoch 7/50
39/39 [=====] - 337s 9s/step - loss: 0.0670 - accuracy:
0.9756 - val_loss: 0.0325 - val_accuracy: 0.9933
Epoch 8/50
39/39 [=====] - 346s 9s/step - loss: 0.0479 - accuracy:
0.9804 - val_loss: 0.0458 - val_accuracy: 0.9924
Epoch 9/50
39/39 [=====] - 338s 9s/step - loss: 0.0489 - accuracy:
0.9844 - val_loss: 0.0078 - val_accuracy: 0.9966
Epoch 10/50
39/39 [=====] - 340s 9s/step - loss: 0.0435 - accuracy:
0.9856 - val_loss: 0.0249 - val_accuracy: 0.9966
Epoch 11/50
39/39 [=====] - 343s 9s/step - loss: 0.0243 - accuracy:
0.9926 - val_loss: 0.0443 - val_accuracy: 0.9806
Epoch 12/50
39/39 [=====] - 346s 9s/step - loss: 0.0316 - accuracy:
0.9900 - val_loss: 0.0165 - val_accuracy: 0.9798
Epoch 13/50
39/39 [=====] - 345s 9s/step - loss: 0.0563 - accuracy:
0.9836 - val_loss: 0.0303 - val_accuracy: 0.9933
Epoch 14/50
39/39 [=====] - 351s 9s/step - loss: 0.0264 - accuracy:
0.9910 - val_loss: 0.0230 - val_accuracy: 0.9941
Epoch 15/50
39/39 [=====] - 345s 9s/step - loss: 0.0367 - accuracy:
0.9933 - val_loss: 0.0037 - val_accuracy: 0.9966
Epoch 16/50
39/39 [=====] - 363s 9s/step - loss: 0.0198 - accuracy:
0.9930 - val_loss: 0.0044 - val_accuracy: 0.9933
Epoch 17/50
39/39 [=====] - 372s 10s/step - loss: 0.0209 - accuracy:
0.9926 - val_loss: 0.0069 - val_accuracy: 0.9958
Epoch 18/50
39/39 [=====] - 368s 9s/step - loss: 0.0239 - accuracy:
0.9924 - val_loss: 0.0149 - val_accuracy: 0.9798
Epoch 19/50
39/39 [=====] - 358s 9s/step - loss: 0.0261 - accuracy:
0.9897 - val_loss: 0.0036 - val_accuracy: 0.9933
Epoch 20/50
39/39 [=====] - 354s 9s/step - loss: 0.0200 - accuracy:
0.9924 - val_loss: 0.0177 - val_accuracy: 0.9949
Epoch 21/50
39/39 [=====] - 367s 9s/step - loss: 0.0193 - accuracy:
0.9936 - val_loss: 0.0068 - val_accuracy: 0.9934
Epoch 22/50
39/39 [=====] - 359s 9s/step - loss: 0.0141 - accuracy:
0.9947 - val_loss: 0.0191 - val_accuracy: 0.9966
Epoch 23/50
39/39 [=====] - 350s 9s/step - loss: 0.0314 - accuracy:
0.9865 - val_loss: 0.0049 - val_accuracy: 0.9949
Epoch 24/50
39/39 [=====] - 345s 9s/step - loss: 0.0218 - accuracy:
0.9922 - val_loss: 0.0271 - val_accuracy: 0.9966
Epoch 25/50
39/39 [=====] - 350s 9s/step - loss: 0.0129 - accuracy:
0.9948 - val_loss: 0.0102 - val_accuracy: 0.9992
Epoch 26/50
39/39 [=====] - 358s 9s/step - loss: 0.0296 - accuracy:
0.9897 - val_loss: 0.0080 - val_accuracy: 0.9941
Epoch 27/50
39/39 [=====] - 377s 10s/step - loss: 0.0169 - accuracy:
0.9934 - val_loss: 0.0246 - val_accuracy: 0.9958
Epoch 28/50

39/39 [=====] - 364s 9s/step - loss: 0.0119 - accuracy:
0.9959 - val_loss: 0.0653 - val_accuracy: 0.9755
Epoch 29/50
39/39 [=====] - 347s 9s/step - loss: 0.0111 - accuracy:
0.9971 - val_loss: 0.0073 - val_accuracy: 0.9941
Epoch 30/50
39/39 [=====] - 334s 9s/step - loss: 0.0117 - accuracy:
0.9966 - val_loss: 0.0083 - val_accuracy: 0.9907
Epoch 31/50
39/39 [=====] - 373s 10s/step - loss: 0.0142 - accuracy:
0.9952 - val_loss: 0.0013 - val_accuracy: 0.9941
Epoch 32/50
39/39 [=====] - 375s 10s/step - loss: 0.0200 - accuracy:
0.9930 - val_loss: 0.0035 - val_accuracy: 0.9983
Epoch 33/50
39/39 [=====] - 370s 9s/step - loss: 0.0073 - accuracy:
0.9979 - val_loss: 0.0061 - val_accuracy: 0.9966
Epoch 34/50
39/39 [=====] - 355s 9s/step - loss: 0.0200 - accuracy:
0.9922 - val_loss: 0.0238 - val_accuracy: 0.9899
Epoch 35/50
39/39 [=====] - 352s 9s/step - loss: 0.0117 - accuracy:
0.9959 - val_loss: 0.0032 - val_accuracy: 0.9916
Epoch 36/50
39/39 [=====] - 352s 9s/step - loss: 0.0094 - accuracy:
0.9979 - val_loss: 0.0094 - val_accuracy: 0.9975
Epoch 37/50
39/39 [=====] - 353s 9s/step - loss: 0.0100 - accuracy:
0.9975 - val_loss: 0.0158 - val_accuracy: 0.9933
Epoch 38/50
39/39 [=====] - 352s 9s/step - loss: 0.0069 - accuracy:
0.9979 - val_loss: 0.0021 - val_accuracy: 0.9992
Epoch 39/50
39/39 [=====] - 352s 9s/step - loss: 0.0317 - accuracy:
0.9881 - val_loss: 0.0015 - val_accuracy: 0.9958
Epoch 40/50
39/39 [=====] - 353s 9s/step - loss: 0.0119 - accuracy:
0.9947 - val_loss: 0.0032 - val_accuracy: 0.9958
Epoch 41/50
39/39 [=====] - 354s 9s/step - loss: 0.0038 - accuracy:
0.9996 - val_loss: 0.0070 - val_accuracy: 0.9967
Epoch 42/50
39/39 [=====] - 353s 9s/step - loss: 0.0119 - accuracy:
0.9955 - val_loss: 0.0010 - val_accuracy: 0.9958
Epoch 43/50
39/39 [=====] - 352s 9s/step - loss: 0.0101 - accuracy:
0.9967 - val_loss: 0.0022 - val_accuracy: 0.9975
Epoch 44/50
39/39 [=====] - 352s 9s/step - loss: 0.0085 - accuracy:
0.9975 - val_loss: 0.0036 - val_accuracy: 0.9975
Epoch 45/50
39/39 [=====] - 352s 9s/step - loss: 0.0077 - accuracy:
0.9984 - val_loss: 0.0109 - val_accuracy: 0.9992
Epoch 46/50
39/39 [=====] - 358s 9s/step - loss: 0.0083 - accuracy:
0.9984 - val_loss: 0.0017 - val_accuracy: 0.9983
Epoch 47/50
39/39 [=====] - 346s 9s/step - loss: 0.0115 - accuracy:
0.9962 - val_loss: 0.0060 - val_accuracy: 0.9992
Epoch 48/50
39/39 [=====] - 357s 9s/step - loss: 0.0164 - accuracy:
0.9928 - val_loss: 0.0017 - val_accuracy: 0.9992
Epoch 49/50
39/39 [=====] - 352s 9s/step - loss: 0.0059 - accuracy:
0.9984 - val_loss: 1.5357e-04 - val_accuracy: 0.9975
Epoch 50/50

