

UNIVERSIDAD LA SALLE

CARRERA DE INGENIERÍA DE SISTEMAS



**Clasificación de Papas Wila Imilla (*Solanum
Tuberosum subsp. Andigena*) cultivadas en el altiplano
de la Ciudad de La Paz usando Visión Artificial**

Por

Andres Esteban Pacheco Sillerico

Tutor: M. Sc. Ing. Marcelo Saavedra

Tesis de Licenciatura presentada para la obtención del Grado de
Licenciatura en Ingeniería Sistemas

La Paz - Bolivia

2019

DEDICATORIA

Al creador de todas las cosas, el que me ha dado fortaleza para continuar cuando a punto de caer he estado; por ello, con toda la humildad que de mi corazón puede emanar, dedico primeramente mi trabajo a Dios.

De igual forma, dedico esta tesis a mis abuelos Lorenzo, Bárbara, Marcos y Antonia que han sabido formarme con buenos sentimientos, hábitos y valores, los cuales me ha ayudado a salir adelante como ejemplos de vida.

AGRADECIMIENTOS

Le agradezco a Dios por haberme permitido vivir hasta este día, haberme guiado a lo largo de mi vida, por ser mi apoyo, mi luz y mi camino. Por haberme dado la fortaleza para seguir adelante en aquellos momentos de debilidad.

Le doy gracias a mis padres Rene y Benita por todo el apoyo brindado a lo largo de mi vida. Por darme la oportunidad de estudiar esta carrera. Por ser ejemplo de vida. Y por promover el desarrollo y la unión familiar en esta nuestra familia.

Gracias Ingeniero Marcelo Saavedra por creer en mí, por haberme brindado la oportunidad de desarrollar mi tesis profesional. También por todo lo que él me ha enseñado.

TABLA DE CONTENIDOS

TABLA DE CONTENIDOS	4
ÍNDICE DE TABLAS	7
ÍNDICE DE ILUSTRACIONES	8
ÍNDICE DE ECUACIONES	10
RESUMEN	11
INTRODUCCIÓN	12
I. MARCO REFERENCIAL	13
1.1. Antecedentes	13
1.2. Planteamiento del Problema	15
1.3. Formulación del Problema	15
1.4. Objetivos	15
1.4.1. Objetivo General	15
1.4.2. Objetivos Específicos	15
1.5. Justificaciones	16
1.5.1. Justificación Científica	16
1.5.2. Justificación Social	16
1.6. Límites y Alcances	16
1.6.1. Límites	16
1.6.2. Alcances	16
1.7. Modelos y Herramientas	17
1.7.1. Método Experimental	17
1.7.2. Herramientas	18
1.8. HIPÓTESIS	19
II. MARCO TEÓRICO	21

2.1.	La Papa en Bolivia	21
2.1.1.	Generalidades	21
2.1.2.	Procesos de Producción de la Papa	21
2.1.3.	Comercialización de la papa de Agricultores campesinos	22
2.1.4.	Selección y Clasificación de las papas Pos Cosecha	23
2.1.4.1.	Selección	23
2.1.4.2.	Clasificación	23
2.2.	Visión Artificial	26
2.2.1.	Definición	26
2.2.2.	Adquisición de Imagen	27
2.2.3.	Procesamiento de imagen	27
2.3.	Modelos de Color	31
2.3.1.	El Modelo HSV	31
2.3.2.	El Modelo RGB	32
2.4.	Datos de Verdad (<i>Ground Truth Data</i>)	34
2.5.	Las Redes Neuronales	37
2.5.1.	La Función de entrada	38
2.5.2.	La Función de activación	38
2.5.3.	La Función de salida	39
2.5.4.	Entrenamiento de una Red Neuronal	39
2.6.	Clasificador Bayesiano	43
2.6.1.	Entrenamiento Bayesiano	44
2.6.2.	Creación del Modelo Bayesiano	45
2.6.3.	Clasificación con el Modelo Bayesiano	45
2.7.	Tabla de Consulta (<i>Look Up Table</i>)	46
III.	MARCO PRÁCTICO	51
3.1.	Sistema General	51
3.2.	Selección de la Papa	53
3.2.1.	Característica de una Papa Dañada	54

