

**FACULTAD DE INGENIERÍA, ARQUITECTURA Y
URBANISMO ESCUELA PROFESIONAL DE INGENIERÍA
DE SISTEMAS**

TESIS

**Método de clasificación automática para defectos
externos con actualización manual de solanum phureja
para las exigencias de percepción de calidad**

**PARA OPTAR EL TÍTULO PROFESIONAL DE
INGENIERA DE SISTEMAS**

Autor (es)

Bach. Ruiz Santa Cruz Yovanny Floribel

[ORCID: https://orcid.org/0000-0003-2678-6163](https://orcid.org/0000-0003-2678-6163)

Bach. Sánchez Torres María Rojana

[ORCID: https://orcid.org/0000-0002-4826-5820](https://orcid.org/0000-0002-4826-5820)

Asesor(a)

Mg. Asenjo Carranza Enrique David

[ORCID: https://orcid.org/0000-0001-9705-5347](https://orcid.org/0000-0001-9705-5347)

Línea de Investigación

Infraestructura, Tecnología y Medio Ambiente

Pimentel – Perú

2024

**MÉTODO DE CLASIFICACIÓN AUTOMÁTICA PARA DEFECTOS EXTERNOS
CON ACTUALIZACIÓN MANUAL DE SOLANUM PHUREJA PARA LAS
EXIGENCIAS DE PERCEPCIÓN DE CALIDAD**

Aprobación del jurado

DR. ATALAYA URRUTIA CARLOS WILLIAM

Presidente del Jurado de Tesis

MG. BANCES SAAVEDRA DAVID ENRIQUE

Secretario del Jurado de Tesis

MG. ASENJO CARRANZA ENRIQUE DAVID

Vocal del Jurado de Tesis



DECLARACIÓN JURADA DE ORIGINALIDAD

Quien(es) suscribe(n) la DECLARACIÓN JURADA, soy(somos) egresado (s) del Programa de Estudios de **Ingeniería de Sistemas** de la Universidad Señor de Sipán S.A.C, declaro (amos) bajo juramento que soy (somos) autor(es) del trabajo titulado:

**MÉTODO DE CLASIFICACIÓN AUTOMÁTICA PARA DEFECTOS EXTERNOS
CON ACTUALIZACIÓN MANUAL DE SOLANUM PHUREJA PARA LAS
EXIGENCIAS DE PERCEPCIÓN DE CALIDAD.**

El texto de mi trabajo de investigación responde y respeta lo indicado en el Código de Ética del Comité Institucional de Ética en Investigación de la Universidad Señor de Sipán, conforme a los principios y lineamientos detallados en dicho documento, en relación con las citas y referencias bibliográficas, respetando el derecho de propiedad intelectual, por lo cual informo que la investigación cumple con ser inédito, original y autentico.

En virtud de lo antes mencionado, firman:

RUIZ SANTA CRUZ, YOVANNY FLORIBEL	DNI: 42509960	
SÁNCHEZ TORRES, MARÍA ROJANA	DNI: 46304595	

Pimentel, 30 de setiembre de 2024.

NOMBRE DEL TRABAJO

**SANCHEZ_TORRES_MARIA_ROJANA_TU
RNITIN.docx**

RECuento DE PALABRAS

12310 Words

RECuento DE CARACTERES

67031 Characters

RECuento DE PÁGINAS

67 Pages

TAMAÑO DEL ARCHIVO

2.9MB

FECHA DE ENTREGA

Sep 30, 2024 2:50 PM GMT-5

FECHA DEL INFORME

Sep 30, 2024 2:51 PM GMT-5

● **19% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 17% Base de datos de Internet
- Base de datos de Crossref
- 8% Base de datos de trabajos entregados
- 1% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● **Excluir del Reporte de Similitud**

- Material bibliográfico
- Coincidencia baja (menos de 8 palabras)
- Material citado

Dedicatorias

A Dios en primer lugar, por su infinito amor, porque ha estado conmigo en cada paso que doy, cuidándome y dándome fortaleza para seguir adelante.

A mi padre querido Elmer Ruiz Sánchez, que dejó este mundo para transformarse en mi ángel que está en el cielo, que desde ahí me guía cada paso que doy. Fue mi mejor amigo, un excelente padre ejemplo de perseverancia y dedicación. Con todo mi amor a mi madre querida Lucila Santa Cruz Vásquez, Quien es mi guía, mi motor, mi ejemplo a seguir, quien confía en mis capacidades para lograr mis metas, la cual me enseña que con humildad se logra todo lo que uno se proponga, una persona increíble que me anima cada día a seguir adelante a luchar por mis sueños.

Mis padres el tesoro más grande, quienes han velado por mi educación siendo mi principal apoyo en todo momento, depositando su entera confianza en mí para pasar cada reto que se me presentó, sin dudar ni un solo momento de mi inteligencia y capacidad.

A mis hermanos, los cuales me motivan siempre a seguir adelante y a no rendirme a lograr mis sueños y cumplir mis metas, gracias por mantener en mi vida la esperanza, a mis sobrinitos Maricielo, Adrián, Valeska, Criss, Iker y Cataleya por alegrarme la vida y darme ánimo para seguir adelante, esta meta lograda lo comparto con todos ustedes.

Yovanny Floribel Ruiz Santa Cruz

Doy gracias a Dios por su infinito amor y darme las fuerzas protectoras en cada paso de este camino académico a vencer las dificultades.

A mis padres, a través de su afecto y cariño con el deseo ser una buena profesional, estuvieron presentes en cada logro de mi carrera me enseñaron a perseverar mis objetivos, fueron comprensibles su presencia alentadora para continuar formándome profesionalmente. Gracias por la confianza puesta para realizarme como profesional.

A mis hermanos quienes fueron ayuda moral con sus consejos para que cumpliera mis metas hasta llegar a ser un profesional, dedico con honor porque son fundamentales en mi vida.

A mis sobrinos Paola Jazmín, Valeska y Joss Gael Nicolas que reflejando su alegría me motivo a seguir adelante.

María Rojana Sánchez Torres.

Agradecimientos

En primer lugar, a Dios porque sin él nada de esto hubiera sido posible, por darme salud, vida y ganas de concluir mis estudios.

Un especial agradecimiento a mis queridos Padres la Sra. Lucila Santa Cruz Vásquez mi madre motor y motivo para seguir adelante y el Sr. Elmer Ruiz Sánchez que en paz descansa y que siempre me cuida desde donde esté, quien a lo largo de toda mi vida me han apoyado y motivado para no rendirme y lograr mi formación académica concluida. A mis hermanos Genry, Yeni y Karen por su comprensión y apoyo ya que siempre he contado con ustedes son mi fortaleza y fuerza, , para lograr mis objetivos siempre.

Quisiera expresar mi más profundo agradecimiento a mi Decano de Escuela de Ingeniería de sistemas Dr. Victor Alexis Tuesta Monteza, al coordinador de tesis, el Mg. Asenjo Carranza Enrique David por su experiencia, dedicación, comprensión y paciencia contribuyeron a mi experiencia en el complejo y gratificante camino de la investigación. Su guía constante y su fe inquebrantable en mis habilidades me han motivado a alcanzar alturas que nunca imaginé. No tengo palabras para expresar mi gratitud por su inmenso apoyo durante este viaje en el aprendizaje. A María Rojana Sánchez Torres compañera de tesis, por las experiencias vividas durante el proceso del desarrollo de nuestra formación universitaria y momentos que hemos pasado y compartido juntas para lograr una más de nuestras metas trazadas.

Yovanny Floribel Ruiz Santa Cruz

Agradezco a Dios por estar siempre presente en cada momento de mi carrera, dándome sabiduría y su fuerza protectora para seguir adelante.

A mi centro de formación profesional universidad SEÑOR DE SIPÁN siento el honor de ser parte, también a todos los docentes que forjaron sus enseñanzas y conocimiento para ser mejores en el futuro.

A mis padres Teodolo y Elucina, estoy agradecida infinitamente por ser consejeros en mi profesión que depositaron su confianza estuvieron pendientes para que todo me vaya mejor y continuar hasta lograr la anhelada meta. A mis hermanos que me dieron el ánimo y la fuerza cuando necesitaba el apoyo moral. Este objetivo es también parte de ustedes por su incondicional ayuda.

María Rojana Sánchez Torres.

I. INTRODUCCIÓN	
1.1. Realidad Problemática.	15
1.2. Trabajos previos.	17
1.3. Teorías relacionadas al tema.	23
1.4. Formulación del Problema.	32
1.5. Justificación e importancia del estudio.	32
1.6. Hipótesis.	33
1.7. Objetivos.	33
1.7.1. Objetivo general.	33
1.7.2. Objetivos específicos.	34
II. MATERIAL Y MÉTODO	34
2.1. Tipo y Diseño de Investigación.	34
2.2. Población y muestra.	35
2.3. Variables, Operacionalización.	36
2.4. Técnicas e instrumentos de recolección de datos, validez y confiabilidad.	40
2.5. Procedimiento de análisis de datos.	40
2.6. Criterios éticos.	45
2.7. Criterios de Rigor Científico.	45
III. RESULTADOS.	46
3.1. Resultados en Tablas y Figuras.	46
3.2. Discusión de resultados.	52
3.3. Aporte práctico.	53
3.5 Implementar el método de clasificación automática de solanum phureja utilizando los algoritmos seleccionados.	64
IV. CONCLUSIONES Y RECOMENDACIONES	79
4.1. Conclusiones.	79
4.1. Recomendaciones.	80
Referencias	81

Índice de Tabla

Tabla 1:Características comerciales de la variedad solanum phureja	29
Tabla 2:Rangos de diámetros mayor y menor (mm) y peso (g) según calibre de la solanum phureja	29
Tabla 3:Matriz de operacionalización de las variables de la investigación	36
Tabla 4:Especificación de las Variables de Consumo de CPU	39
Tabla 5:Especificación de las Variables del Tiempo de Respuesta	39
Tabla 6:Especificaciones de las variables de consumo de Memoria RAM	40
Tabla 7:Especificación de la Variable Exactitud	40
Tabla 8:Especificación de la Variable de Grado de Error.....	41
Tabla 9:Especificación de la Variable de Precisión.....	41
Tabla 10: Especificación de la Variable Curva	42
Tabla 11:Red Neuronal Convolutacional	44
Tabla 12:Red Neuronal Convolutacional	45
Tabla 13: Red Neuronal Convolutacional	46
Tabla 14: Red Neuronal Porcentaje	48
Tabla 15: Materiales utilizados para el acondicionamiento del ambiente controlado requerido para la adquisición de las imágenes.	52
Tabla 16: Trastornos fisiológicos y deformación asimétrica seleccionadas para determinar las características de calidad de la papa en el mercado peruano.	56
Tabla 17:Distribución de la muestra de solanum phureja almacenadas.	56
Tabla 18: Distribución de imágenes en la carpeta entrenamiento y validación	57
Tabla 19: Evaluación de los algoritmos de procesamiento de imágenes usados en la investigación	58
Tabla 20: Evaluación de algoritmos de aprendizaje de máquina usados en la investigación	59
Tabla 21:Matriz de confusión	73

Índice de Figuras

Figura 1:Etapas que intervienen en el procesamiento de imágenes digitales [19]	22
Figura 2: Modelo de una neuronal artificial [21]	24
Figura 3:Diagrama de bloques de un sistema SVA. [38]	27

Figura 4: Solanum Phureja (Papa amarilla). [39]	28
Figura 5: Rangos de diámetros mayor y menor (mm) y peso (g) según el calibre de la solanum phureja. [27].....	30
Figura 6: Muestra de la galería de imágenes de Solanum Phureja correspondientes a las carpetas que conforman la población de estudio	33
Figura 7: Resultados obtenidos por la red Convolutiva cuyo consumo promedio de CPU es de 11%	44
Figura 8: Resultados obtenidos por la red Convolutiva cuyo consumo promedio de RAM es de 15%	45
Figura 9: Tiempo de respuesta	47
Figura 10: Precisión de la red neuronal	47
Figura 11: Exactitud de la RN	48
Figura 12: Caja de luz foto estudio para la adquisición de imágenes reales de la solanum phureja	50
Figura 13: Dimensiones y estructura de la caja de luz foto estudio	51
Figura 14: Posición de las luces LED blancas en la caja de luz foto estudio	51
Figura 15: Visualización de la solanum phureja dentro de la caja de luz, con y sin luz LED	52
Figura 16: Imagen digital de la solanum phureja adquirida a una distancia focal de 40 cm	53
Figura 17: Organización de imágenes adquiridas en carpetas ordenadas	53
Figura 18: Solanum phureja con grietas exorbitantes.	54
Figura 19: Solanum phureja con manchas oscuras.	55
Figura 20: Solanum phureja con deformación	55
Figura 21: Solanum phureja con trastornos fisiológicos y deformación	56
Figura 22: Estructura de la carpeta Dataset	57
Figura 23: Solanum phureja contenidas en la carpeta PB del Data set	57
Figura 24: Solanum phureja contenidas en la carpeta PM del Data set	58
Figura 25: Algoritmo de Binarización	60
Figura 26: Algoritmo de suavizado gaussiano	60
Figura 27: Algoritmo de segmentación	60
Figura 28: Algoritmo de la Mediana	61
Figura 29: Máscara de la ecuación de Laplaciano	62
Figura 30: Esquema usado para la implementación de los algoritmos para	

detectar la condición externa en las solanum phureja	62
Figura 31:Módulos de convolución para la extracción de características de solanum phureja	63
Figura 32: Estructura de la red neuronal convolucional	63
Figura 33: Diseño de la Investigación	75

Resumen

La problemática que enfrentan el productor papero campesino en el Perú, al momento de vender su cosecha es la negociación a bajos precios; siendo una de las razones la falta de calidad del tubérculo que comercializan. Tal situación resulta de interés para la ingeniería de sistemas al identificar como una necesidad a las causas de la poca importancia que se le da al proceso de selección; estos productores paperos campesinos saben que descartar aquellas que tienen daños externos visibles en su textura y forma requiere un mayor trabajo y tiempo. Realizan esta labor de forma manual por lo que se basan en la selección manual del tamaño de la papa. Así pues, esta investigación radica en desarrollar un método con un algoritmo de Redes Neuronales Convolucionales, el cual tiene un procesamiento de imágenes digitales con aprendizaje de máquina a fin de clasificar defectos externos de *Solanum Phureja* dependiendo de las exigencias del mercado peruano, anteriormente establecidas el cual incluye características físicas, tales como: textura y forma. Partiendo del análisis de una imagen del tubérculo, empezamos con elaboración de una base de datos dividida en dos carpetas, la primera está constituido por imágenes del tubérculo en buen estado, y la segunda contiene imágenes del tubérculo con los defectos de características en mención. Consiguiente a ello, procedemos a preparar y simplificar la imagen convirtiéndola así a un formato en escala de grises, la imagen del tubérculo fue localizada mediante descriptores de contorno, después, se realizó el procesamiento de imágenes con la base de datos y, por último, se llevó a cabo el aprendizaje y reconocimiento de imágenes utilizando redes neuronales. Con esta finalidad hemos utilizado un diseño metodológico propio, aplicando un instrumento cuantitativo (cuestionario) y una técnica cualitativa (entrevista) a un ingeniero agrónomo de Cajamarca, con el propósito de efectuar la validación por juicio del experto. Las conclusiones de la investigación nos indican que el modelo diseñado tiene una exactitud del 92% y una precisión promedio del 93%.