39/39 [=====] - 345s 9s/step - loss: 0.0114 - accuracy: 0.9954 - val_loss: 0.0123 - val_accuracy: 0.9992

3.5.3.3 Desarrollo de interfaz web

Para el desarrollo de interfaz web se utilizó el micro Framework Flask el cual permite tener una mejor visualización para el reconocimiento de la deficiencia de Zinc

➤ Instalación del micro Framework

Se realizó la instalación desde la terminal mediante `pip install flask==1.1.2` así mismo se requirió la importación desde keras:

```
from __future__ import division, print_function
# Keras
from keras.models import load_model
from keras.applications.imagenet_utils import preprocess_input
# Flask
from flask import Flask, request, render_template
from werkzeug.utils import secure_filename
import os
import numpy as np
import cv2
```

Figura 40: Importación para construir interfaz web con Flask
Fuente: Elaboración propia (2020)

CAPÍTULO IV. Resultados y discusión

4.1 Resultado del objetivo 1: Caracterizar la Deficiencia de Zinc en naranjos

Para la realización de este objetivo se caracterizó la deficiencia de Zinc mediante la adquisición de imágenes donde se recolectaron imágenes en buenas condiciones, realizando un trabajo de campo.

Con la ayuda de un ingeniero Agrónomo se procedió a la identificación visual de las hojas deficientes y sanas. Donde se pudieron extraer características de color, tamaño, forma que influyen en la hoja causada por la deficiencia de Zinc y Manganese y así clasificarlas. En la figura 41 se muestran los resultados obtenidos en la clasificación de las imágenes.



Figura 41: Clasificación de imágenes de hojas de naranjo

Fuente: Elaboración propia (2020)

4.2 Resultado del objetivo 2: Recopilar un Data set de imágenes de hojas de naranjos

En este objetivo se recopiló un Data Set de imágenes de hojas de naranjo con deficiencia de Zinc, con deficiencia de Manganese y hojas sanas en el que se realizó reprocesamiento de imágenes y Extracción de características, identificando si las hojas están sanas o con deficiencia de zinc o manganese. Se crearon 3 directorios: pruebas, entrenamiento y validación. Dicho DataSet se puede encontrar en el siguiente repositorio de github <https://github.com/lizceth/IDdeficienciasNaranjo/tree/master/dataset>




Figura 42: Etiquetando y clasificando el Data Set
Fuente: Elaboración propia (2020)

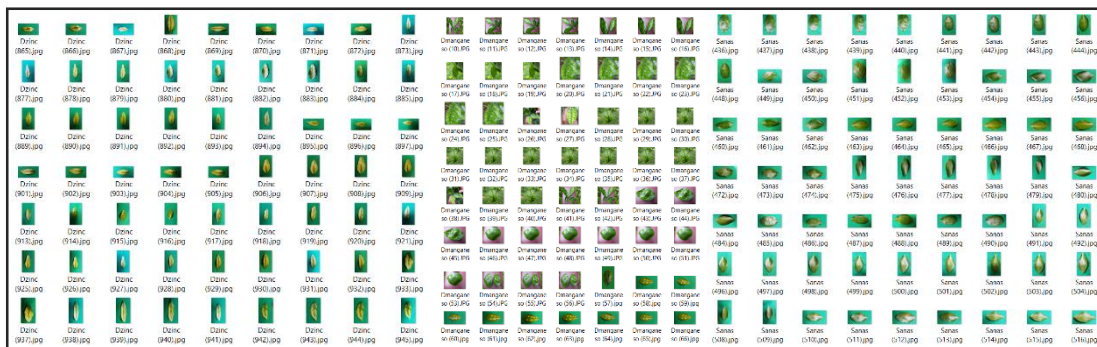


Figura 43: Data recolectada por cada directorio
Fuente: Elaboración propia (2020)

4.3 Resultado del objetivo 3: Construir y validar el modelo de Red Neuronal Convocional

En este objetivo se realizó Transfer Learning y se Reuso el modelo preentrenado VGG16 el cual después de su entrenamiento se logró los siguientes resultados de precisión. El modelo se puede encontrar en el siguiente repositorio de Google Drive: <https://drive.google.com/drive/u/1/folders/1OuiCB8x2QyWiRLCrIWNRtiOZLBMWduVf>

	precision	recall	f1-score	support
0	0.8617	0.8720	0.8668	250
1	1.0000	0.6060	0.7547	500
2	0.7104	0.9860	0.8258	500
accuracy			0.8112	1250
macro avg	0.8573	0.8213	0.8158	1250
weighted avg	0.8565	0.8112	0.8055	1250