3.2.2.	Características de Color de una Papa	55
3.3.	Sistema de Visión Artificial	56
3.3.1.	Adquisición de la imagen	56
3.4.	Sistema Fuera de Línea (<i>Offline System</i>)	58
3.4.1.	Imagen Almacenada en el Computadora	59
3.4.2.	Detección de la Papa mediante el Modelo HSV	59
3.4.3.	Extracción de Características	64
3.4.4.	Entrenamiento mediante el Modelo RGB	64
3.4.5.	Entrenamiento de la Red Neuronal	65
3.4.6.	Entrenamiento del Clasificador Bayesiano	69
3.4.7.	Datos de Verdad (Ground Truth Data)	73
3.4.8.	Eliminación de Impurezas del Clasificador de la Red Neuronal	74
3.4.9.	Eliminación de Impurezas del Clasificador Bayesiano	76
3.5.	Sistema en Línea (<i>Online System</i>)	78
3.5.1.	Imagen en Tiempo Real	80
3.5.2.	Detección de la Papa y Extracción de Características	80
3.5.3.	Tabla de Consulta (<i>Look Up Table</i>)	81
3.5.4.	Eliminación de Impurezas	82
3.6.	Resultados del Sistema Fuera de Línea	83
3.7.	Comprobación de la Hipótesis	90
IV.	CONCLUSIONES Y TRABAJOS FUTUROS	91
4.1.	Conclusiones	91
4.2.	Trabajos Futuros	93

ÍNDICE DE TABLAS

<i>Tabla N°1 Método Experimental y No Experimental</i>	<i>18</i>
<i>Tabla N° 2 Clasificación por peso de las semillas</i>	<i>24</i>
<i>Tabla N°3 Clasificación por su tamaño de las semillas</i>	<i>25</i>
<i>Tabla N°4 Clasificación de la utilidad por peso</i>	<i>25</i>
<i>Tabla N°5 Clasificación de la utilidad por tamaño</i>	<i>26</i>
<i>Tabla N°6 Máximos y Mínimos de la Detección del Tubérculo</i>	<i>61</i>
<i>Tabla N°7. Muestra del Entrenamiento de la Red Neuronal</i>	<i>67</i>
<i>Tabla N°8. Reasignación de Píxeles Clasificados</i>	<i>67</i>
<i>Tabla N°9. Muestra de clasificación del entrenamiento Bayesiano</i>	<i>71</i>
<i>Tabla N°10. Matriz de confusión, Clasificador de dos clases</i>	<i>83</i>
<i>Tabla N°11 Umbrales de los Clasificadores</i>	<i>84</i>
<i>Tabla N°12. Indicadores de Desempeño</i>	<i>85</i>
<i>Tabla N°13 Indicadores Papas Sanas - Clasificación Red Neuronal</i>	<i>86</i>
<i>Tabla N°14 Indicadores Papas Sanas - Clasificador Bayesiano</i>	<i>87</i>
<i>Tabla N°15 Indicadores de Desempeño - Clasificación Red Neuronal</i>	<i>88</i>
<i>Tabla N°16 Indicadores de Desempeño - Clasificador Bayesiano</i>	<i>89</i>

ÍNDICE DE ILUSTRACIONES

<i>Ilustración 1 Producción de Papa en Bolivia</i>	14
<i>Ilustración 2 Adquisición de imagen</i>	27
<i>Ilustración 3 Proceso de un sistema de visión artificial con inteligencia artificial</i>	28
<i>Ilustración 4 Matiz Simplificada del Modelo HSV</i>	31
<i>Ilustración 5 Saturación Simplificada del Modelo HSV</i>	32
<i>Ilustración 6 Luminosidad o Valor Simplificado del Modelo HSV</i>	32
<i>Ilustración 7 Modelo aditivo de colores rojo, verde, azul.</i>	33
<i>Ilustración 8 Ejemplo de una Red Neuronal totalmente conectada</i>	37
<i>Ilustración 9 Función de error de una red neuronal</i>	40
<i>Ilustración 10 Concepto de una Tabla de Consulta</i>	47
<i>Ilustración 11 Ejemplo de una Tabla de Consulta</i>	48
<i>Ilustración 12 Ejemplos del Uso de 3 Tablas de Consulta</i>	49
<i>Ilustración 13 Diagrama Sistema General</i>	52
<i>Ilustración 14 Diseño del Sistema General</i>	53
<i>Ilustración 15. Papa Dañada: Papa con Cortes por Material de Agricultura</i>	54
<i>Ilustración 16. Papa Dañada: Papa herida por Gusanos</i>	55
<i>Ilustración 17 Píxeles de Papa en el Plano RGB</i>	56
<i>Ilustración 18 Adquisición de la Imagen</i>	57
<i>Ilustración 19 Fotografía de Papa</i>	57
<i>Ilustración 20 Diagrama Sistema Fuera de Línea</i>	58
<i>Ilustración 21 Diseño del Sistema Fuera de Línea</i>	59
<i>Ilustración 22 Tubérculo en el Modelo HSV</i>	60
<i>Ilustración 23. Selección del Fondo y su Inverso</i>	62
<i>Ilustración 24. Detección de Ruido al Segmentar el Tubérculo</i>	62
<i>Ilustración 25. Erosión con un E. E. de 8x8</i>	63
<i>Ilustración 26. Dilatación con un E. E. de 5x5</i>	63