Palabras Clave:

Solanum phureja, clasificación automática, procesamiento digital de imágenes, redes neuronales, aprendizaje de máquina.

Abstract

The problem faced by Peruvian potato farmers when selling their harvest is the negotiation of low prices; one of the reasons is the lack of quality of the tubers they sell. This situation is of interest to systems engineering when identifying as a need the causes of the little importance given to the selection process; these potato farmers know that discarding those that have visible external damage to their texture and shape requires more work and time. They do this work manually, so they rely on manual selection of potato size. Therefore, the present research consists of developing a method with a Convolutional Neural Networks algorithm that has a digital image processing with machine learning to classify external defects of *Solanum Phureja* according to the requirements of the Peruvian market, previously established that include physical characteristics such as texture and shape. Starting with the analysis of an image of the tuber, first a database was created, divided into two folders, the first made up of images of the tuber in good condition and the second with images of the tuber with the characteristic defects in question. After that, we proceeded to prepare and simplify the image by converting it to a grayscale format, the tuber was located in the image by means of contour descriptors, image processing was performed with the database, and finally, image learning and recognition was performed using neural networks. For this purpose, we used our own methodological design, applying a quantitative instrument (questionnaire) and a qualitative technique (interview) to an agronomist engineer from Cajamarca, with the purpose of validation by expert judgment. The conclusions of the research indicate that the model designed has an accuracy of 92% and an average precision of 93%.

Keywords:

Solanum phureja, automatic classification, digital image processing, neural networks, machine learning.

I. INTRODUCCIÓN

1.1. Realidad Problemática.

El Perú está ubicado en la posición catorce a nivel global como generador de papa; siendo superado por las siguientes naciones en orden descendente: China, Rusia India, Polonia, Países Bajos, Francia, Alemania, Estados Unidos, Belarús, Canadá, Turquía e Irán. A nivel de Sudamérica, el Perú ocupa el primer lugar en producción de papa. El cultivo en la nación Inca se concentra, aproximadamente, en un 90% en los departamentos de La Libertad, Apurímac, Huánuco, Áncash, Huancavelica, Puno, Junín, Cajamarca, Ayacucho y Cusco; entre las más representativas [1].

Concretamente, este posicionamiento del Perú como nación agraria obedece a su continuo desarrollo a través del tiempo, así lo demuestran los datos de producción históricos para el período 1950-2016 donde la producción de papa paso de 1.334,3 a 4.527,6 t con una tasa promedio de 1,8% en el crecimiento anual, estimando para el año 2016 un aporte al Producto Interno Bruto (PIB) del 4% [2]. Sin embargo, con un promedio de 16.1 toneladas/hectárea, en el año 2019 se registra el record de 5.331 toneladas, mayor en 3,89% a la del año 2018, como consecuencia del incremento en el consumo interno, además de las propicias condiciones climatológicas [3]

Por otra parte, al ser la papa autóctona del Perú ha sido un alimento base para la alimentación en las civilizaciones prehispánicas y pilar fundamental de la sociedad actual desde hace unos 8 mil años; su permanencia, tradición de consumo y valor nutricional ha orientado la tendencia actual hacia su aprovechamiento para la elaboración de productos procesados siendo su mayor distribución como papa pelada y cortada en tiras sin congelar, y en menor proporción, papa entera y pelada [4]

Además, la papa representa una fuente de ocupación productiva significativa para el Perú. Las cifras para el año 2019 sostienen la generación de unos 110 mil empleos, siendo cultivadas por más de 711 familias ubicadas en la sierra peruana y produciendo unos 34 millones jornales de trabajo [5] Otra de los indicadores que aumenta el valor de la papa, es el mercado de exportación; para el año 2019 el total exportado de papas prefritas congeladas alcanzó las 33.080 toneladas, un

incremento del 1,8% en relación al 2018 [6]. Sumado a esto, el auge de los supermercados ha originado una mayor demanda de la denominada papa de calidad, en cifras para el año 2018 se contabilizaban unos 456 establecimientos, de los cuales un 72% se ubica en Lima [7]).

La suma de todos estos factores indica la importancia económica para el Perú de la papa y explica el porqué de las exigencias de calidad del mercado peruano, nacional e internacional. De allí, que exista una mayor rigurosidad al momento de realizarse los procesos de recolección, selección, empaque y, por último, distribución en la cadena de abastecimiento. Específicamente, en la fase de selección la comunidad campesina productora de papa es vital, ellos son quienes cultivan, recolectan y seleccionan el producto para venderlo a compradores contratados por mayoristas, proveedores de supermercados, a otros comerciantes de papa y a otros productores grandes.

Concretamente, la selección de la papa la realizan a mano, siendo su único parámetro de calidad, el tamaño para luego llenar sacos de 100-120 kg. Obviando eliminar papas dañadas, podridas o verdeadas. Esta precaria forma de seleccionar la papa ha significado para el pequeño productor campesino la merma de sus ingresos monetarios, asumiendo pérdidas que irán en detrimento de la actividad productiva y, por ende, disminuirá la economía nacional, al tener que vender su producción al precio que le ofrezcan por no cumplir con todos los requerimientos al tener tierra, defectos físicos, arrugas y brotes.

Por esta razón, surgió la necesidad de desarrollar un mecanismo de selección que ayudase a cubrir las exigencias de la papa de calidad para el mercado peruano y, de este modo, incrementar los precios a la hora de su distribución para lograr la obtención de mejores beneficios. Por tanto, se plantea el uso del procesamiento digital de imágenes de una resolución aceptable y el aprendizaje máquina para automatizar el proceso de clasificación en los cultivos de papa, específicamente, *solanum phureja*; incorporando a las características de calidad atributos que permitan separar aquellas papas defectuosas o sospechosas externamente de las que son visiblemente aptas para ser comercializadas de acuerdo a las exigencias del mercado peruano. Actualmente los agricultores no cuentan con un sistema que

permita clasificar la solanum phureja, ya que todo esto lo realiza el agricultor de manera visual – manual donde el mismo determina si su estado bueno o malo.

1.2. Trabajos previos.

[8] Los autores desarrollaron una investigación titulada: Detection of multiple kinds of fruit in apple plant in the SNAP system using Faster R-CNN, cuyo objetivo fue desarrollar un método de detección de manzanas en árboles de pared de fructificación vertical que es un sistema de huerto simple, angosto, accesible y productivo implantado en Washington. Concluyen que el uso de R-CNN fue eficiente para identificar las características de las manzanas con una buena capacidad de convergencia detectando manzanas en diferentes condiciones, como frutas no ocluidas, con hojas ocluidas, con ramas, alambres ocluidos y con frutas ocluidas lo que ayudaría al robot en el posterior proceso de recolección. La muestra estuvo conformada por un total de 12.800 imágenes adquiridas en un huerto comercial. La anotación de las imágenes fue rectangular, y a partir de ellas, se generaron los archivos .xml correspondientes.

Con respecto a la identificación de rasgos de productos hortícolas, esto demuestra que el uso del preprocesamiento de imágenes es exitoso, siempre y cuando, se base en criterios de condición. Por lo tanto, es aplicable para identificar características de calidad que permitan separar las papas amarillas dañadas de aquellas que cumplen con los requisitos de calidad, es decir, que tengan aspecto fresco, firmes y limpias, con color y tamaño uniforme, libres de humedad externa ni materias extrañas visibles; por medio de la implementación del aprendizaje máquina.

[9] Los científicos desarrollaron una investigación titulada: “Clasificación de frutas basadas en redes neuronales convolucionales”, en Ecuador. Su objetivo fue entrenar una Red Neuronal Convolucional Profunda (CNN) para clasificar frutas por medio de la captura y procesamiento de imágenes. Sus resultados, permitieron identificar la resolución de la imagen como el principal factor para que la CNN sea efectiva, a mayor resolución aumenta eficiencia de aprendizaje; no obstante, se percataron que el uso desmedido de imágenes puede causar que la CNN memorice en vez de aprender. La muestra comprendió 13.516 imágenes divididas en 13

categorías de frutas obtenidas con una cámara digital de 13 megapíxeles, descargadas de Internet en ImageNet. Fue empleado el modelo MobileNet compilado en Python por medio de la librería TensorFlow y MatLab para el aprendizaje de la CNN.

Por su parte, el uso de etiquetas en el entrenamiento del aprendizaje máquina, es justificado con este estudio. Al poder asociar cada imagen con una característica de calidad de la papa amarilla se incrementará la efectividad del procesamiento de imagen; siendo necesaria, en el caso de las papas defectuosas, una gran cantidad de imágenes para lograr una correcta identificación, dada la similitud entre los aspectos de una papa sospechosa o enferma por inmadurez, con cortes, cicatrices, magulladuras, grietas, rajaduras, brotamiento, verdeamiento, pudrición, daños causados por insectos o roedores y mezclas varietales.

[10] La investigación “Research on Potato Appearance Quality Detection Based on Computer Vision” [Investigación sobre la detección de la calidad de la apariencia de la papa basada en visión artificial], en China, marcaron como objetivo detectar la calidad de la papa a partir de su apariencia. Concluyen que la tecnología de procesamiento y reconocimiento de imágenes de papa normal y papa de piel verde es realizada por discriminación de similitud de escala de grises de píxeles; en tanto, los resultados experimentales de la detección visual de la papa demostraron que el método propuesto tiene una correcta tasa de reconocimiento de más del 90% para las papas en varios estados, entre las cuales las papas normales y germinadas tienen una tasa de reconocimiento correcta de más del 96%; asimismo, las características geométricas de la imagen y la información del borde permitieron identificar la parte dañada de la epidermis de la papa. El sistema que se utilizó fue basado en un algoritmo de reconocimiento y detección de características de imágenes enfocadas en la visión por computadora y el método Otsu.

Con respecto a la utilización de la visión por computador en el análisis de la apariencia de la papa amarilla para determinar su calidad y adaptabilidad a las exigencias del mercado peruano, que la misma puede realizarse partiendo del procesamiento de la imagen de la piel; siendo el principal indicador el color; así como también, de la forma a partir de su característica geométrica redondeada.

Todo esto, ayudará a diferenciar los daños en el proceso de selección de las papas no aptas y de piel verde.

[11] Los autores desarrollaron una investigación titulada: “Clasificación de manzanas utilizando visión artificial y redes neuronales artificiales”, en México. Su objetivo fue diferenciar las variedades de manzanas por medio de un algoritmo inteligente combinado con la visión artificial y CNN. De ello, concluyen que el ruido es un factor que debe considerarse para asegurar la eficiencia y precisión de la clasificación, es importante contar con imágenes de calidad y buena iluminación para facilitar la extracción de la imagen del fondo a partir del color.

Luego de escoger cuatro variedades de manzanas la base de datos contó con un total de 2800 imágenes las cuales contaban con 128x128 píxeles de donde se utilizó el 80% para el entrenamiento de la CNN y lo que restaba, es decir, el 20%, para pruebas. El algoritmo evolucionó empleando las librerías de código abierto, que son: OpenCV, Tensorflow y Keras en Python, además de una estructura de diferentes capas convolucionales y MaxPooling.

Este aporte constata la relevancia de captar imágenes de buen tamaño y con calidad para poder extraer los rasgos de clasificación de forma adecuada durante la etapa de procesamiento, sobre todo para lograr la correcta separación de la imagen de la papa amarilla del fondo. Además, las condiciones de luz resultan igual de importantes, a mejor iluminación aumenta la calidad de la imagen. Solo de esta manera podrá diferenciarse el color característico de una papa de buena calidad, de una de mala calidad y podrá eliminarse el fondo sin tener pérdidas en la imagen a procesar.

[12] Los investigadores desarrollaron una investigación titulada: “R-CNN faster for multi-class fruit detection using robotic vision System” [R-CNN más rápido para la detección de frutas de varias clases mediante un sistema de visión robótica], en Estados Unidos. El objetivo fue detectar frutas de clases múltiples basado en Faster R-CNN basado en imágenes precisas y en tiempo real. Sus resultados demostraron más del 91% de efectividad pudiendo diferenciar entre manzanas, mango y naranja, infiriendo que la precisión y rapidez en el reconocimiento se logra con el agrupamiento de las capas convolucionales.

Para ello, crearon una biblioteca de imágenes de huertos al aire libre utilizando 4000 imágenes reales. El método utilizado incluyó la creación de bibliotecas de imágenes de frutas, argumentación de datos, generación mejorada de modelos RCNN más rápidos y evaluación del desempeño. Bajo este enfoque, para alcanzar el correcto reconocimiento de las características de calidad de la papa amarilla, las imágenes deben ser tomadas de la realidad, de papas físicas que tengan los atributos que le permitan entrenar a la CNN adecuadamente y, de este modo, lograr la precisa clasificación de una papa buena, de una mala o dañada.

Siendo clave el agrupamiento de las características, a partir de una biblioteca de imágenes, que ayude a que el proceso de reconocimiento se ejecute a una mayor velocidad para facilitar la tarea de selección, reduciendo el tiempo y aumentando la calidad de la papa que se comercializa.

[13] En estudio desarrollaron una investigación titulada: “Algorithms for Detecting Potato Defects Using Images in the Infrared Range of Spectrum” [Algoritmos para detectar defectos de papa utilizando imágenes en el rango de espectro infrarrojo], en Rusia. Su objetivo fue medir la calidad de la papa en base a sus propiedades fisicoquímicas. Se evidenció que los algoritmos descritos en el artículo permitieron detectar, con una probabilidad de hasta un 95%, regiones más claras en un fondo oscuro de la superficie del objeto de control. El método que se utilizó para detectar los defectos del tubérculo se basó en obtener la diferencia de temperaturas entre los tejidos dañados y los tejidos sanos después de un calentamiento de la papa a corto plazo. Luego de aplicar dicho método se obtuvo como resultado un sistema automatizado el cual se aplica para realizar pruebas de calidad térmica sin contacto de papas que se mueven a lo largo de un transportador de cadena.

Este trabajo orienta las técnicas a emplear para identificar las características de una papa amarilla defectuosa, a partir de imágenes infrarrojas; sin embargo, dentro del alcance no se encuentra el inspeccionar los defectos internos como la descomposición y pudrición de la pulpa pues esto significaría la recolección de imágenes espectrales. No obstante, es de gran valor para reconocer los defectos

externos, identificar las papas visiblemente dañadas que no se encuentran aptas para su comercialización.

[14] El autor desarrolló una investigación titulada: “Clasificador de imágenes de frutas basado en inteligencia artificial”, en Perú, cuyo objetivo se dirigió a la construcción de un clasificador de imágenes de frutas a partir de la extracción del color. Los resultados del reporte de clasificación le llevaron a concluir que la precisión disminuye cuando las frutas tienen colores similares, siendo necesario robustecer el clasificador incorporando la característica de forma y textura. Las muestras de imágenes son de recolección propia y recopilada de Internet, en total 83 imágenes de 4 frutas: manzana roja, manzana verde, banana y naranja. La técnica empleada para la clasificación fue el histograma de color 3D RGB, con la implementación de algoritmos en una máquina de aprendizaje supervisado basada en el modelo Radom Forest en Python.