Figura 44: Matriz de confusión, datos de precisión del modelo de red neuronal convocional

Fuente: Elaboración propia (2020)

Ahora que ya tenemos nuestro modelo entrenado se puso a prueba dicho modelo, para lo cual se necesitó un conjunto de datos de prueba para construir la Matriz de Confusión, en la figura 44 que como resultado pudimos ver que de la clase 0 que son las hojas de naranjo con deficiencia de Manganeso se tuvo una precisión del 86% y esto supone que hay una buena predicción de la clase, seguido la clase 1 son las hojas de naranjo con deficiencia de Zinc se tiene un 100% de precisión es porque no tenemos falsos negativos por ende nuestro modelo no detecta la clase muy bien, pero cuando lo hace es altamente confiable, esto debido a que se podría mejorar el modelo colocando más diversidad de imágenes y en distintas circunstancias, y con la clase 2 que son las hojas de naranjo sanas podemos ver que tenemos una precisión del 71% esto nos quiere decir que nuestro algoritmo detecta bien la clase, pero también incluye muestras de las otras clases. Así se puede tener mejor visualización mediante la siguiente figura.

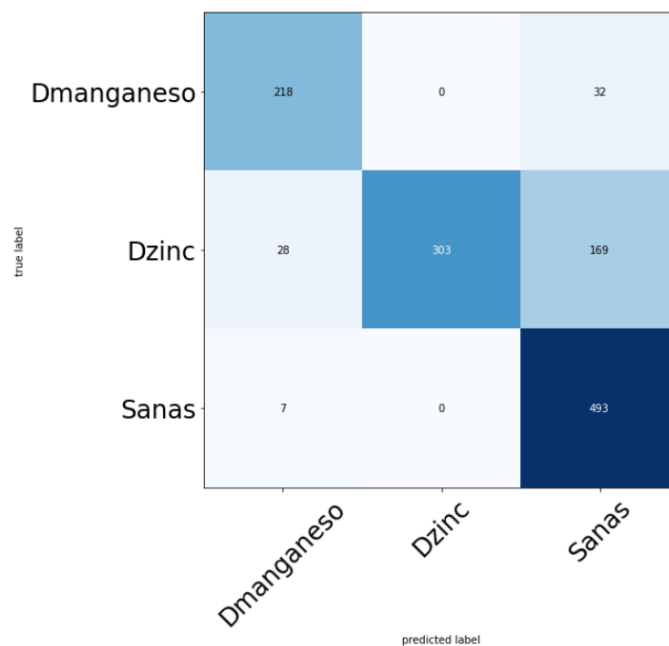


Figura 45: Matriz de confusión - validación del modelo
Fuente: Elaboración propia (2020)

De la matriz de confusión en la figura 45 se puede determinar que, de las 1250 imágenes de entrada, 250 corresponden a hojas con deficiencia de manganeso, 500 de deficiencia de zinc y 500 hojas sanas, de las cuales, según resultados que muestra la gráfica, se tuvo precisión de 493 que corresponden a hojas sanas, 218 datos que corresponden a hojas con deficiencia

de manganeso, 303 datos fueron reconocidos como deficiencia de zinc, no obstante, se tienen 236 datos que no tuvieron precisión en el reconocimiento.

4.3.1 Graficas de los resultados de validación

Datos de perdida: la figura 46 muestra que los datos de perdida están presentes hasta la época 20, así mismo desde esta época va disminuyendo, estabilizándose con más fuerza desde la época 30 a la 50.




Figura 46: Datos de perdida
Fuente: Elaboración propia (2020)

Datos de Precisión: En la siguiente figura (47) muestra los datos de exactitud o de precisión, el cual se visualiza como la línea roja donde incrementa a partir de la época 30 y posterior a esta existe mejor precisión.




Figura 47: Datos de Precisión
Fuente: Elaboración propia (2020)

Se realizo un Testing de validación por consola con el objetivo de verificar que el modelo entrenado en realidad predice y sabiendo esto no tendremos problemas al momento de integrar con la interfaz web, el siguiente resultado se muestra en la figura 48.

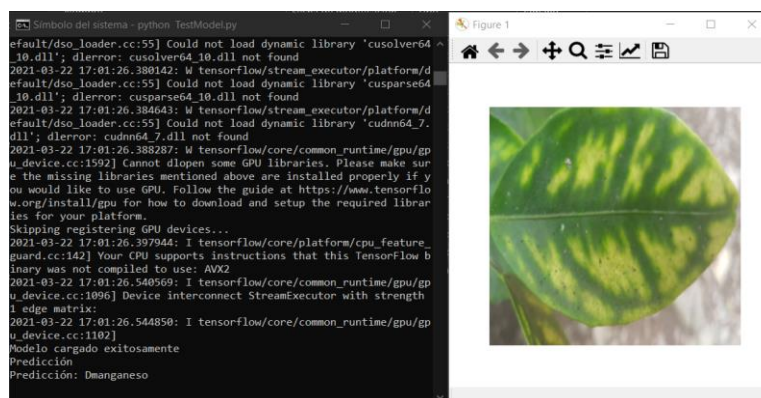
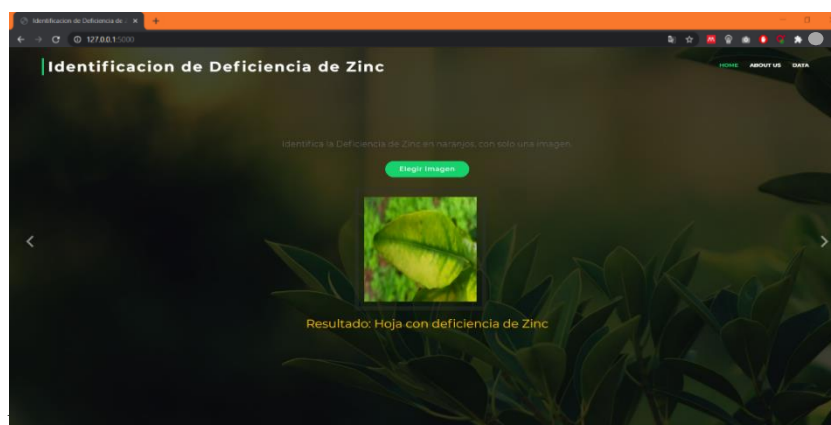


Figura 48: Resultados de testing y validación del modelo por consola
Fuente: Elaboración propia (2020)

Para ejecutar el archivo de Testing del modelo por consola, se cargó una imagen de una hoja con deficiencia de manganeso, seguido se ejecutó el archivo de testing el cual en los resultados que muestra en consola la predicción es una hoja con deficiencia de manganeso, lo cual es correcto.

4.4 Resultado del objetivo 4: Desarrollar una interfaz web para mejor visualización para el usuario

En este objetivo se logró desarrollar una interfaz web con el Micro FrameWork Flask; donde se carga una imagen y accederemos al botón de predicción, seguido nos muestra si la imagen corresponde a una hoja sana o hoja con deficiencia de Zinc. Dicha aplicación se encuentra en el siguiente repositorio de github: <https://github.com/lizceth/IDdeficienciasNaranja>



Fuente: Elaboración propia (2020)

CAPÍTULO V. Conclusiones y recomendaciones.

5.1 Conclusiones

Que la deficiencia de zinc en los naranjos es un problema recurrente en la región cusco, y su afectación a la planta reduce la producción, perjudicando al agricultor económicamente.

Que para una mejor precisión e identificación se deben contar con una gran cantidad de datos para el entrenamiento del modelo y/o algoritmo. Considerando que las imágenes capturadas cuenten con una iluminación adecuada.

Que el modelo pre entrenado VGG16 fue optimo en la precisión de la identificación de la deficiencia de zinc con un total de 81.12% de precisión. Su uso fue de considerable refuerzo para llevar a cabo la predicción.

Finalmente concluiremos con el logro de desarrollo de esta herramienta útil para el agricultor el cual le permitirá tener un mejor control de sus cultivos frente a las deficiencias nutricionales que pueda tener.

5.2 Recomendaciones

Se recomienda seguir desarrollando investigaciones que involucren el desarrollo de innovaciones tecnológicas en inteligencia artificial, para ser aplicadas en el ámbito de la agricultura.

Se recomienda también que a futuro se desarrolle y amplié esta herramienta a fin que permitan realizar un amplio diagnóstico de enfermedades y deficiencias de todos los nutrientes en las plantas.

Finalmente se recomienda como un futuro trabajo tener esta plataforma en un aplicativo móvil a fin de sea más práctico y accesible para el agricultor.

REFERENCIAS

2-6 . *Síntomas Visuales de Deficiencias Nutricionales (Diagnóstico Visual)*. (2015).

Alejandro Reategui Pezo, M. A. V. M. (2018). Aplicacion informatica para reconocimiento de la especie de camu camu (*Myrciaria Dubia*)a travez de redes neuronales convolucionales, iquitos peru. *Director*, 15(2), 2017–2019. [https://www.uam.es/gruposinv/meva/publicaciones_jesus/capitulos_espanyol_jesus/2005_motivacion para el aprendizaje Perspectiva alumnos.pdf%0Ahttps://www.researchgate.net/profile/Juan_Aparicio7/publication/253571379_Los_estudios_sobre_el_cambio_conceptual_](https://www.uam.es/gruposinv/meva/publicaciones_jesus/capitulos_espanyol_jesus/2005_motivacion_para_el_aprendizaje_Perspectiva_alumnos.pdf%0Ahttps://www.researchgate.net/profile/Juan_Aparicio7/publication/253571379_Los_estudios_sobre_el_cambio_conceptual_)

Amezcu Romero, J. C., & Lara Flores, M. (2017). El Zinc en las Plantas. *Ciencia*, 68(3), 28–35. <http://www.smart-fertilizer.com/es/articulos/zinc-in-plants>

Anaconda Inc. (2020). *Anaconda | Press Noticias de Anaconda*. <https://www.anaconda.com/press>

Aplican inteligencia artificial en la detección de HLB en cítricos | Revista RIA. (n.d.). Retrieved October 6, 2020, from <http://ria.inta.gob.ar/contenido/aplican-inteligencia-artificial-en-la-deteccion-de-hlb-en-citricos>

AVALOS, E. E. (2018). *Predicción de agentes patógenos en plantas ornamentales utilizando redes neuronales*. <http://dspace.itcolima.edu.mx/handle/123456789/1235>

Bendemra, H. (2018). *Construye tu primer clasificador de Deep Learning con TensorFlow: Ejemplo de razas de perros | by Hamza Bendemra, Ph.D. | Ciencia y Datos | Medium*. Hamza Bendemra Ph.D. <https://medium.com/datos-y-ciencia/construye-tu-primer-clasificador-de-deep-learning-con-tensorflow-ejemplo-de-razas-de-perros-ed218bb4df89>

Bill, L. (2019). *Presentamos Python, segunda edicion* (Segunda ed). O'Reilly Media, Inc. <https://learning.oreilly.com/library/view/introducing-python-2nd/9781492051374/ch01.html#idm45795028571560>

Bootcamp AI. (2019, November 14). *Redes neuronales. Programa de Visión... | by Bootcamp AI | Medium*. <https://bootcampai.medium.com/redes-neuronales->