En efecto, el desarrollo de un clasificador de los defectos externos de la Solanum phureja debe permitir seleccionar las papas teniendo como criterio el color: amarillento, amarillo claro, rojo a morado y amarillo. Además, debe incluir su forma: chata, redondeada en forma de piña, alargada, oblonga. Así como, la textura o relieve de los ojos: superficiales y en poco número, con cejas moradas y profundos, semiprofundos. Estas son las particularidades de las variedades de la solanum phureja que sirven para seleccionarlas adecuadamente.

[15] En esta investigación titulada: “Análisis Comparativo de las técnicas utilizadas en un Sistema de Reconocimiento de Hojas de Planta”, en México. Su objetivo fue comparar diferentes sistemas de extracción de las características y, además, de clasificación en hojas de planta. De forma concluyente, afirman que la combinación de las diferentes características es necesaria para obtener una buena precisión de clasificación; esto se hace más evidente cuando se labora con conjuntos de hojas que poseen rasgos muy semejantes. La muestra se basó en imágenes de hojas para analizar sus características geométricas: tamaño, elongación, elipsidad, área, longitud, diámetro, rectangularidad, esfericidad y excentricidad.

Tal como lo expresaron los autores, el método utilizado fue la segmentación con los “algoritmos de frontera adaptativa” usando una fase de Análisis de

Componentes Principales (PCA), además, “un clasificador bayesiano, el algoritmo de aprendizaje backpropagation para redes neuronales y Máquinas de Vectores de Soporte (SVM)”.

Habiendo descrito la fase de clasificación, este trabajo deja ver lo esencial de enfocar las soluciones de aprendizaje de máquina en el procesamiento de imágenes que denoten las características geométricas, texturales y cromáticas. En el caso de la papa amarilla la redondez, esfericidad, dimensiones máximas y mínimas del calibre o tamaño, porosidad, color de la piel, diámetro, peso y densidad son rasgos físicos que permitirán catalogar su grado de calidad.

[16] La investigación titulada: “Detección automática de líneas de cultivo de papa utilizando imágenes digitales”, en Ecuador, cuyo objetivo fue detectar automáticamente las líneas de cultivo que se encontraban en imágenes capturadas dentro de campos de papa estando en las primeras etapas de crecimiento. Los resultados le permitieron aseverar que, el uso de métodos automáticos basados en la región de interés es robusto para abordar algunos problemas que pueden afectar e interferir en la calidad y el procesamiento que tienen las imágenes.

La muestra estuvo compuesta por 320 imágenes en formato .jpg de 24 bits con una resolución de 3000x2550 pixeles, en 4 filas de cultivo, tomadas con una cámara a color, la cual se instaló en la parte frontal de un tractor. La aplicación que está desarrollada en Matlab, la cual emplea Fitting Curve Toolbox ajusta de manera automática la curva más adecuada para los puntos establecidos, usando, en primer lugar, el método Otsu de doble umbralización y operaciones morfológicas para la fase de segmentación de la imagen; luego la Transformada de Hough (HT) para identificar puntos de inicio en la línea de cultivo ante la presencia de pixeles blancos y restos de maleza en la imagen ya segmentada; finalmente, se detecta la línea de cultivo, tanto curvas como rectas, con la técnica de mínimos cuadrados para la calidad del ajuste.

En este trabajo destacan la iluminación controlada, las perspectivas, alturas y volúmenes, así como la presencia de suciedad e imperfecciones que son consecuencia de problemas sucedidos en la siembra o, también, en la germinación de los cultivos, siendo las plagas o las enfermedades las que lo provocan; estos factores deben ser tomados en cuenta para lograr la adecuada clasificación de una línea de cultivo de papa. Pero también aplican para evitar falsas detecciones

derivadas de las sombras y brillos que perjudican el procesamiento y la calidad de la imagen al clasificar los defectos externos de la papa amarilla, más allá de la semilla y germinación.

[17] Los autores desarrollaron una investigación titulada: “Identificación del estado de madurez de las frutas con redes neuronales artificiales, una revisión”, en Colombia. Su objetivo fue realizar un acercamiento teórico sobre los distintos estudios en los cuales se ha implementado la RNA y la visión artificial para identificar el estado de madurez de las frutas.

Luego de efectuada la revisión de la literatura sus conclusiones afirman las ventajas de utilizar la RNA y la visión artificial en la clasificación, control y predicción sobre los cambios físicos que pueden darse en las frutas y hortalizas, por ejemplo, mandarinas, dátiles y manzanas; también para reemplazar sistemas automatizados que, en ocasiones, se encargaban de la clasificación y control de alimentos, además de la predicción de las cosechas. Todo esto, por medio de la clasificación y el reconocimiento de patrones. El método fue, el análisis sobre conceptos y teorías de RNA.

Vinculando la RNA al procesamiento de imágenes en la clasificación de la papa amarilla se ha de considerar como técnica esencial el reconocimiento de patrones, a partir de las características físicas que denotan las imperfecciones que permitirán entrenar a la máquina para mejorar el actual proceso de selección automatizando la comparación a partir de muestras del cultivo que serán comparadas con las imágenes contenidas en un banco de datos.

1.3. Teorías relacionadas al tema.

1.3.1 Procesamiento de imágenes digital. El procesamiento de imágenes se relaciona a la agrupación de técnicas y procedimientos aplicados a imágenes digitales con el fin de posibilitar la búsqueda de patrones o información particular requerida para un estudio o entrenamiento [18] En el procesamiento se distinguen cinco tareas (Figura 1): adquisición, preprocesado, segmentación, representación y descripción, reconocimiento e interpretación.




Figura 1: Etapas que intervienen en el procesamiento de imágenes digitales [19]

La adquisición es la fase donde se recopila la imagen por medio de cámaras digitales atendiendo a los criterios de iluminación. El pre procesamiento busca mejorar la apariencia visual de la imagen a través de la eliminación del ruido e ilustración de los detalles; y, posteriormente, dividir la imagen con la técnica de Binarización. La segmentación y particiones la imagen luego de haber encontrado una Región de Interés (ROI) con la técnica de umbralización, para tratar imágenes que tengan fondo con diferentes niveles de grises y extraer de ellas la forma; y en caso de no ser posible se recurre al estudio de gradientes de luminosidad haciendo uso del histograma [19].

Por su parte, la representación toma los datos en binario, para ser procesados como un contorno o una región completa; la primera adecuada cuando las características que interesan son la forma exterior, en tanto, la segunda se orienta a las propiedades internas. Es entonces cuando la descripción extraerá rasgos con información cuantitativa para poder realizar la posterior diferenciación. Por último, el reconocimiento le brinda una etiqueta a un objeto basándose en la información correspondiente a sus descriptores; requiriendo una base de conocimientos que le permita interpretar la información extraída [19].

1.3.2 Imagen digital. La representación de un objeto o cosa es la imagen, es una reproducción de la realidad en un momento determinado. Su captación por medio de cámaras que incorporan un sensor Semiconductor Complementario de Óxido Metálico (CMOS) o un sensor de Dispositivo de Carga Acoplada (CCD) para convertirla a binario, esto es la digitalización. Entonces, cuando se habla de imagen digital se refiere a la representación en dos dimensiones de dicha imagen en base a una matriz numérica binaria en su mayoría. Podrá tratarse de una imagen del tipo matricial conocida también como mapa de bits la cual es comúnmente utilizada en la informática o de una figura vectorial según si la imagen en estudio es del tipo estática o dinámica [18].


Ahondando en la captación digital de la imagen, el código binario en la cuales convertida para ser procesada contiene la información de luminosidad y espacio. Estas pueden ser vectorizadas o mapa de bits; estas últimas están determinadas por resolución o número de píxeles por pulgada cuadra (ppp) y su formato puede ser JPEG, GIF, PNG, TIFF, BMP, PSD, RAW. Para reducir la cantidad de información contenida el formato JPG realiza una compresión que elimina información para alivianar el peso del archivo con la consecuente disminución en la calidad de la definición de la imagen.

En cambio, los formatos TIF, GIF y PNG logran la reducción del peso del archivo organizando los datos binarios sin incidir en la calidad de la imagen [20]Para finalizar, es importante mencionar la existencia de imágenes digitales positivas y negativas, tal como ocurre con las imágenes analógicas, que resultan de la incidencia de la luz sobre la superficie. Donde llega la luz, hay oscurecimiento y donde no llega hay claridad.

1.3.3 Redes neuronales artificiales. Una neurona es un cuerpo celular, con vida que cuenta con capacidad de comunicación; recibe miles señales de entrada de otras neuronas y emite señales de salida. Estas señales son de naturaleza eléctrica y química y fluyen a través de la sinapsis a través de neurotransmisores. Este contexto permite realizar una comparación con una neurona artificial [21], identificando 5 puntos de convergencia (ver figura 2):

- Las señales de entrada son recibidas por las neuronas.
- Los pesos sinápticos pueden alterar las señales.
- Las neuronas suman las entradas o señales eléctricas afectadas por la sinapsis para definir qué hacer.
- La neurona emite una señal de salida activándose.

Al activarse la salida puede ir a muchas otras neuronas emitiendo un impulso eléctrico, que actúa como entrada para otras neuronas o un estímulo.



Al establecer una comparación la neurona artificial es compleja, de alta velocidad y tiene una sola unidad de procesamiento, la memoria está separada del procesador, está localizada y puede ser direccionada aleatoriamente; el procesamiento de datos es centralizado, secuencial y las indicaciones se encuentran guardadas en programas; es muy vulnerable ante errores y tiene un ambiente de operación bien marcado. En resumen, una RNA no es más que un modelo computacional el cual hace una analogía a la red neuronal propia de los

Figura 2: Modelo de una neurona artificial [21]

seres humanos capaz de resolver problemas altamente complejos; es una topología de red que sigue reglas de aprendizaje y tipos entrenamiento para aprender y, luego ejecutar [22].

La RNA está compuesta por una agrupación de unidades denominadas neuronas artificiales, las cuales se encuentran interconectadas con la intención de transferir señales. Los datos que se ingresan realizan varias operaciones en su proceso para obtener valores de salida. Cada unidad de la agrupación se encuentra interconectada mediante enlaces; estos obtienen un valor el cual viene dado por la neurona preliminar y se multiplica por valores según su ponderación. Dichas ponderaciones hacen que los enlaces se multipliquen o se anulen en el peor de los casos para la realización del ciclo con su análogo adyacente.

Asimismo, en la salida de las neuronas existe la posibilidad de una denominada función limitante el cual transforma el valor final o define un límite antes de que se

transmita nuevamente en otra unidad. Lo anteriormente detallado se define como función de activación. Estos sistemas se encuentran en continuo aprendizaje autogenerándose de forma independiente, su gran valor resalta en la obtención de soluciones o patrones que serían casi imposibles de explicar con programación tradicional por así decirlo. Para generar este desarrollo de aprendizaje automático, es común minimizar una función de pérdida la cual es evaluada por la red en todo su conjunto.

1.3.4 Técnicas de aprendizaje máquina.

1.3.4.1 Algoritmos Genéticos. Un método de optimización es el algoritmo genético, el cual se basa en los sistemas de desarrollo natural para resolver inconvenientes en la búsqueda y el aprendizaje. Las características que tiene un ser humano contienen información que se encuentra codificada en los cromosomas. Los algoritmos genéticos crean métodos que tienen la facilidad de ser aplicados a una computadora con el propósito de solucionar los problemas descritos previamente, pues se basan en esta idea, pero con una dificultad de nivel alto.

Encuentra sus cimientos en la ley de la "supervivencia del más apto". La ejecución de la aplicación de un Algoritmo Genético hacia un problema, siendo determinante la definición de dos elementos: los cromosomas codificados de los individuos que fueron tomados en cuenta como soluciones y la función de supervivencia de estos. Asimismo, se trabaja con diversos operadores genéticos.

Estos algoritmos constituyen una similitud en medio del conjunto de resoluciones de un problema y el de individuos pertenecientes a una población natural, llevando así la información de cada solución para codificarse en un string (vector binario) en modo de cromosoma. John Holland, quien ha creado algoritmos, indica que, es posible hallar soluciones aproximadas a problemas de gran complejidad computacional mediante un proceso de evolución simulada.

En dicho sentido, se evalúan los cromosomas mediante una función, la cual se llama calidad ("fitness"), basada en el objetivo del problema. Por igual, es insertado una forma de selección, y así, los cromosomas mejor evaluados serán seleccionados para "reproducirse" con mayor frecuencia que los demás. Holland desarrolló algoritmos en un principio sencillos, sin embargo, obtuvieron resultados satisfactorios en problemas que fueron complicados. Estos algoritmos se basan en constituir de manera eficiente dos planteamientos cruciales: Las representaciones

simples vienen a ser strings binarios que parten de las soluciones del problema y el que se realice transformaciones simples con el fin de transformar las representaciones dichas. Teniendo el propósito de poner en práctica este esquema anterior y, además, poder formalizarlo en algoritmo, se debe detallar con ahínco los elementos siguientes:

- Representación cromosómica.
- Población inicial.
- Medida de evaluación.
- Criterio de selección / eliminación de cromosomas.
- Técnicas de recombinación.
- Técnicas de mutación.

Estos conceptos son desarrollados y, también es expuesto el funcionamiento de los algoritmos genéticos para el aprendizaje de rostros.

1.3.4.2 Algoritmo y el aprendizaje de máquina. [23] En su investigación “Redes Neuronales aplicadas al pronóstico del índice de precios al consumidor” indica que el aprendizaje en una red neuronal permite crear, modificar o eliminar sus conexiones. El aprendizaje puede ser controlado o no. Cuando es controlado se registra el adiestramiento, estableciendo la respuesta o salida que debería generarse a partir de una entrada en concreto. Entonces, se compara la salida con la salida esperada, si existen diferencias, se destruye la conexión ajustando los parámetros hasta que se obtiene la salida deseada.

En cambio, cuando no es supervisada la red neuronal se autoorganiza, solo necesitan las entradas y buscan las relaciones lógicas para obtener una salida aceptable. En ambos casos, la red necesitara de algoritmos de aprendizaje, encontrando 3 tipos: por corrección de error, por refuerzo y estocástico [24].

1.3.4.3 Visión artificial. La visión artificial comprende aplicaciones que combinan hardware y software para captar y procesar imágenes. Cuenta con sensores digitales en el interior de cámaras para adquirir imágenes para procesarlas, analizarlas y medir características en tiempo real a una gran velocidad, con precisión y repetibilidad. Además, ayuda a obtener una calidad superior, mayor

productividad, entre otras ventajas. Involucra la tecnología de reconocimiento de patrones a partir de una región de interés [25]. En tal sentido, es un sistema automatizado que recoge imágenes, en base a parámetros previos, para ello hace uso de una cámara y algoritmos formando una imagen digital que permita organizar o reconocer patrones de determinadas características.

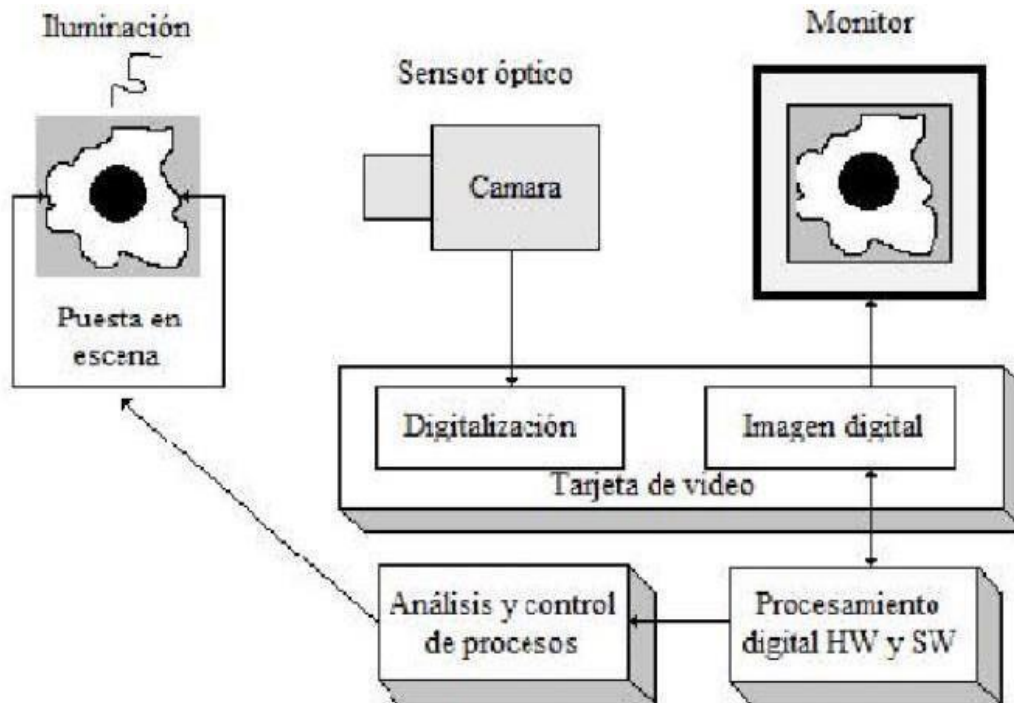


Figura 3: Diagrama de bloques de un sistema SVA. [38]

1.3.4.4 Solanum Phureja. La solanum phureja se originó de la especie solanum stenotomum, a través de los procesos de mutación y selección natural, es de color amarillo intenso, tiene un sabor dulce, agradable y es apta para el consumo. [26] Es decir, no presenta una etapa de reposo previo lo cual conlleva a que la papa empieza su brotación de manera inmediata luego de su formación, sin siquiera haber tenido un periodo de tiempo de reposo previo lo que se denomina dormición. Esta característica de dormición les brinda la facilidad para que variedades de solanum phureja puedan ser plantadas nuevamente de inmediato en zonas con climas benignos en las cuales es factible el cultivo continuo en todo el año.



Figura 4: *Solanum Phureja* (Papa amarilla). [39]

1.3.4.5 Disposiciones relativas a la calidad. La *solanum phureja* de consumo, en general, no debe tener daños como lo son los cortes y deformaciones. Su tamaño recomendado es mediano y el peso entre 70 y 120 gr. Específicamente, la *solanum phureja* debe ser voluminosa, turgente, firme con un peso de tubérculo-semilla de 20 a 30 gr. [26]

En resumen, deben ser firmes, de aspecto fresco y entero, sin eliminar ninguna parte por cualquier medio. Además, se excluye el sonido, que produce que se presenten podredumbre u otras alteraciones que no son adecuados para el consumo; prácticamente limpias, libre de polvo y barro y prácticamente libre de cualquier materia extraña visible.

Así como libre de insectos, gusanos, plagas y otros daños causados, que afecten al aspecto general del producto, libres de una anormal humedad externa, libre de defectos tanto externos como internos, ennegrecimiento por magulladuras, manteniendo la calidad del alimento. Por tanto, debe mantenerse libre de magulladuras, libres de daños causados por temperaturas bajas, libre de agujeros que penetren en la pulpa, libre de costra, pudrición blanda y descomposición húmeda.

1.3.4.6 Características físicas de calidad en la solanum phureja. Se considera que un producto agrícola es de calidad cuando logra su madurez comercial la cual debe mantenerse hasta que llega al consumidor final conservando el color que tiene piel, su firmeza y color que tiene la pulpa.

En el Perú existe la Norma Técnica Peruana NTP 011.119 que establece los requerimientos de los tubérculos de papa destinada al consumo humano: uniformidad y tamaño.

Uniformidad. Cada lote debe estar conformado por solo la variedad de solanum phureja del mismo color amarillo, forma y características varietales (ver Tabla 1).

Tabla 1: Características comerciales de la variedad solanum phureja.

Variedad	Forma	Piel	Pulpa	Características físicas y uso sugerido
Solanum phureja	Redondeada en forma de piña	Piel de color amarillo claro, ojos profundos	Amarilla	25% de materia seca, con una gravedad puntual de 1.089. Uso recomendado: sancochado, fritura, puré.

Nota: Tamaño. Cada lote debe cumplir con los calibres expresados en diámetros y pesos (ver Tabla 2 y Figura 5). El calibre es la relación entre el peso y los diámetros definiéndolos en extra, primera y segunda. [27]

Tabla 2: Rangos de diámetros mayor y menor (mm) y peso (g) según calibre de la solanum phureja.

Variedad	Calibres		
	Extra	Primera	Segunda
D mayor (mm)	94-77	76-58	57-30
Solanum De menor (mm)	83-64	63-47	46-32
Peso (g)	361-362	201-99	98-20

Nota: los diámetros mayor y menor están referidos a las dimensiones máximas y mínimas de los ejes longitudinales y transversales del tubérculo cuando se interceptan en ángulo recto. [27]




Figura 5: Rangos de diámetros mayor y menor (mm) y peso (g) según el calibre de la *solanum phureja*. [27]

1.4. Formulación del Problema.

¿De qué manera se podrá realizar la clasificación automática de los defectos externos de *solanum phureja* para cumplir con las exigencias del mercado peruano?

1.5. Justificación e importancia del estudio.

El trabajo de investigación surgió gracias a que, en el Perú para realizar el proceso de distribución y venta de papas luego de la cosecha se realiza la selección mediante las características físicas que cumplen la exigencia del mercado. Actualmente, se realiza de manera manual, lo cual incurre en el error humano, por ende, esto ha provocado grandes pérdidas para las empresas distribuidoras.

Debido a ello, dicha investigación en el aspecto pedagógico permitió contar con un análisis de rendimiento en términos de eficiencia de un sistema con aprendizaje automático que sirvió como fuente de información para trabajos futuros; en el ámbito social, permitió dar a conocer a la población las técnicas existentes de visión por computadora, explicando que puede ser utilizada para realizar este tipo de procedimientos experimentando un elevado nivel de acierto.

En cuanto a la viabilidad la investigación no presentó ningún impacto negativo en la agricultura, y en lo económico los gastos realizados para tener la base de datos que ayude a realizar el aprendizaje, constó de fotos tomadas con la cámara de un equipo celular y/o cámara fotográfica sin obtener limitación alguna.

1.5.1 Limitaciones de la investigación. Una de las limitaciones más comunes para clasificar la calidad de forma y color de la solanum phureja y obtener un producto de calidad es el tiempo ya que cuando está bien las cosechas son más productivas que cuando el tiempo está mal el ingreso para los productores es menor, el precio es inconstante debido a las alta y bajas temporadas de producción de la solanum phureja.

Otras limitaciones consideradas en esta investigación es la cámara de baja resolución que impidan capturar la imagen correctamente de acuerdo a los protocolos establecidos y obteniendo imágenes con bajo contraste de iluminación, como también los defectos de la solanum phureja.

1.5.2 Delimitaciones de la Investigación. En este proyecto se incluirá el desarrollo de un algoritmo de clasificación de solanum phureja en ambiente controlado; para el reconocimiento de las imágenes para el mejoramiento de la clasificación en la ejecución de la investigación se consideró a los estudiantes como investigadores y la elaboración del sistema durante el año 2021.

1.6. Hipótesis.

Mediante el desarrollo de un método de clasificación automática; se podrán identificar defectos externos de solanum phureja para cumplir con las exigencias del mercado peruano.

1.7. Objetivos.

1.7.1. Objetivo general.

Desarrollar un método de clasificación automática para defectos externos con actualización manual de Solanum Phureja para cumplir con las exigencias de percepción de calidad.

1.7.2. Objetivos específicos.

- a) Crear una base de datos con imágenes digitales de solanum phureja considerando las características físicas de calidad.
- b) Seleccionar algoritmos de procesamiento de imágenes y aprendizaje de máquina con mejor desempeño en clasificación.
- c) Aplicar los algoritmos de procesamientos de imágenes.
- d) Aplicar el método de clasificación automática de solanum phureja utilizando los algoritmos seleccionados.
- e) Realizar las pruebas al prototipo.

II. MATERIAL Y MÉTODO

2.1. Tipo y Diseño de Investigación.

2.1.1 Tipo de Investigación. Esta investigación correspondió al tinte cuantitativo, [28] el proceso se trata de tener el mayor control para lograr que otras posibles explicaciones, distintas o rivales a la propuesta del estudio (hipótesis), se desechen y se excluya la incertidumbre y minimice el error. También es tecnológica, por cuanto se parte de la base del proceso de observación y reflexión sobre la máquina, el conocimiento científico apoyado por las ciencias de la computación.

Para su ejecución, se propone utilizar índices e indicadores para estimar el nivel de confianza con el uso de la estadística como ciencia auxiliar para compilar, ordenar e interpretar datos. A su vez, contempla un estudio comparativo partiendo de los resultados alcanzados y los estándares prefijados según los experimentos llevados a cabo para dar solución a una problemática real.

2.1.2 Diseño de investigación. El diseño compete a los tipos cuasi experimental, diseño pre-test y post test de un sólo grupo. Se justifica por ser de utilidad para una primera aproximación al fenómeno de estudio con un grado de control mínimo [28]. Su representación es la siguiente: G: O1 X O2 Dónde: G: Grupo de estudio experimental O1: Observación de procesamiento de imágenes digitales y aprendizaje de máquina. X: Variable independiente: Clasificación de solanum phureja. O2: Observación de reconocimiento de imágenes digitales y aprendizaje de máquina.

2.2. Población y muestra.

2.2.1.1 Población. Para [28] vendría a ser el acumulado de todos los casos que componen una serie de especificaciones. De este modo para el presente estudio la población está conformada por una base de datos de 800 imágenes de *Solanum Phureja* ordenadas en dos carpetas las cuales están divididas por sus defectos externos (PM) y sin defectos (PB).




Figura 6: Muestra de la galería de imágenes de *Solanum Phureja* correspondientes a las carpetas que conforman la población de estudio

2.2.1.2 Muestra. Es poblacional debido a que está conformada por una base de datos de 800 imágenes de *Solanum Phureja* ordenadas según sus defectos externos, que conforman la selección de manera conveniente aquellas que adaptan a las condiciones y características del estudio.

$$N * Z^2 * p * q^n = EE^2 * (N - 1) + (p * q) * Z^2$$

Donde:

n = representación del tamaño de la muestra. **N** = representación del tamaño de la población. **p,q** = Desviación estándar de la población que, generalmente cuando no se tiene su valor, suele utilizarse un valor constante de 0,5.

Z = Valor obtenido mediante niveles de confianza. Es un valor constante que, si no se tiene su valor, se lo toma en relación con el 95% de confianza equivale a 1,96 (usualmente) o en relación al 99% de confianza equivale 2,58, valor que queda a criterio del investigador.

EE = Límite aceptable de error muestral que generalmente cuando no se tiene su valor, suele utilizarse un valor que varía entre el 1% (0,01) y 9% (0,09), valor que queda a criterio del encuestador.

Para este trabajo en particular la muestra vendría dada por:

TAMAÑO DE MUESTRA

$$n = \frac{(p \cdot q) \cdot Z^2 \cdot N}{(EE)^2(N - 1) + (p \cdot q)Z^2}$$

n	260
p	0.5
q	0.5
Z	1.96
N	800
EE	0.05

De este modo tendríamos como muestra para nuestro estudio 260 imágenes de papas de forma aleatoria.

2.3. Variables, Operacionalización.

2.3.1 Variable Independiente. Método de clasificación automático de los defectos externos de solanum phureja.

2.3.2 Variable Dependiente. Clasificación automática de los defectos externos de solanum phureja.

Tabla 3: Matriz de operacionalización de las variables de la investigación.

VARIABLE INDEPENDIENTE	DIMENSIONES	INDICADORES	FÓRMULA	MÉTODOS, TÉCNICAS, INSTRUMENTOS DE RECOLECCIÓN DE DATOS
Método de clasificación de imágenes defectos externos	Procesamiento de Muestras	Tiempo de respuesta automático de los Observación de memoria RAM	$TF - TI = \frac{\text{Tiempo de Respuesta Consumo de CPU} - T_{CPU}}{TM - UM}$	Documentación Consumo de
VARIABLE DEPENDIENTE	DIMENSIONES	INDICADORES	FÓRMULA	MÉTODOS, TÉCNICAS, INSTRUMENTOS DE RECOLECCIÓN DE DATOS
Clasificación automática de los defectos externos de solanum phureja.	Clasificación	Exactitud Precisión	$P = \frac{NR + PR}{NR + FP + FN + PR}$	Ficha de observación Ficha de aceptación

		Grado de error	$FP + FM$	
			<hr/>	
		Curva	PT	
			PR	
			<hr/>	
			$FP + PR$	

Fuente: Elaboración propia (2021).

2.4. Técnicas e instrumentos de recolección de datos, validez y confiabilidad.

En esta investigación, se ejecutó la recolección de datos por medio de una entrevista con productores, comerciantes del mercado con mayor experiencia y tiempo en el rubro de comercialización y distribución mayorista del solanum phureja para conocer sus impresiones sobre los daños físicos más frecuentes, cuáles son sus causas y la manera de prevenirlos, luego se procedió a validar dichas informaciones mediante juicio de expertos.

Por otro lado, la construcción de una base de datos se desarrolló tomando fotografías que permitieran crear un dataset conformado por dos carpetas una donde ubicamos imágenes de la solanum phureja en buenas condiciones y otra donde se mostraban las principales características de rechazo por los daños físicos, lo que permitió evaluar las características propias y crear un estándar para el desarrollo del modelo y posterior aprendizaje del algoritmo.

Ficha de Observación.

Son particularidades de una técnica que consiste en determinar una investigación, acontecimiento o caso, recibir la información completa y registrarla para así analizarlo posteriormente y poder adquirir así la mayor cantidad de datos como investigador.

Documentación.

Se realizó consultas bibliográficas a distintas bases de datos con material bibliográfico (artículos, páginas web, etc.).