13349dd1a5bb

- Browenlee, J. (2016, June 20). *Regularización de abandonos en modelos de aprendizaje profundo con Keras*. <https://machinelearningmastery.com/dropout-regularization-deep-learning-models-keras/>
- Cifuentes, A., Mendoza, E., Lizcano, M., Santrich, A., & Moreno Trillos, S. (2019). Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes Development. *Open Access*, 10(2), 7–17.
- DANE. (2016). El cultivo de la naranja Valencia (Citrus sinensis [L .] Osbeck) y su producción como respuesta a la aplicación de correctivos y fertilizantes y al efecto de la polinización dirigida con abeja Apis mellifera. *Insumos y Factores Asociados a La Producción Agropecuria*, 52, 1–12.
- Deficiencias nutritivas en los cítricos*. (2016). <https://boletinagrario.com/f785,deficiencias-nutritivas-citricos.html>
- Digg Data. (2015). *Project management for Data Science projects*. <https://digdata.in/post/129903266636/project-management-for-data-science-projects>
- Dipanjan, S. R. T. G. (2018). *CRISP-DM: aprendizaje práctico de transferencia con Python*. <https://learning.oreilly.com/library/view/hands-on-transfer-learning/9781788831307/7e31accb-a94b-4005-99d3-c3894fe7eed1.xhtml>
- Durán Suárez, J., & Del Real Torres, A. (2017). *Redes Neuronales Convolucionales en R Reconocimiento de caracteres escritos a mano Redes Neuronales Convolucionales en R Reconocimiento de caracteres escritos a mano Redes Neuronales Convolucionales en R*. 78. <http://bibing.us.es/proyectos/abreproy/91338/fichero/TFG+Jaime+Durán+Suárez.pdf>
- Galán Cotrina, V. (2015). *CRISP-DM A UN PROYECTO DE MINERÍA*.
- García Gazabón, G. I. (2014). *TESIS DE GRADO GISELA GARCIA GAZABÓN Modelo de Machine Learning para la Clasificación de pacientes en términos del nivel asistencial requerido en una urgencia pediátrica con Área de Cuidados Mínimos*. UNIVERSIDAD TECNOLÓGICA DE BOLÍVAR.

- Gob.pe. (2020). *plataforma digital unica del estado peruano*. <https://www.gob.pe/senasa>
- Google Developers. (2020, February 10). *Redes neuronales de clases múltiples: Softmax*. <https://developers.google.com/machine-learning/crash-course/multi-class-neural-networks/softmax?hl=es>
- Imagenet ILSVRC. (2015). *Concurso de reconocimiento visual a gran escala de ImageNet (ILSVRC)*. <http://www.image-net.org/challenges/LSVRC/>
- Ingenium, R. (2016). *Metodología de la investigación tecnológica en ingeniería*. 1(1), 43–46.
- Insumos, D. D. E., & Inocuidad, A. E. (n.d.). *IMPLEMENTACIÓN DE BUENAS PRÁCTICAS AGRÍCOLAS (BPA)*.
- Intagri S.C. (2014). *Nutrición de Cultivos con Zinc | Intagri S.C.* <https://www.intagri.com/articulos/nutricion-vegetal/nutricion-cultivos-zinc>
- Intelligent. (2018, January 3). *Deep learning & Convolutional Neuronal Network: qué es y en qué consiste*. <https://itelligent.es/es/deep-learning-convolutional-neuronal-network-cnn-consiste/>
- Jonathan, L. (2018). *No Title*. economipedia.com
- Jupyter Org. (2020, October 21). *Project Jupyter | Installing the Jupyter Software*. <https://jupyter.org/install>
- Keras io. (2020). *About Keras*. <https://keras.io/about/>
- Kunal, R. (2019). *1. Comenzando con Flask - Creación de API REST con Flask: Cree servicios web Python con MySQL*. https://learning.oreilly.com/library/view/building-rest-apis/9781484250228/A479840_1_En_1_Chapter.html
- Lopez Mendoza Marvin. (2020, August 9). *Lenguajes de programación más utilizados en 2020 | OpenWebinars*. <https://openwebinars.net/blog/lenguajes-de-programacion-mas-utilizados-en-2020/>
- Luis, L. (2019, February 10). *Machine learning con TensorFlow y Keras en Python*.

<https://www.luisllamas.es/machine-learning-con-tensorflow-y-keras-en-python/>

M. Reese, R. G. A. L. R. J. (2017). *CRISP-DM - Java: ciencia de datos simplificada*. Packt Publishing.

<https://learning.oreilly.com/library/view/java-data-science/9781788475655/34ad88d7-b555-47c8-84a2-3aeffa31c6f2.xhtml>

Matplotlib: Python plotting — Matplotlib 3.3.2 documentation. (n.d.). Retrieved October 23, 2020, from <https://matplotlib.org/>

Mehdipour Ghazi, M., Yanikoglu, B., & Aptoula, E. (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235(August 2016), 228–235. <https://doi.org/10.1016/j.neucom.2017.01.018>

Melo Chura, A. D. (2018). *Universidad nacional del altiplano*.

MINAGRI. (2018). Compendio estadístico del Perú. *Agrario*, 88.

Montes, S. (2018). *Estudio de métodos para identificar signos de retinopatía diabética en imágenes de fondo del ojo*. 90. https://cicese.repositorioinstitucional.mx/jspui/bitstream/1007/2071/1/tesis_Montes_Fuentes_Selene_22_feb_2018.pdf

Muneeb ul Hassan. (2018, October 20). *VGG16 - Red convolucional para clasificación y detección*. <https://neurohive.io/en/popular-networks/vgg16/>

Muñoz, J. D. (2017, October 17). *Qué es Flask y ventajas que ofrece | OpenWebinars*. <https://openwebinars.net/blog/que-es-flask/>

Noren, A. (2019, June 22). *ReLU: Funciones de activación - sitiobigdata.com*. <https://sitiobigdata.com/2019/06/22/relu-funciones-activacion/#>

P-salazar, J., Sánchez-delacruz, E., & Biswal, R. R. (2018). *Clasificación de clorosis en hojas de árboles de naranja mediante aprendizaje automático Classification of Chlorosis in Leaves of Orange Trees Using Machine Learning*. 147(5), 185–195.

Peru, F. F. (n.d.). *Exportaciones de naranja crecieron 11% durante la campaña 2019 – Fresh Fruit Perú*. Retrieved October 21, 2020, from <https://www.freshfruit.pe/2019/11/16/exportaciones-de-naranja-crecieron-11-durante->

la-campana-2019/

Red Neuronal Convolutacional CNN - Diego Calvo. (2017). <https://www.diegocalvo.es/red-neuronal-convolutacional/>

Requena, K. E., Rozo, D. M., & Arévalo, J. E. (2017). Principios y características de las redes neuronales artificiales. *Desarrollo e Innovación En Ingeniería, March 2019*, 173–183. https://www.researchgate.net/profile/Edgar_Serna_M/publication/331385353_Desarrollo_e_innovacion_en_ingenieria_ed_2/links/5c76e4ce92851c69504663b5/Desarrollo-e-innovacion-en-ingenieria-ed-2.pdf#page=379