2.5. Procedimiento de análisis de datos.

Se sigue el cronograma prefijado, donde se estructuró en fechas y productos entregables. Se estimó como tiempo de desarrollo de la investigación un lapso de seis meses en los cuales se tuvo como meta lograr la realización de los objetivos trazados.

Para tal acción, procedimos a desarrollar una base de los datos de las imágenes de todos los tubérculos dividiéndolos en dos carpetas la primera en la cual se encontraban todas las solanum phureja en perfecto estado (sin las características físicas que definimos como dañadas) y en la otra carpeta las imágenes de los tubérculos con todas las características denominadas daño o defecto.

- Posteriormente se preparó y simplifíco cada imagen cambiándola a un formato en escala de grises.
- Se localizó el contorno de la solanum phureja en la imagen, la cual es nuestra región de interés mediante descriptores de contorno.
- Se realizó el procesamiento de imágenes con la base de datos haciendo al tamaño y los cambios de contraste invariantes, además, a la par, se estuvo utilizando algoritmos de los momentos invariantes.
- Para el aprendizaje sobre características dañadas en el tubérculo se utilizó redes neuronales convulsiónales.
- Finalmente se realizó las pruebas correspondientes con otros solanum phureja que no pertenecían a nuestra base de datos.

Detallar el significado de las siglas que se utilizaron en los indicadores.

NCPU:	Número de Procesos.
TI:	Tiempo de Inicio.
TF:	Tiempo Final.
TCPU:	Uso total del proceso del CPU.
TMR:	Total de Memória RAM.
UMR:	Uso de Memória RAM.
NR:	Real Negativo.
PR:	Real Positivo.
FP:	Falso Positivo.
FN:	Falso Negativo.

Consumo de CPU:

Calculamos cuanto es lo consumido al momento de ser empleado el algoritmo.

$$CPU = \frac{TCPU}{NCPU}$$

Donde:

Tabla 4: Especificación de las Variables de Consumo de CPU.

VARIABLE	DESCRIPCIÓN
TCPU	Uso total del Proceso del CPU.
NCPU	Número de procesos.

Tiempo de Respuesta:

Se calculó el tiempo total de respuesta del algoritmo que tarda en ejecutarse.

$$\text{Tiempo de respuesta} = TF - TI.$$

Donde:

Tabla 5: Especificación de las Variables del Tiempo de Respuesta.

VARIABLE	DESCRIPCIÓN
TI	Tiempo de Inicio.
TF	Tiempo Final.

Consumo de Memoria RAM:

Es el cálculo de la memoria RAM consumida mediante la ejecución del algoritmo.

Utilización de memoria.

$$\frac{TMR - UMR}{TMR}$$

Donde:

Tabla 6: Especificaciones de las variables de consumo de Memoria RAM.

VARIABLE	DESCRIPCIÓN
TMR	Total, de Memoria RAM.
UMR	Uso de Memoria RAM.

Exactitud:

La cantidad total de predicciones acertadas del algoritmo en base al número de predicciones realizadas.

Exactitud.

$$\frac{NR+PR}{NR+FP+FN+PR} = \frac{400+335}{400+37+28+335} = 0.92$$

Dónde:

Tabla 7: Especificación de la Variable Exactitud.

VARIABLE	ESPECIFICACIÓN
NR	Real Negativo.
PR	Real Positivo.
FP	Falso Positivo.
FN	Falso Negativo.

Grado de Error:

La cantidad total de predicciones acertadas de los algoritmos en base al número de predicciones realizadas.

Grado error =

$$\frac{FP+FN}{PT} = \frac{37+28}{800} = 0.08$$

Donde:

Tabla 8: Especificación de la Variable de Grado de Error.

VARIABLE	ESPECIFICACIÓN
FN	Erróneos Negativos
FP	Erróneos Positivos
PT	Población Total

Precisión:

Se calcula el total de predicciones positivas que el algoritmo acertado.

$$p = \frac{PR}{FP+PR} = \frac{335}{25+335} = 0.93$$

Donde:

Tabla 9: Especificación de la Variable de Precisión.

VARIABLES	ESPECIFICACIÓN
PR	Real Positivo.
FP	Erróneo Positivo.

Curva:

Para poder calcular la cantidad final de predicciones positivas que se realizaron se aplica lo siguiente:

$$\text{Curva} = \frac{PR = 335}{FP+PR 37+335} = 0.90$$

Donde:

Tabla 10: Especificación de la Variable Curva.

VARIABLE	ESPECIFICACIÓN
PR	Real Positivo
FP	Erróneo Negativo

2.6. Criterios éticos.

Tomando como referencia los lineamientos de la Universidad Señor de Sipán [29], esta investigación tuvo conocimiento sobre las normas éticas a nivel nacional e internacional, las cuales fueron tomadas en cuenta para el desarrollo de la misma. Existen regulaciones que explican la necesidad actual de usar la relación beneficioriesgo, cuando se va a realizar una intervención o experimentar con individuos. De igual modo, se tienen que considerar las buenas prácticas para que los sujetos que participan en el estudio se encuentren debidamente informados de los objetivos, riesgos y beneficios del mismo, así como de las alternativas que existan durante su ejecución.

2.7. Criterios de Rigor Científico.

Se estimaron y describieron supuestos con la finalidad de mostrar los límites de acción, las preocupaciones, considerando especialmente el principio de la coherencia interna la cual es fundamental tomar en cuenta. Se entendió por tanto que, la coherencia interna estuvo relacionada con la forma del cómo expresar la estructura con cada uno de los aspectos que la componen dentro de la investigación en relación con el fin de engranarlos de forma eficiente.

Del mismo modo, considerando los criterios de calidad, se elaboraron unos parámetros con el fin de tener total entendimiento del proceso y la complejidad que ello conlleva en toda su extensión. Para lograr este objetivo, se requirió de observar en retrospectiva los hallazgos y resultados encontrados con la finalidad de comprender el rigor del status científico, con el que se realizó la investigación siguiendo los criterios de credibilidad, transferibilidad, dependencia y conformabilidad.

III. RESULTADOS.

3.1. Resultados en Tablas y Figuras.

En esta sección, se muestran los resultados logrados por las redes neuronales convolucionales en sus dos etapas de entrenamiento y pruebas, y para realizar las mediciones de estos indicadores en etapa de entrenamiento, se hizo uso de la herramienta administrador de procesos de Windows que permiten visualizar el porcentaje utilizado por el CPU y la memoria RAM en tiempo real en el momento de cada uno de los experimentos.

Y en etapa de pruebas se hizo uso de una matriz e confusión mediante la librería de Python Sklern que permiten hacer mediciones exactas del tiempo de respuesta, Precisión, Exactitud. La medición de consumo de CPU permitió conocer cuál es el consumo en porcentaje que utiliza la red neuronal y se realizó tres mediciones.

Tabla 11: Red Neuronal Convolutacional.

N°	Red Neuronal Convolutacional	Mediciones
1	RNC	3

En la siguiente figura se aprecia los resultados obtenidos por la red Convolutacional cuyo consumo promedio de CPU es de 11%.

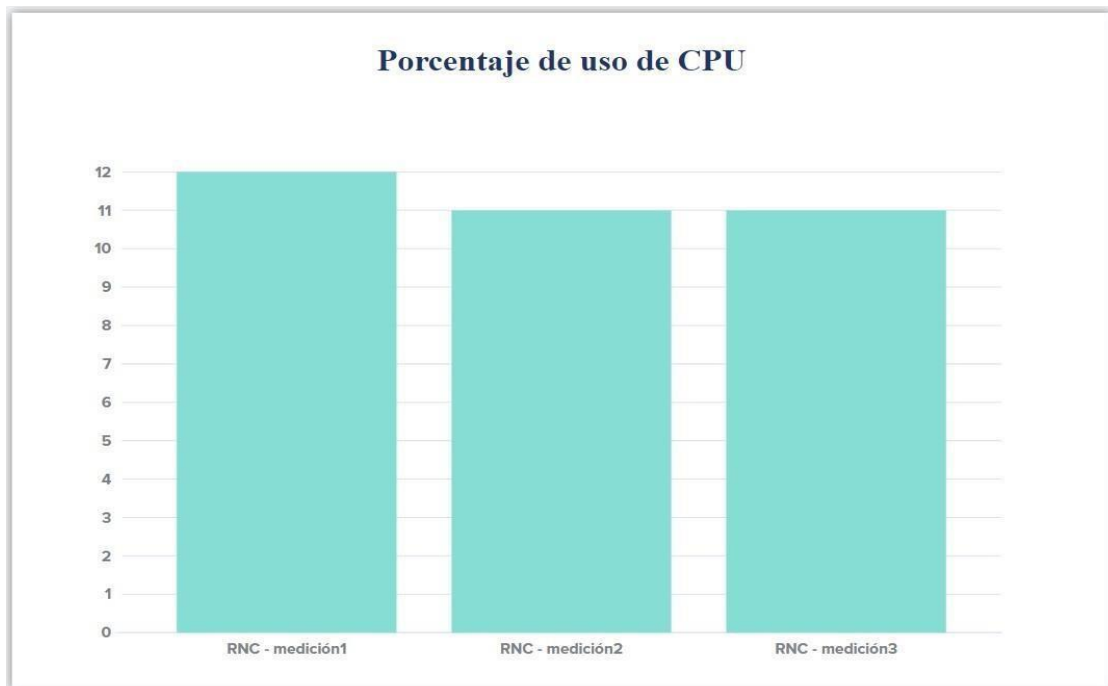


Figura 7: Resultados obtenidos por la red Convolutacional cuyo consumo promedio de CPU es de 11%.

Además, se realizó la medición del consumo de memoria RAM pues la ejecución de cada una de las redes convolucionales hace uso de memoria RAM donde almacena la información temporal de las ejecuciones que se realizan. Es importante conocer este indicador puesto que se propone el método como una posible solución a un ambiente de producción donde se requerirá el óptimo rendimiento por parte del sistema.

Se realizó tres mediciones de consumo de memoria RAM por la ejecución de la RNC como se observa en la tabla 12.

Tabla 12: Red Neuronal Convolucional.

N	Red Neuronal Convolucional	Mediciones
1	RNC	3

En el siguiente gráfico se aprecia los resultados obtenidos por la red Convolutiva cuyo consumo promedio de RAM es de 15%.

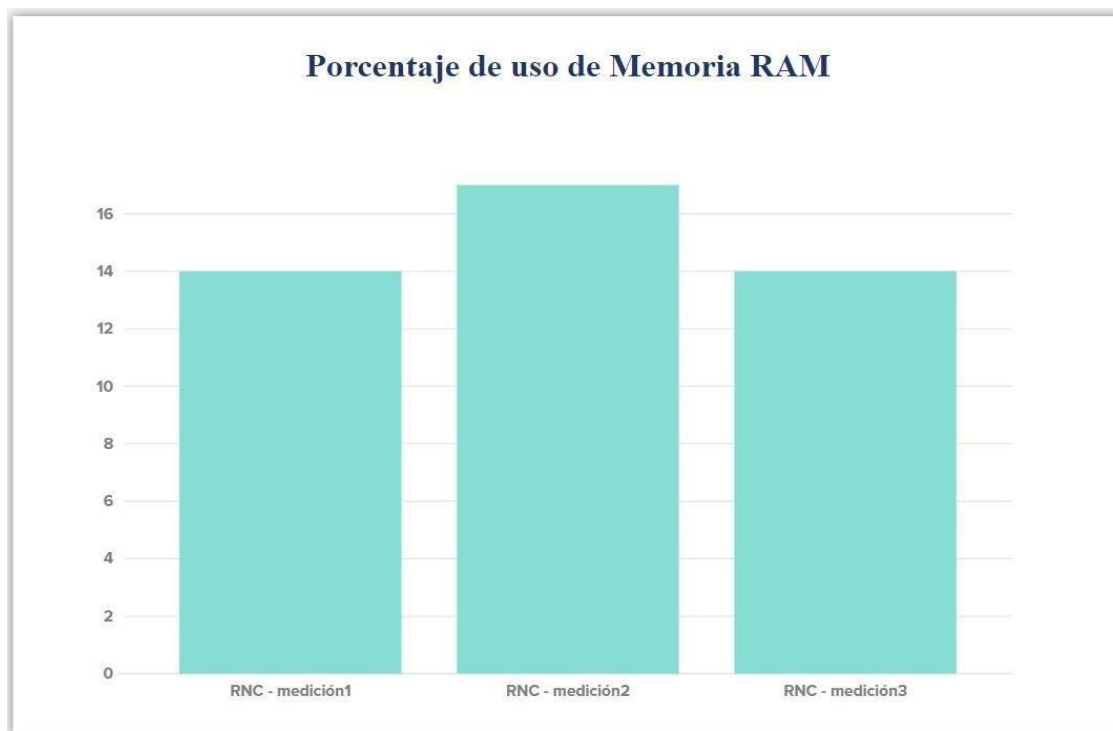


Figura 8: Resultados obtenidos por la red Convolutiva cuyo consumo promedio de RAM es de 15%.

En esta etapa de entrenamiento también se tomó en cuenta la medición del tiempo de respuesta que tardó el sistema en segundos la etapa de entrenamiento de las fotos de 800 solanum phureja. Es importante conocer este recurso computacional pues en un ambiente de producción de control de acceso de gran volumen podría fallar en su desempeño.

La medición del tiempo de respuesta de esta investigación fue a través de un contador de tiempo, que se implementó mediante un script de código Python dentro de la etapa de la red neuronal en entrenamiento.

Para la medición fueron realizadas tres mediciones de consumo de tiempo de respuesta como se puede mostrar en la tabla 13.

Tabla 13: Red Neuronal Convolutacional.

N°	Red Neuronal Convolutacional	Mediciones
1	RNC	3

En el siguiente gráfico se muestra el resultado de cantidad de tiempo de respuesta promedio de la ejecución de la red neuronal Convolutacional donde obtuvo 2482 segundos.

3000

2616




Figura 9: Tiempo de respuesta

En la figura anterior se muestra el tiempo promedio respuesta en cada medición. Donde en la segunda medición el tiempo respuesta es más bajo, esto debe a la aleatoriedad en que se prenden o se apagan neuronas dentro de la capa oculta para así poder evitar la memorización de la RN.

En la etapa de entrenamiento de aprendizaje de las imágenes digitales de solanum phureja se hizo la medición de la precisión de buenas o malas papas. Se pudo determinar que la precisión en buenas papas es del 93% y la precisión en malas papas es del 88%.

100%

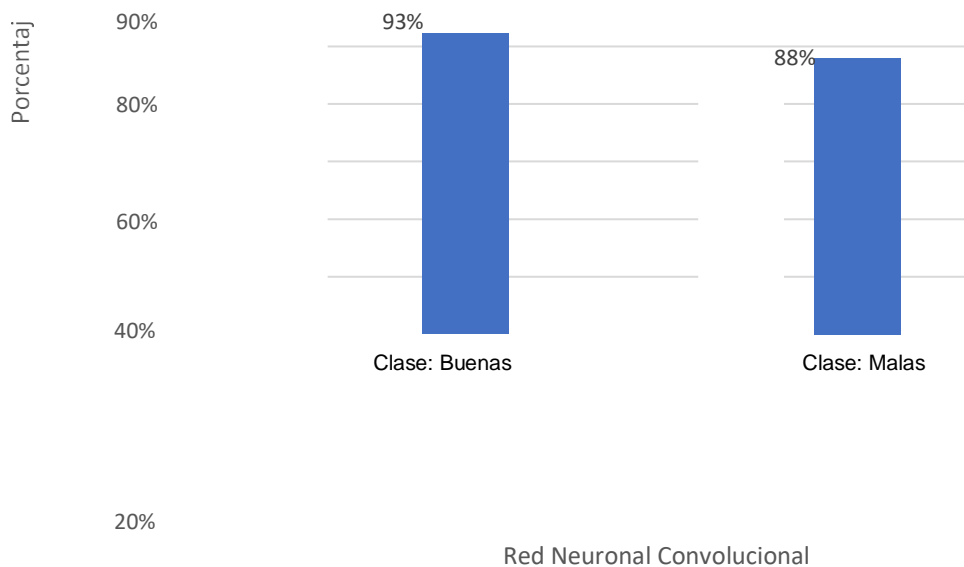


Figura 10: Precisión de la red neuronal.

Es posible apreciar, en el gráfico, que, el porcentaje de precisión es ligeramente menor en la clase: “malas papas”, es decir que es más fácil entrenar y aprender a clasificar las “buenas papas”.

El uso de redes convolucionales para el reconocimiento está relacionado con la exactitud porque permite medir el porcentaje de clases que el modelo de esta investigación ha acertado en el reconocimiento de solanum phureja.




Figura 11: Exactitud de la RN

Se percibe en el gráfico que el porcentaje de exactitud es alto (92%), es decir los resultados que nos dará la red son confiables.

Resumen de Indicadores de la investigación.

Tabla 14: Red Neuronal Porcentaje.

C R T. Precisión(buenas/mala Exactit PU AM Respuesta s) ud					
Red Neuronal	1 1%	1 5%	2482 seg.	93% / 88%	92%

En la tabla número 14 se percibe un resumen de los resultados que se han obtenido de cada uno de los indicadores de las pruebas donde se observa un bajo consumo de CPU, un uso de memoria RAM aceptable, un tiempo de respuesta de entrenamiento menor a una hora, alta precisión para reconocer cada clase y una exactitud que nos permite tener confianza en los resultados.

3.2. Discusión de resultados.

En la presente investigación se obtuvo 92 % de exactitud, frente a la investigación de [15] denominada “Clasificación de frutas basadas en redes neuronales convolucionales” donde se obtuvo 87% de exactitud. Esto se debe a que usaron un modelo de transferencia de aprendizaje complejo denominado Mobilenet que requería imágenes de alta calidad, además el modelo fue entrenado en un lenguaje de programación no especializado para machine learning (Matlab).

Se observó que el método que aplicaron en la investigación es una red muy compleja y, por ende, hicieron uso de muchos recursos en comparación de la presente propuesta de investigación donde se logró buenos resultados lo que la hace eficiente.

Por otro lado, en [30] se obtuvo 85% de exactitud en su investigación titulada: “Análisis Comparativo de las técnicas utilizadas en un Sistema de Reconocimiento de Hojas de Planta”, en México abordaron el problema acerca del reconocimiento e identificación de hojas indicaron que la combinación de las diferentes características es necesaria para obtener una buena precisión de clasificación. Esto se debe a que

el método utilizado fueron los algoritmos de segmentación frontera adaptativa y una fase de PCA utilizando un clasificador bayesiano, el algoritmo de aprendizaje backpropagation para redes neuronales y SVM.

En la investigación “Fruit classification using convolutional neural networks” se obtuvo 85 % de exactitud con la red neuronal Resnet50, tuvo un dataset de 100 imágenes por clase mientras que en esta investigación se usaron muestras en un ambiente controlado de 700 imágenes para entrenar la red y 100 imágenes para predecir sabiendo que las redes convolucionales convergen mejor mientras más imágenes se tenga. Es por ello que esta investigación a pesar de su baja cantidad de muestras tiene un muy buen resultado.

3.3. Aporte práctico.

Construir una base de datos con imágenes digitales de solanum phureja considerando las características físicas de calidad. Para el desarrollo de un método de clasificación automática de los defectos externos de solanum phureja para cumplir con las exigencias del mercado peruano utilizando aprendizaje de máquina (redes neuronales convolucionales) se procede al acondicionamiento de un ambiente controlado para la adquisición de las imágenes que conformaron la base de datos de entrenamiento. Para ello, se utilizó un cubo acrílico o caja de luz foto estudio (ver Figura 11).



La estructura de la caja de luz comprende un orificio donde se coloca la cámara para la toma de las imágenes, a

Figura 12: Caja de luz foto estudio para la adquisición una altura de 40 de imágenes reales de la *solanum phureja*. cm con respecto a la base. Se elige esta elevación porque permite enfocar la *solanum phureja* en toda su región. En la figura 12, se especifican las dimensiones de la caja de luz foto estudio.




Figura 13: Dimensiones y estructura de la caja de luz foto estudio.

La caja de luz foto estudio cuenta con una iluminación proporcionada por luces LED blancas, las cuales están incorporadas en la parte superior. Esto permitió eliminar la sombra que produce la luz externa dentro de la caja blanca como observable en la figura 13:



Figura 14: Posición de las luces LED blancas en la caja de luz foto estudio.

Al desactivar los LEDS (ver Figura 14) se produce una sombra en la base y en la solanum phureja. Por lo tanto, al añadirlas en la parte superior se logró tener una mejor iluminación, más uniforme, dentro de la caja; obteniendo claridad en la imagen de solanum phureja.




Figura 15: Visualización de la solanum phureja dentro de la caja de luz, con y sin luz LED.

Tabla 15: Materiales utilizados para el acondicionamiento del ambiente controlado requerido para la adquisición de las imágenes.

Estructura para la adquisición de imágenes	
Caja	Acrílico.
Tamaño	40x40x40 cm ³
Fuente de iluminación	Leds (1100 lumen).
Temperatura de color	6000 - 6500 Kelvin.
Fuente de alimentación	5 voltios.
Potencia	15 watts.

Las imágenes fueron recolectadas con una resolución de 4 megapíxeles para tener una mayor información de las características físicas de la solanum phureja, con un tamaño de 1280x750 píxeles aproximadamente. Para la configuración de la cámara se dejaron algunos valores por defecto, es decir, para la sensibilidad (ISO) se

determinó un valor de 100 porque la fuente de iluminación daba una claridad en el entorno, por lo tanto, permitió captar menos luz. Además, no se modificó la distancia focal porque a 40 cm se obtuvo una buena representación de la solanum phureja, el valor por defecto es 23 mm (ver la figura 15).



Figura una distancia focal de 40 cm. 16: Imagen digital de la solanum phureja adquirida a

Las imágenes adquiridas fueron de 800 solanum phureja y quedaron organizadas en distintas carpetas nombradas por clase, de tal manera que se pudo diferenciar a los individuos de manera que no se repitieran, visualizándose como se observa en la siguiente imagen:




Figura 17: Organización de imágenes adquiridas en carpetas ordenadas

[31] explica los métodos y procesos que se han empleado en un sistema de identificación y clasificación de enfermedades encontradas en cultivos de papa usando el procesamiento de imágenes en 400 fotografías distribuidas en 70% para entrenamiento y 30% para validación, la cual aprueba determinar las fases que presentan la Alternariosis, enfermedad muy usual perteneciente al cultivo de Papa;

sin embargo, debido a los diversos tipos de enfermedades presentes en la hoja de papa, se aplicó también, para determinar los tres características de papas:

Características externas de la solanum phureja.

A continuación, por medio de la observación se realizó el levantamiento de las características físicas que el mercado exige tenga la solanum phureja para poder ser comercializado como una papa de calidad. Estas son: tamaño grande (alargado o redondo), de pocos orificios en la superficie de la solanum phureja, de piel delgada, lisa, limpios y libres de impurezas. A continuación, se detallan los casos de mala condición externa de las solanum phureja que son considerados en esta investigación.

Grietas exorbitantes. Defecto común ocasionado, en su mayoría, a muy bajas temperaturas (ver Figura 17).



Figura 18: Solanum phureja con grietas exorbitantes.

Manchas oscuras. Estas se producen debido a una lesión en la superficie de la papa en la etapa de cosecha o, por alguna plaga y/o enfermedad la cual hace que entre en proceso de putrefacción (ver Figura 18).



Figura 19: *Solanum phureja* con manchas oscuras.

Deformaciones. Las deformaciones son algo atípico en la *Solanum phureja* es algo atípico; en su mayoría tienden a mantener una forma esférica. Estas deformaciones se observan cuando la papa tiene un crecimiento anormal, y comúnmente, se debe a los flujos de temperatura y a la plantación inadecuada (ver Figuras 19 y 20).



Figura 20: *Solanum phureja* con deformación.

Tabla 16: Trastornos fisiológicos y deformación asimétrica seleccionadas para determinar las características de calidad de la papa en el mercado peruano.

Figura 21: *Solanum phureja* con trastornos fisiológicos y deformación

Defecto	Color	Textura	Forma
Grieta	Si	No	No
Mancha oscura	Si	Si	No



Por otra parte, del total de muestras recolectadas se obtuvo la distribución, según su estado, de solanum phureja que es mostrada en la Tabla 19.

Tabla 17: Distribución de la muestra de solanum phureja almacenadas.

Muestra solanum phureja	Trastorno	Cantidad
Papa en buen estado		400
Papa en mal estado	Grieta	208
	Mancha	144
	Deformación	48

Una vez que se obtuvo la recopilación de las imágenes digitales, éstas fueron seleccionadas de acuerdo a sus características físicas y almacenadas en dos carpetas PB y PM (ver Figura 21). En la carpeta PB se guardaron las imágenes digitales de las solanum phureja que evidenciaron algún trastorno fisiológico o una deformación asimétrica en su estructura (ver Figura 22). Con respecto a la carpeta PM, se guardaron solanum phureja en perfectas condiciones (ver Figura 23). Se realizó la distribución de las imágenes tomando como base en el principio de Pareto (ver Tabla 18).

Tabla 18: Distribución de imágenes en la carpeta entrenamiento y validación.

UBICACIÓN	PB	PM	Total
Entrenamiento	250	250	500
Validación	150	150	300




Figura 22: Estructura de la carpeta Dataset.




Figura 23: Solanum phureja contenidas en la carpeta PB del Data set.



Figura 24: Solanum phureja contenidas en la carpeta PM del Data set.

Seguidamente, se implementó un algoritmo para modificar el nombre de las imágenes digitales de las Solanum Phureja. Estas imágenes fueron renombradas como papas Buenas_etiquetado.jpg, donde N es un contador de la cantidad de imágenes que se tiene en la carpeta y el etiquetado solo tiene dos valores, 0 para la carpeta Papas Buenas y 1 para la carpeta Papas Malas. Posteriormente se elaboró el flujo de trabajo que se implementó para procesar cada imagen y obtener las características que son utilizadas por el algoritmo de aprendizaje supervisado.

Seleccionar algoritmos de procesamiento de imágenes y aprendizaje de máquina con mejor desempeño en clasificación.

En esta investigación se usan algoritmos de procesamiento de imágenes que son aplicados en algunos casos aleatoriamente debido que la imagen que está siendo procesada por la RNC puede estar en algunos casos escalada, rotada, trasladada, en escala de grises, contener ruido; de esta manera poder simular la manera en que un ser humano entiende o capta un objeto.

Tabla 19: Evaluación de los algoritmos de procesamiento de imágenes usados en la investigación.

Filtros Utilizados	Binarización	Suavizado Gaussiano	Filtro de Mediana	la Filtro Laplaciano
Complejidad	Lineal	Lineal	cuadrática	cuasi lineal
Aplicación	Siempre	Siempre	aleatoriamente	aleatoriamente
Canny	Lineal	Siempre	siempre	siempre

Tabla 20: Evaluación de algoritmos de aprendizaje de máquina usados en la investigación.

RNC	SVM (soport KNN vector machine)
-----	---------------------------------

Velocidad	Rápida	normal	Normal
Exactitud	Alta	Alta	Alta
Data Set	con bajo ruido	con bajo ruido	con bajo ruido
Mantenimiento	relativamente sencillo	Regular	regular

RNC: Redes Neuronales Convolucionales.

SVM: Maquinas de soporte Vectorial.

KNN: k vecinos más próximos.

Se seleccionó la RNC por motivos principalmente de la velocidad y de su buena capacidad de mantenimiento.

El algoritmo que hemos utilizado se llama retro propagación (Backpropagation).

Implementar los algoritmos de procesamientos de imágenes.

El algoritmo de Binarización.

Es usado para convertir una imagen a colores en blanco y negro, de esta manera podemos trabajar más concisamente con los píxeles importantes. Los Problemas: Ruido, efectos de iluminación.

Elegir un valor de umbral T para toda la imagen.

Según el nivel de gris de cada píxel, y el umbral elegido, cada píxel formará parte de uno de los siguientes conjuntos.

Conjunto de píxeles negros (0): $\text{imagen}(i;j) < T$

Conjunto de píxeles blancos (1): $\text{imagen}(i;j) \geq T$

Retornar imagen_binarizada

Figura 25: Algoritmo de Binarización.

El algoritmo de suavizado gaussiano.

Permite que los tonos de los píxeles estén cercanos uno al otro, lo que provoca que la imagen resalte bordes y detalles.

```
imgBlurred = np.zeros((alto, ancho, 1), np.uint8)
imgBlurred = cv2.GaussianBlur(imgMaxContrastGrayscale, TAMAÑO_FILTRO_SUAVE_GAUSIANO, 0)
```

Figura 26: Algoritmo de suavizado gaussiano.

El algoritmo de segmentación tiene como objetivo separar la imagen principal en regiones significativas.

```
#DETECTAMOS CONTORNOS.
contornos, _ = cv2.findContours(binaria, cv2.RETR_TREE, cv2.CHAIN_APPROX_SIMPLE)
#DIBUJAMOS CONTORNOS SOBRE "imagen".
imagen = cv2.drawContours(imagen, contornos, -1, (0, 255, 0), 2)
```

Figura 27: Algoritmo de segmentación.

Algoritmo de la Mediana.

Mejora la nitidez y resalta los colores en una imagen, además reduce el ruido.

Es un algoritmo $O(n^2)$.

```
def median_filter(data, kernel_size):
    temp = []
    indexer = kernel_size // 2
    data_final = []
    data_final = np.zeros((len(data), len(data[0])))
    for i in range(len(data)):

        for j in range(len(data[0])):

            for z in range(kernel_size):
                if i + z - indexer < 0 or i + z - indexer > len(data) - 1:
                    for c in range(kernel_size):
                        temp.append(0)
                else:
                    if j + z - indexer < 0 or j + indexer > len(data[0]) - 1:
                        temp.append(0)
                    else:
                        for k in range(kernel_size):
                            temp.append(data[i + z - indexer][j + k - indexer])

            temp.sort()
            data_final[i][j] = temp[len(temp) // 2]
            temp = []
    return data_final
```

Figura 28: Algoritmo de la Mediana

El nivel de gris de un pixel de la imagen se reemplaza por la mediana de los niveles de gris de la vecindad (usualmente de tres por tres).