Restrepo Salazar, Juan Camilo; Sanchez Lopez, Ricardo; Gallego Beltran, Juan Fernando; Beltrán Ospina, Teresita; Soto Rave, Carlos Alberto; Nieto Solorzano, F. (2012). *Manejo Fitosanitario del cultivo de citricos.*

Rivera, M. (2019, March). *Reeuso de Redes Preentrenadas.* http://personal.cimat.mx:8181/~mrivera/cursos/aprendizaje_profundo/preentrenadas/preentrenadas.html

Rodríguez, I. (2018). *TEMA : APLICACIÓN DE NUTRIENTES FOLIARES EN LOS ESTADOS FENOLÓGICOS DEL CULTIVO DE MORA (Rubus glaucus Benth) EN LA GRANJA EXPERIMENTAL PÍLLARO. 72.*

Rodríguez, V. A., Brunetti, S. C. C., Martínez, G. C., Chabbal, M. D., & Mazza, M. (2014). Fertilización Foliar Con Zinc Y Manganeso En Huertos De Naranja ‘Valencia Late.’ *Cultivos Tropicales*, 35(4), 100–105.

Senasa. (2018). *Que es Senasa.* <https://www.senasa.gob.pe/senasa/que-es-senasa/#:~:text=El Servicio Nacional de Sanidad,Producción Orgánica e Inocuidad agroalimentaria...>

SENASA. (2017). *Senasa certifica más de mil toneladas de naranja con destino a Costa Rica - SENASA al día.* <https://www.senasa.gob.pe/senasacontigo/senasa-certifica-mas-de-mil-toneladas-de-naranja-con-destino-costa-rica/>

Singh Ranjeet. (2019, June 8). *Computer Vision — An Introduction | by Ranjeet Singh | Towards Data Science.* <https://towardsdatascience.com/computer-vision-an->

introduction-bbc81743a2f7

TensorFlow Org. (2020). *TensorFlow*. <https://www.tensorflow.org/>

Terralia, I. A. (2018). *Terralia Informacion agricola : ZINC 5%. L:cítricos: en cítricos Agroquímicos de México*. https://www.terralia.com/agroquimicos_de_mexico/view_composition?book_id=3&composition_id=14975&crop_id=769

Tesis Inteligencia Artificial. (2017). <https://es.calameo.com/read/0051074327b779c4a67ad>

Tomas, C. A. G. (2019). *Aplicacion de algoritmos inteligentes para reconocimiento automatico de enfermedades foliares de cultivo de palta*. 052, 1–75.

Torres, J. (2019, September 8). *Data Augmentation y Transfer Learning con Keras / TensorFlow 2.0*. <https://torres.ai/data-augmentation-y-transfer-learning-en-keras-tensorflow/>

VALDERRAMA MOLANO, J. A. (2017). *CLASIFICACIÓN DE OBJETOS USANDO APRENDIZAJE PROFUNDO IMPLEMENTADO EN UN SISTEMA EMBEBIDO*. 13–14.

Wei, J. (2019, July 2). *AlexNet: la arquitectura que desafió a las CNN | de Jerry Wei | Hacia la ciencia de datos*. <https://towardsdatascience.com/alexnet-the-architecture-that-challenged-cnns-e406d5297951>

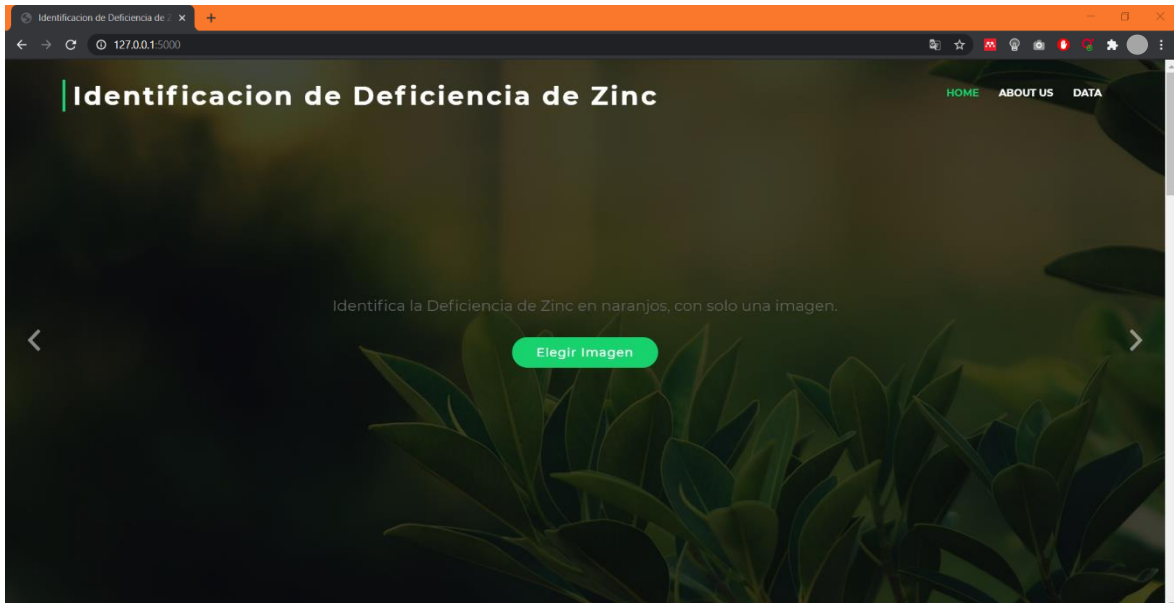
Wes, M. (2017). *Python para analisis de datos, segunda edicion*. O'Reilly Media, Inc. <https://learning.oreilly.com/library/view/python-for-data/9781491957653/>

Wikipedia Org. (2020, August 14). *Visión artificial*. https://es.wikipedia.org/wiki/Visión_artificial