Algoritmo Laplaciano.

El Laplaciano tiene la función bidimensional f , es un operador de derivación isotrópico (independiente de la dirección de la discontinuidad de la imagen) definido por:

Como en el caso del gradiente, la ecuación de Laplaciano puede desarrollarse en forma digital de varias maneras, la más habitual en la práctica es aplicar la siguiente máscara.

0	1	0
1	-4	1
	0 1	0

```
def calculate(x,y,sigma):
    return ((x**2+y**2-2*sigma**2)/sigma**4)*math.exp(-1*(x**2+y**2)/2*sigma**2)

def create_log_filter(size,sigma):
    matrix=[[0] * size for i in range(size)]
    for i in range(size):
        for j in range(size):
            matrix[i][j]=calculate(i-(size-1)/2,j-(size-1)/2,sigma)
    return matrix

x = create_log_filter(3,1.4)
for line in x:
    print(line)
```

Figura 29:Máscara de la ecuación de Laplaciano.

3.5 Implementar el método de clasificación automática de solanum phureja utilizando los algoritmos seleccionados.

Es importante identificar los daños que se pueden ocasionar a lo largo del paso del tiempo o las condiciones climáticas en la solanum phureja en una etapa temprana para evitar que sean vendidos a bajo costo o se pudran por no llegar a ser vendidos por su baja calidad. En la siguiente figura se señala el diseño del esquema usado

para la implementación de los algoritmos para detectar la condición externa en las solanum phureja.




Figura 30: Esquema usado para la implementación de los algoritmos para detectar la condición externa en las solanum phureja.

El primer paso es obtener un conjunto de imágenes en un ambiente controlado de solanum phureja que cumplan con requisitos descritos en segmentos posteriores. Luego, estas imágenes se importa un conjunto de librerías que prepara el entorno para construir y entrenar un modelo de aprendizaje profundo utilizando la arquitectura MobileNet, con procesamiento y aumentación de imágenes: como tensorflow y os

```
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import MobileNet
from tensorflow.keras.layers import GlobalAveragePooling2D, Dense, Dropout
from tensorflow.keras.models import Model
from sklearn.model_selection import train_test_split
import os
from tensorflow.keras import regularizers
```

Figura 31: Módulos de convolución para la extracción de características de solanum phureja

Se realiza la respectiva conexión de Colab con Google Drive para cargar el dataset ubicado en drive.

```
# Importar la biblioteca para montar Google Drive
from google.colab import drive

# Montar Google Drive en el entorno de Colab
drive.mount('/content/drive')

# Acceder a las imágenes en Google Drive
dataset_dir = "/content/drive/MyDrive/EJERCICIO DE MOVILES/Dataset"
papa_buena_dir = os.path.join(dataset_dir, "PapaBuena")
papa_mala_dir = os.path.join(dataset_dir, "PapaMala")
```

Figura 32: Estructura de la red neuronal convolucional

Se procesa las imágenes del dataset y se crea generadores de datos de imágenes

```
# Preprocesamiento de imágenes
image_size = (224, 224) # Tamaño de imagen para MobileNet
batch_size = 32

# Crear generadores de datos de imágenes
train_datagen = ImageDataGenerator(
    rescale=1./255,
    validation_split=0.2, # Dividir automáticamente en conjuntos de entrenamiento y validación
    rotation_range=20,
    width_shift_range=0.2,
    height_shift_range=0.2,
)

train_generator = train_datagen.flow_from_directory(
    dataset_dir,
    target_size=image_size,
    batch_size=batch_size,
    class_mode='binary',
    subset='training', # Utilizar subconjunto de entrenamiento
```

```
)

validation_generator = train_datagen.flow_from_directory(
    dataset_dir,
    target_size=image_size,
    batch_size=batch_size,
    class_mode='binary',
    subset='validation', # Utilizar subconjunto de validación

)
```

Se carga el MobileNet para el Pre-entrenado y luego poder modificar para la clasificación binaria.

```
# Cargar MobileNet pre-entrenado y modificar para clasificación binaria
base_model = MobileNet(weights='imagenet', include_top=False, input_shape=(224, 224, 3))

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dropout(0.5)(x)
output = Dense(1, activation='sigmoid')(x)
#output = Dense(1, activation='sigmoid', kernel_regularizer=regularizers.l1(0.01))(x)

model = Model(inputs=base_model.input, outputs=output)
```

Se congela las capas base

```
# Congelar las capas base (no se entrenarán durante el proceso de entrenamiento)
for layer in base_model.layers:
    layer.trainable = False
```

Se compila, se entrena y se evalúa el modelo de clasificación

```
# Compilar el modelo
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])

# Entrenar el modelo
epochs = 30
model.fit(train_generator, epochs=epochs, validation_data=validation_generator)

# Evaluar el modelo
loss, accuracy = model.evaluate(validation_generator)
print("Loss:", loss)
print("Accuracy:", accuracy)
```

Luego de hacer el proceso de compilar, entrenar y evaluar el modelo, nos imprime el resultado de clasificación respecto a la imagen de la dataset.

```
[ ] print("Clases asignadas:", train_generator.class_indices)

↩ Clases asignadas: {'PapaBuena': 0, 'PapaMala': 1}
```

Importamos nuevas librerías que nos ayudaran para evaluar y visualizar el rendimiento de un modelo de clasificación de la solanum phureja.

```
[ ] import numpy as np
import matplotlib.pyplot as plt
from sklearn.metrics import confusion_matrix, classification_report
```

A continuación, se obtienen las predicciones del modelo en el conjunto de validación. También se obtienen las etiquetas verdaderas del conjunto de validación (papa Buena y papa Mala)

Se calculará y se mostrará la precisión y por último se calculará y mostrará la matriz de confusión.

```

# Obtener las predicciones del modelo en el conjunto de validación
predictions = model.predict(validation_generator)
y_pred = np.round(predictions).flatten() # Convertir las probabilidades en clases (0 o 1)

# Obtener las etiquetas verdaderas del conjunto de validación
y_true = validation_generator.classes

# Calcular y mostrar la precisión
accuracy = np.mean(y_pred == y_true)
print("Accuracy:", accuracy)

# Calcular y mostrar la matriz de confusión
conf_matrix = confusion_matrix(y_true, y_pred)
print("Confusion Matrix:")
print(conf_matrix)

```

Se mostrará la matriz de confusión por medio de un gráfico.


```

# Mostrar la matriz de confusión gráficamente
plt.figure(figsize=(8, 6))
plt.imshow(conf_matrix, interpolation='nearest', cmap=plt.cm.Blues)
plt.title('Confusion Matrix')
plt.colorbar()
tick_marks = np.arange(2)
plt.xticks(tick_marks, ['Papa Mala', 'Papa Buena'], rotation=45)
plt.yticks(tick_marks, ['Papa Mala', 'Papa Buena'])
plt.xlabel('Predicted Label')
plt.ylabel('True Label')
for i in range(2):
    for j in range(2):
        plt.text(j, i, str(conf_matrix[i, j]), ha='center', va='center', color='white')
plt.show()

```

Se calculará e imprimirá el reporte de clasificación por medio de un gráfico.

```
# Calcular e imprimir el reporte de clasificación
class_names = ['Papa Mala', 'Papa Buena']
print("Classification Report:")
print(classification_report(y_true, y_pred, target_names=class_names))
```



Se genera el modelo en un formato TensorFlow en Google Drive, especificando una ruta donde se guardará el modelo.

```
[ ] # Guardar el modelo en formato TensorFlow en Google Drive

# Especificar la ruta donde deseas guardar el modelo en formato TensorFlow en tu Google Drive
ruta_modelo_tf = '/content/drive/MyDrive/ModeloCCN_PapaAmarilla/modelo_tf_papa'

# Guardar el modelo en formato TensorFlow SavedModel en Google Drive
tf.saved_model.save(model, ruta_modelo_tf)

print("¡Modelo guardado exitosamente en formato TensorFlow en Google Drive!")
```

Con la ruta especificada anteriormente se encuentra el archivo del modelo de clasificación en el Google drive.

Se crea una carpeta en cualquier disco, en este caso D, para realizar el código de una página web con Flask.



Dentro de visual se importan dichas librerías para poder levantar la página web con el modelo de clasificación de papas.

```
from flask import Flask, render_template, request, Response
import tensorflow as tf
import numpy as np
from PIL import Image
import traceback

app = Flask(__name__)
```

Se ubica la ruta donde se encuentra el modelo de clasificación generada en el Colab.

```
# Ruta al modelo en el disco local
ruta_modelo_local = 'D:/modelo_tf_papa'
```

Se crea una función para preprocesar la imagen antes de pasarla al modelo

```
# Función para preprocesar la imagen antes de pasarla al modelo
def preprocess_image(image):
    image = image.resize((224, 224))
    image = np.array(image.convert('RGB'), dtype=np.float32) / 255.0
    image = np.expand_dims(image, axis=0)
    return image
```

Se carga el modelo de Tensorflow de clasificación.

```
# Cargar el modelo TensorFlow SavedModel
try:
    # Intentar cargar el modelo desde la ruta especificada
    loaded_model = tf.saved_model.load(ruta_modelo_local)
except Exception as e:
    # Imprimir un mensaje de error si el modelo no se puede cargar
    print("Error al cargar el modelo:", str(e))

# Ruta para la página principal y la ruta para realizar la predicción
@app.route("/")
@app.route('/realizar_prediccion', methods=['GET', 'POST'])
def realizar_prediccion():
    if request.method == 'POST':
        try:
            # Verificar si se ha subido una imagen en la solicitud
            if 'imagen' not in request.files:
                return render_template('modelo.html', resultado="Error: No se ha proporcionado ninguna imagen.")

            # Obtener la imagen del formulario
            imagen = request.files['imagen']

            # Verificar si se ha subido un archivo de imagen vacío
            if imagen.filename == '':
                return render_template('modelo.html', resultado="Error: No se ha proporcionado ninguna imagen.")

        except:
            # Abrir la imagen y preprocesarla
            image = Image.open(imagen)
            image = preprocess_image(image)

            # Realizar la predicción utilizando el modelo cargado
            resultado_prediccion = loaded_model(image)

            # Interpretar el resultado de la predicción
            if resultado_prediccion >= 0.5:
                resultado = "Papa Mala"
            else:
                resultado = "Papa Buena"

            # Renderizar la plantilla HTML con el resultado de la predicción
            return render_template('modelo.html', resultado=resultado)
```

Figura 33: Patrón mostrado en la sesión de entrenamiento. El archivo modelo.html es una plantilla HTML que forma parte de una aplicación web desarrollada con Flask. Está guardado en la carpeta templates y su propósito es proporcionar una interfaz de usuario para cargar una imagen de una papa, enviar la imagen al servidor para su procesamiento y mostrar el resultado de la predicción.

Se mejoraron los mensajes de error y se añadieron descripciones más específicas en los bloques print para facilitar la depuración.

```
2 # Renderizar la plantilla HTML con el resultado de la predicción
3 return render_template('modelo.html', resultado=resultado)
4
5 except Exception as e:
6 # Imprimir un mensaje de error si hay un problema al procesar la imagen
7 print("error:", str(e))
8 traceback.print_exc()
9 return render_template('modelo.html', resultado="Error al procesar la imagen.")
10
11 except Exception as e:
12 # Imprimir un mensaje de error si hay un problema al realizar la predicción
13 print("error:", str(e))
14 traceback.print_exc()
15 return render_template('modelo.html', resultado="Error al realizar la predicción.")
16
17 # Renderizar la plantilla HTML para GET requests
18 response = Response(render_template('modelo.html'))
19 # Configurar las cabeceras de la respuesta para evitar el almacenamiento en caché
20 response.headers['Cache-Control'] = 'no-store, no-cache, must-revalidate, max-age=0'
21 response.headers['Pragma'] = 'no-cache'
22 return response
23
24 # Ejecutar la aplicación Flask en modo de depuración
25 if __name__ == "__main__":
26     app.run(debug=True)
```

Figura 34: código y parámetros seleccionados.

Al ejecutar el código y presionar "Run", obtendremos como respuesta la dirección URL que cargará la página web de clasificación de la solanum phureja.



Figura 35: Código de acuerdo con el desarrollo del algoritmo principal.

Se selecciona la imagen a evaluar y luego hacer click en el botón realizar



Figura 36 Código de acuerdo con el desarrollo del algoritmo principal.

Finalmente, el programa nos arrojará el estado en el que se encuentra la papa. En este caso fue una papa en mal estado.




Figura 37 Código de acuerdo con el desarrollo del algoritmo principal

Realizar las pruebas al prototipo.

Para realizar las pruebas del sistema se usarán las métricas más importantes de una matriz de confusión, es decir Exactitud, Precisión. Se tomó una muestra representativa de 800 imágenes de solanum phureja.

Exactitud:

La exactitud nos da una visión general de los aciertos que ha tenido el sistema, es decir en donde los caracteres de la placa determinada por el sistema son exactamente igual a los caracteres de la placa real.

$$Exactitud = \frac{735}{800}$$

$$Exactitud = 0.92$$

Precisión:

Nos permite conocer la exactitud en cada clase que determina el sistema. Se pudo determinar que la precisión en buenas papas es del 93% y la precisión en malas papas es del 88%.

Clase: "Buenas papas"

$$Precision(buenas papas) = \frac{740}{800}$$

$$Precision(buenas papas) = 0.93$$

Clase: "Malas papas"

$$Precision(malas papas) = \frac{710}{800}$$

$$Precision(malas papas) = 0.88$$

Tabla 21: Matriz de confusión.

n = 800

Predicho (No)

Predicho (Si)

Actual (No)	400	37
Actual (Si)	28	335

Discriminando, se tiene que:

400 predicciones reales negativas, Es decir, el algoritmo acertó 400 veces al decir que la papa no está defectuosa.

37 predicciones erróneas de clase positiva (erróneos positivos). El algoritmo se confundió y dijo 25 veces que la papa estaba defectuosa cuando era apta para el consumo.

28 predicciones erróneas de clase negativa (erróneos negativos). El algoritmo predijo 28 veces que la papa no era defectuosa y resulta que si lo es.

335 predicciones correctas de clase positiva (positivos reales). El algoritmo acertó 335 veces al predecir que la papa era defectuosa.

Tomando como base estos valores se calcula la exactitud y la precisión del algoritmo obteniendo un 92% y un 93%, respectivamente. El algoritmo tiene un margen de error aceptable, con respecto a la clasificación de otros estudios, según el estado del arte.

Cálculo de la exactitud.

$$\begin{aligned}
 NR + PR AC &= \frac{400 + 335}{400 + 37 + 28 + 335} \\
 &= \frac{735}{800} \\
 AC &= 0.92
 \end{aligned}$$

Cálculo de la precisión

$$P = \frac{PR}{FP + PR}$$

$$\frac{335}{25 + 335} \quad P =$$

$$P = \frac{335}{360} = 0.93$$

Representa el flujo de la investigación de la red neuronal convolucional.




Figura 33: Diseño de la Investigación.

Flujo de Datos de la red Neuronal explicando Detalladamente.

Este flujo está separado por bloques y columnas.

En el primer bloque de la primera columna se refiere a la entrada donde inicia el trabajo de la red para la clasificación de la solanum phureja.

En la segunda columna del primer bloque ahí está el inicio y la salida.

En la tercera columna están los valores ahí por ejemplo inicia con 160, 160, 3.

Esto indica cómo va a ir evolucionando el tamaño en que la red neuronal va a ir haciendo el aprendizaje y el entrenamiento de las imágenes de la Solanum phureja.

En la siguiente hay una convolución en 2d con entrada y salida de las imágenes que genera que la tercera dimensión de las imágenes se amplíe y se convierta en 32.

Ese trabajo interno implica que se han aplicado 32 filtros aleatoriamente para aplicarle a una imagen traslación, suavizado, detección de bordes, etc.

Luego está el otro bloque que es de max pooling2d y lo que hace es reducir el tamaño de los dos primeros componentes de los dos primeros bloques.

El Flatten significa aplanamiento es cuando el conjunto de imágenes grandes se convierte en un solo vector en representación de la imagen que se está entrenando y luego pasan a capa densa y capas ocultas, entre otros que se puedan utilizar. La capa densa tiene 256 neuronas.

El Dropoud es una operación que aleatoriamente apaga o activa ciertas neuronas para que la red neuronal convolucional no caiga en una memorización sino aprenda en sí.

Por último, en la capa densa reciben como entrada la salida de la anterior y como salida final solo tiene 2 papa buena y papa mala.

IV. CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones.

Basándose en los resultados de la presente investigación, se puede dilucidar las siguientes conclusiones:

En la preparación del Dataset, en la etapa de adquisición de las imágenes se utilizó una cámara profesional con buena resolución donde se puede apreciar la mayor cantidad de detalles de la solanum phureja ya que los resultados con imágenes de baja calidad no convergen con las RN.

Para seleccionar los métodos de clasificación de imágenes se realizó una revisión de la literatura de distintas técnicas de algoritmos de inteligencia artificial existentes.

Para diseñar el método se realizó una selección por medio de un ranking de mejores resultados de aplicación de algoritmos de procesamiento de imágenes eligiendo los filtros con mejores resultados para este propósito.

La implementación del método fue realizada en Visual studio Code y lenguaje programación Python 3.12.6 en el framework para ciencia de datos. Esta investigación constó de dos etapas; en la primera, se realizó la extracción de características y en la segunda, la clasificación de la RNC.

Para las pruebas del método se realizó el cálculo de las métricas más importantes de una matriz de confusión, es decir Exactitud y Precisión. Se obtuvo un 92 % de exactitud y una precisión en la clase buenas papas del 93 %, sin embargo, en la clase malas papas la precisión y exactitud fue del 88 %.

4.1. Recomendaciones.

Se recomienda que, para la adquisición de imágenes se utilice un scanner que cuente con un mínimo de profundidad 32 de bit, y se edifique una estructura que permita un mejor control de la luz en un ambiente real (ya que en esta investigación solo se usa un ambiente controlado).

En la preparación del dataset se podrían adquirir las imágenes sin sombras o manchas de la tierra que expulsan las solanum phureja en su cascara; así se evita ruido inútil.

Se recomienda trabajar con una cantidad mayor de imágenes digitales por cada clase de solanum phureja, un aproximado de 5000 imágenes.

En la implementación del método, es necesario encontrar los hiperparámetros adecuados, y añadir transferencia de aprendizaje a la red neuronal convolucional y así lograr mejores resultados.

Se recomienda aprovechar la escalabilidad y mantenibilidad de los algoritmos en Python dado que la implementación de las librerías de keras versión 2.0 de la librería de TensorFlow 2.0 se aprovechan mejor si desarrolláramos un proyecto móvil.

Referencias

- [1] Ministerio de Agricultura y Riego, «gob.pe,» 25 05 2020. [En línea]. Available: <https://www.gob.pe/institucion/midagri/noticias/164182-peru-se-mantiene-como-primer-productor-de-papa-en-america-latina>.
- [2] Ministerio de Agricultura y Riego, «Papa: Características de La Producción Nacional y de La Comercialización en Lima Metropolitana,» 2017.
- [3] Instituto Nacional de Estadística e Informática, «Informe Tecnico De Produccion Nacional Diciembre2019,» 2020.
- [4] INSTITUTO NACIONAL DE INNOVACIÓN AGRARIA 2019, «Sistematización de la experiencia de los subproyectos de papa financiados por el programa nacional de innovación agraria.,» *PNIA*, 2019.
- [5] Ministerio de Agricultura y Riego, «Perú se mantiene como primer productor de papa en América Latina. Perú.,» 02 05 2020.
- [6] Agronoticias, «Perú importó más de 33 mil toneladas de papa el 2019.,» 2020.
- [7] R. Gestión, «Lima concentra el 72% de los supermercados, seguida por Piura con 8% y La Libertad con 7%. Gestión.,» *Redacción Gestión*, 31 05 2019.
- [8] F. F. L. Z. X. M. Y. L. R. K. M. & Z. Q. Gao, «Detection of multiple kinds of fruit in apple plant in the SNAP system using Faster R-CNN[Detección de múltiples clases de fruta en planta para manzana en el sistema SNAP utilizando Faster R- CNN].,» 2020.
- [9] J. V. A. Alvarado y M. A. Campoverde-Molina, «Clasificación de frutas basadas en redes neuronales convolucionales. Polo del Conocimiento,» *Dialet*, 2019.
- [10] Y. Du, Y. Hu, L. San y J. Tian, «Research on Potato Appearance Quality Detection Based on Computer Vision [Investigación sobre la detección de la calidad de la apariencia de la papa basada en visión artificial],» *IEEE*, 2019.
- [11] C. M. Delfin, C. J. González y J. C. O. Rojas, «Clasificación de manzanas utilizando visión artificial y redes neuronales artificiales,» 2018.
- [12] S. Wan y S. Goudos, «R-CNN faster for multi-class fruit detection using robotic vision System [R-CNN más rápido para la detección de frutas de varias clases mediante un sistema de visión robótica]».

- [13] P. D. A. S. A. & S. G. Balabanov, «Algorithms for Detecting Potato Defects Using Images in the Infrared Range of Spectrum [Algoritmos para detectar defectos de papa utilizando imágenes en el rango de espectro infrarrojo].», *IEEE*, 2018.
- [14] D. A. Heras, «Clasificador de imágenes de frutas basado en inteligencia artificial,» *Revista Killkana Técnica*.
- [15] R. Aguilar, J. Torres y C. Martín, «Aprendizaje Automático en la Identificación de Sistemas. Un Caso de Estudio en la Predicción de la Generación Eléctrica de un Parque Eólico,» 2017.
- [16] I. D. G. Santillán, C. D. Herrera y J. I. M. Ortega, «Detección automática de líneas de cultivo de papa utilizando imágenes digitales,» *SATHIRI-Sembrador*, 2016.
- [17] G. A. Figueredo-Ávila y J. A. Ballesteros-Ricaurte, «Identificación del estado de madurez de las frutas con redes neuronales artificiales, una revisión,» *Dialet*, 2015.
- [18] C. A. D. & R. O. Cáceres, «Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de Begonia semperflorens (flor de azúcar). Sanidad Vegetal y Protección de Cultivos,».
- [19] Departamento de Electrónica y Automática., «Procesamiento Digital de Imágenes.,» 2013.
- [20] J. F. A. G. M. y S. O. A. Roberto Aparici, «La imagen: Análisis y representación de la realidad,» *Dialet*, 2009.
- [21] F. C. Bravo y J. A. L. Sotelo, «Una aproximación práctica a las redes neuronales artificiales,» 2009.
- [22] W. Rivas Asanza y B. Mazón Olivo, «Redes neuronales artificiales aplicadas al reconocimiento de patrones,» *Universidad Técnica de Machala.*, 2018.
- [23] V. V. T. Ayerdi, «Redes neuronales aplicadas al pronostico del indice de precios al consumidor,» 2008.
- [24] M. R. Fonseca, «Simulación de redes neuronales como herramienta Big Data en el ámbito sanitario,» 2016.
- [25] Cognex Corporation, «Introducción a la visión artificial. Una guía para la automatización de procesos y mejorasde calidad,» 2016.

- [26] Instituto Colombiano Agropecuario, «Manejo fitosanitario del cultivo de la papa (Solanum tuberosum subsp. andigena y S. phureja) - Medidas para la temporada invernal.,» 2011.
- [27] INDECOPI, «Norma Técnica Peruana NTP 011.119. Papa. Definiciones y requisitos. Comisión de Normalización y de Fiscalización de Barreras Comerciales No Arancelarias.,» 2010.
- [28] S. F. C. & B. P. Hernández, «Metodología de la Investigación. México: McGraw-Hill.,» 2014.
- [29] Universidad Señor de Sipan, «Línea de Investigación Institucional.,» 2019.
- [30] J. T. J. G. F. R. J. R. A. & J. J. Cervantes, «Análisis Comparativo de las técnicas utilizadas en un Sistema de Reconocimiento de Hojas de Planta. Revista Iberoamericana de Automática e Informática Industrial RIAI.,» 2017.
- [31] Yandun, 2020.
- [32] I. Mejia, R. Ramirez, H. Jimenez y J. Rosas, «A new method a architecture entreprise,» *Conference IEEE bussines*, pp. 200-215, 2019.
- [33] H. Jimenez, R. Rodriguez y J. Tiparra, Diagnóstico de TEA, Madrid: Latinoamérica SA, 1978.
- [34] P. SZNAJDLEDER, Java a fondo - estudio del lenguaje y desarrollo de aplicaciones - 2a ed., México: Alfaomega, 2012.
- [35] I. Mejia, M. Tuesta y M. Forero, «A new method of enterprise archicture small organizations,» *Computer Science Techology*, pp. 150-170, 2020.
- [36] J. Palma y R. Marín, Inteligencia Artificial, Madrid: McGrawHill, 2008, pp. 3-8.
- [37] K. Rojas, «Identificación de efectos negativos de la TEA en el aprendizaje,» *IEEE conference Techology children especial*, pp. 200-215, 2018.
- [38] L. H. R. Cambero y M. L. J. Vicencio, «Desarrollo del sistema de visión artificial,» 2014.
- [39] Ministerio de Agricultura y Riego, «Grupo Yanapai; Instituto Nacional de Innovación Agraria (INIA),» *Centro Internacional de la Papa (CIP).,»* 2017.
- [40] carbero y jimenez.
- [41] C. E. Bernardo Zárate, Y. M. Carbajal Llanos y V. R. Contreras Salazar, «Metodología de la Investigación. México: McGraw-Hill.,» 2014.

ANEXOS.

**FACULTAD DE INGENIERÍA, ARQUITECTURA Y URBANISMO
RESOLUCIÓN N°0463-2024/FIAU-USS**

Pimentel, 24 de mayo de 2024

VISTO:

El Acta de reunión N° 21 - 05 - 2024 del Comité de investigación de la INGENIERÍA DE SISTEMAS remitida mediante vía oficio N° 0101-2024/FIAU-IS-USS de fecha 22 de mayo de 2024, y;

CONSIDERANDO:

Que, de conformidad con la Ley Universitaria N° 30220 en su artículo 48° que a letra dice: "La investigación constituye una función esencial y obligatoria de la universidad, que la fomenta y realiza, respondiendo a través de la producción de conocimiento y desarrollo de tecnologías a las necesidades de la sociedad, con especial énfasis en la realidad nacional. Los docentes, estudiantes y graduados participan en la actividad investigadora en su propia institución o en redes de investigación nacional o internacional, creadas por las instituciones universitarias públicas o privadas.";

Que, de conformidad con el Reglamento de grados y títulos en su artículo 21° señala: "Los temas de trabajo de investigación, trabajo académico y tesis son aprobados por el Comité de Investigación y derivados a la facultad o Escuela de Posgrado, según corresponda, para la emisión de la resolución respectiva. El periodo de vigencia de los mismos será de dos años, a partir de su aprobación. En caso un tema perdiera vigencia, el Comité de Investigación evaluará la ampliación de la misma.

Que, de conformidad con el Reglamento de grados y títulos en su artículo 24° señala: La tesis es un estudio que debe denotar rigurosidad metodológica, originalidad, relevancia social, utilidad teórica y/o práctica en el ámbito de la escuela profesional. Para el grado de doctor se requiere una tesis de máxima rigurosidad académica y de carácter original. Es individual para la obtención de un grado; es individual o en pares para obtener un título profesional. Asimismo, en su artículo 25° señala: "El tema debe responder a alguna de las líneas de investigación institucionales de la USS S.A.C.";

Que, mediante documentos de vistos, el Comité de investigación de la referida Escuela profesional acordó designar el asesor de tema de tesis, de la línea de investigación de CIENCIAS DE LA INFORMACIÓN COMO HERRAMIENTAS MULTIDISCIPLINARES Y ESTRATÉGICAS EN EL CONTEXTO INDUSTRIAL Y DE ORGANIZACIONES, a cargo de los estudiantes y /o egresados del Programa de estudios INGENIERÍA DE SISTEMAS, hasta la fecha que indica la presente resolución.

Estando a lo expuesto, y en uso de las atribuciones conferidas y de conformidad con las normas y reglamentos vigentes;

SE RESUELVE:

ARTÍCULO 1: DESIGNAR, asesor de tema de tesis a cargo de los estudiantes y /o egresados del Programa de estudios de INGENIERÍA DE SISTEMAS que se detallan en el anexo de la presente Resolución.

ARTÍCULO 2: DEJAR SIN EFECTO, toda Resolución emitida por la Facultad que se oponga a la presente Resolución.



Universidad
Señor de Sipán

FACULTAD DE INGENIERÍA, ARQUITECTURA Y URBANISMO
RESOLUCIÓN N°0463-2024/FIAU-USS

Pimentel, 24 de mayo de 2024

ANEXO

DESIGNACION DE ASESOR DE TEMA DE TESIS

APELLIDOS NOMBRES	TITULO DEL PROYECTO DE INVESTIGACIÓN	RESOLUCIÓN DE APROBACION DE PROYECTO	DESIGNACION DE ASESOR
SANCHEZ TORRES, MARIA ROJANA RUIZ	Método de clasificación automática para defectos externos con actualización manual de Solanum Phureja para las exigencias de percepción de calidad	N°0782-2023/FIAU-USS	Mg. Asenjo Carranza Enrique David
SANTACRUZ, YOVANNY FLORIBEL			



Dr. Victor Alexci Tuesta Monteza
Decano (E) / Facultad de Ingeniería,
Arquitectura y Urbanismo
UNIVERSIDAD SEÑOR DE SIPÁN SAC.



Dr. Halyn Alvarez Vásquez
Secretario Académico Facultad de
Ingeniería, Arquitectura y Urbanismo
UNIVERSIDAD SEÑOR DE SIPÁN SAC.

REGÍSTRESE, COMUNÍQUESE Y ARCHÍVESE

Cc: Interesado, Archivo