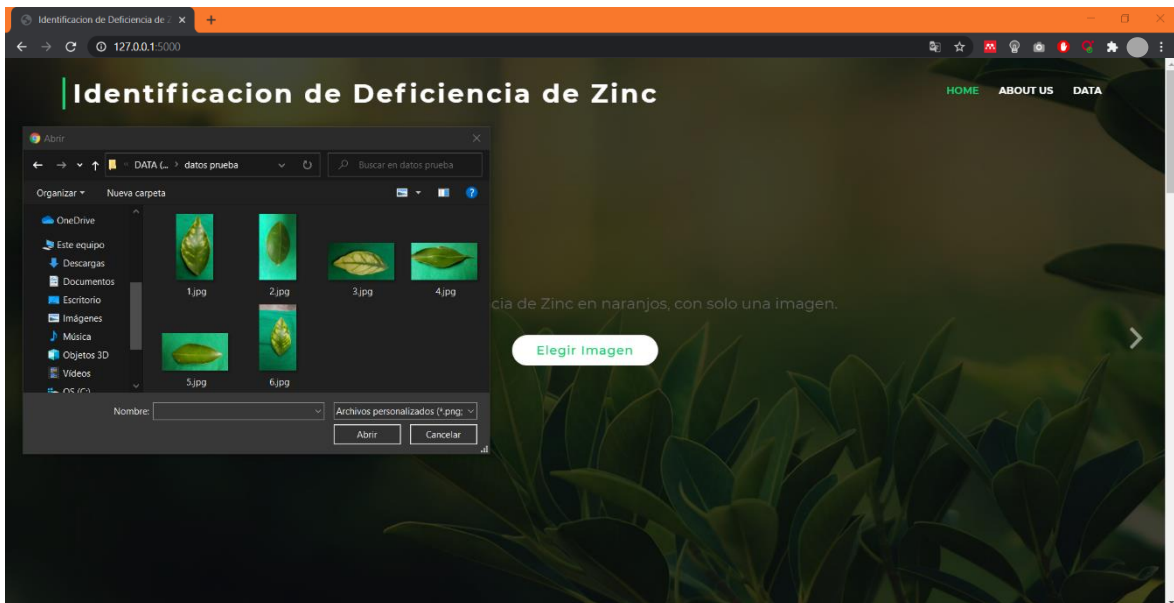
Zinc en la producción de cítricos | Yara Perú. (2019). <https://www.yara.com.pe/nutricion-vegetal/citricos/zinc-en-la-produccion-de-citricos/>

ANEXOS

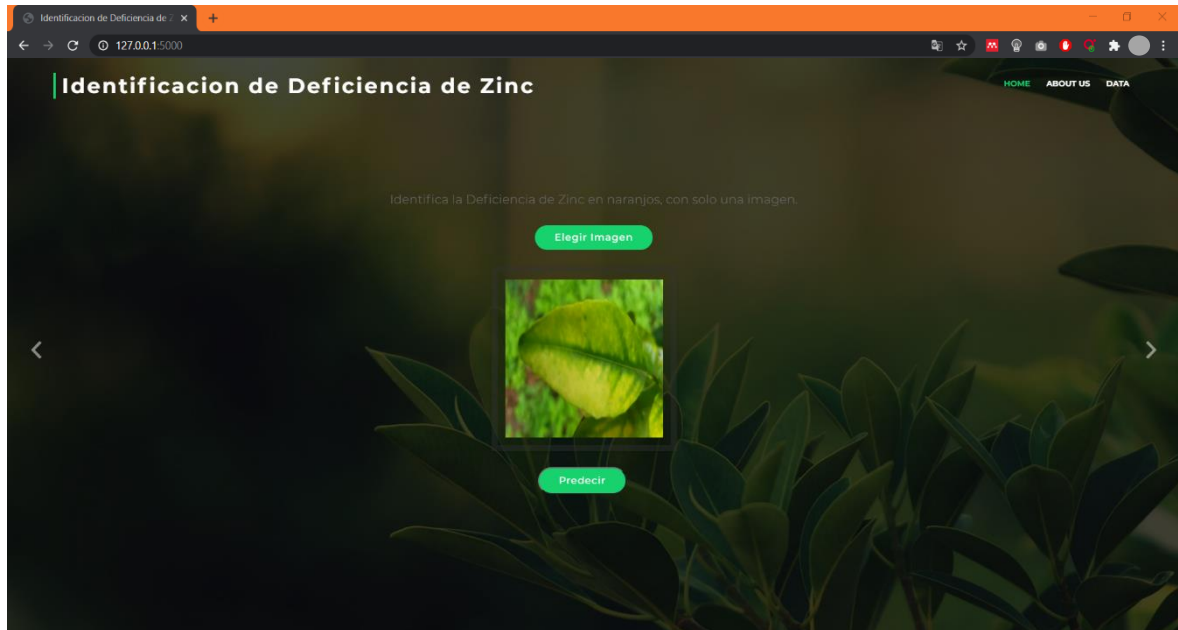
Anexo A: Pantalla principal del aplicativo web



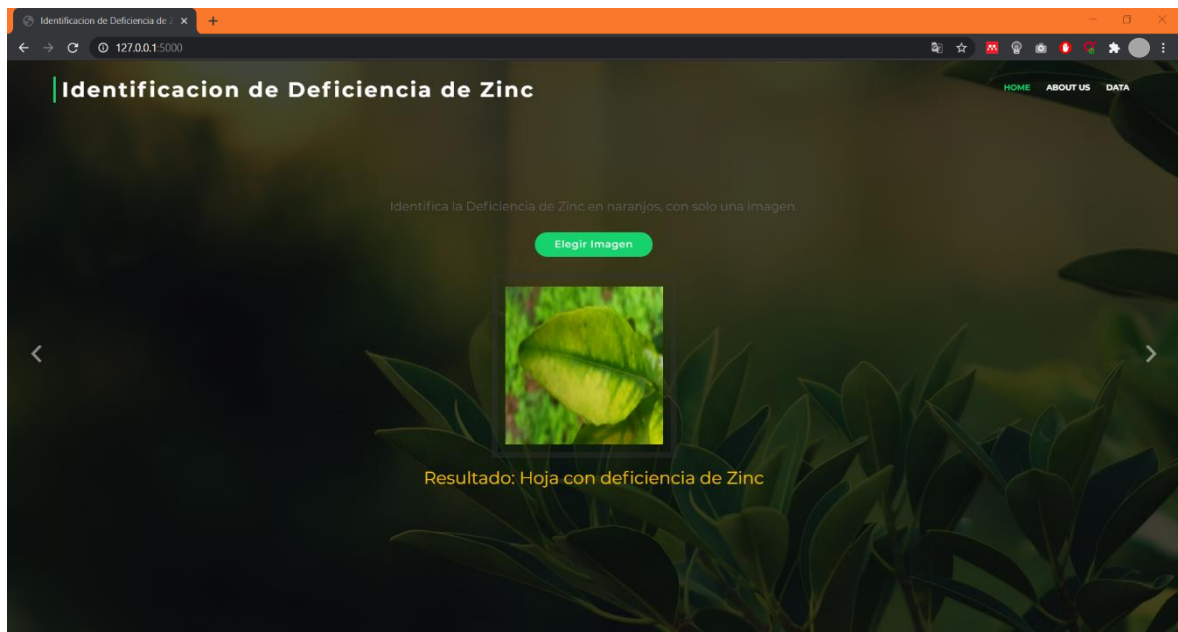
Anexo B: Pantalla de selección de archivo a identificar o predecir.



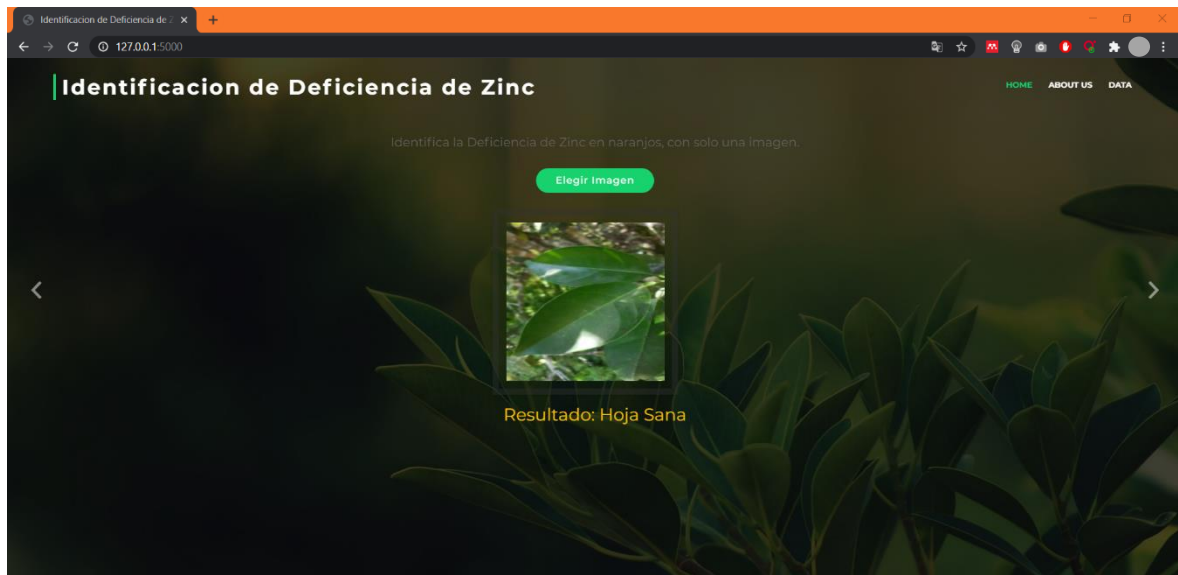
Anexo C: Interfaz para la identificación de la imagen ingresada.



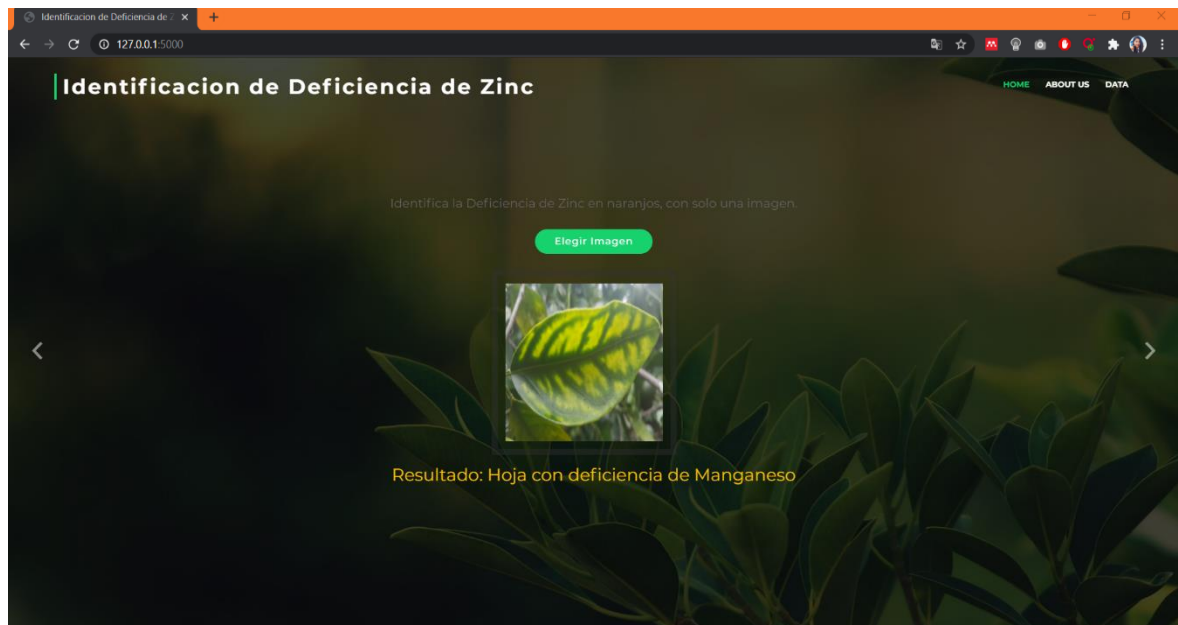
Anexo D: Interfaz en el que se muestra los resultados de la identificación que corresponde a una hoja con deficiencia de zinc.



Anexo E: Interfaz en el que se muestra los resultados de la identificación que corresponde a una hoja sana.



Anexo F: Interfaz en el que se muestra los resultados de la identificación que corresponde a una hoja con deficiencia de Manganeso.



Anexo G: Trabajo de campo con el Ingeniero Agrónomo en la identificación visual de hojas con deficiencias nutricionales.