<i>Ilustración 27. Recorte de la Imagen a solo el Tubérculo</i>	64
<i>Ilustración 28 Red Neuronal, perceptrón Multi Capa</i>	66
<i>Ilustración 29. Entrenamiento de la Red Neuronal</i>	66
<i>Ilustración 30. Ejemplo 1 de Clasificación con la Red Neuronal</i>	68
<i>Ilustración 31. Ejemplo 2 de Clasificación con la Red Neuronal</i>	68
<i>Ilustración 32. Ejemplo 3 de Clasificación con la Red Neuronal</i>	69
<i>Ilustración 33 Clases de Clasificación - Bayesiano</i>	69
<i>Ilustración 34. Ejemplo 1 de Clasificación con el clasificador Bayesiano</i>	72
<i>Ilustración 35. Ejemplo 2 de Clasificación con el clasificador Bayesiano</i>	73
<i>Ilustración 36. Ejemplo 3 de Clasificación con el clasificador Bayesiano</i>	73
<i>Ilustración 37 Ground Truth de un Tubérculo</i>	74
<i>Ilustración 38. Ejemplo 1 de Clasificación Limpio con la Red Neuronal</i>	75
<i>Ilustración 39. Ejemplo 2 de Clasificación Limpio con la Red Neuronal</i>	75
<i>Ilustración 40. Ejemplo 3 de Clasificación Limpio con la Red Neuronal</i>	76
<i>Ilustración 41. Ejemplo 1 de Clasificación Limpio con el clasificador Bayesiano</i>	77
<i>Ilustración 42. Ejemplo 2 de Clasificación Limpio con el clasificador Bayesiano</i>	77
<i>Ilustración 43. Ejemplo 3 de Clasificación Limpio con el clasificador Bayesiano</i>	78
<i>Ilustración 44 Diagrama del Sistema Online</i>	79
<i>Ilustración 45 Diseño del Sistema Online</i>	79
<i>Ilustración 46 Compresión del Espacio RGB</i>	82
<i>Ilustración 47 Relación Ground Truth - Matriz de Confusión</i>	84
<i>Ilustración 48 Curva ROC de los Clasificadores</i>	90

ÍNDICE DE ECUACIONES

(1) Funcion de Entrada de una Red Neuronal	38
(2) Vector Gradiente.....	41
(3) Matriz Hessiana	41
(4) Gradiente de Primer y Segundo Orden	42
(5) Teorema de Bayes.....	44
(6) Proceso Morfológico - Detección de Tubérculo	63
(7) Vector de Medias	69
(8) Clases del Clasificador Bayesiano	70
(9) Matriz de Covarianzas	70
(10) Clasificador Bayesiano	70
(11) Función de Probabilidad	70
(12) Sub Función de Probabilidad.....	71
(13) Proceso Morfológico - Impurezas Red Neuronal	74
(14) Proceso Morfológico - Impurezas Clasificador Bayesiano	76

RESUMEN

Se desarrolló un sistema de visión artificial para la clasificación del tubérculo de la Papa Wila Imilla en dos clases: papa dañada y en buen estado, dependiendo del estado de su superficie. Para ello se empleó la metodología experimental, ya que es la adecuada para poner a prueba la hipótesis del presente trabajo. El clasificador se evaluó en dos técnicas de clasificación: Bayesiano y redes neuronales. Con el clasificador Bayesiano se obtuvo una proporción de éxito de detección de daño en el tubérculo de la papa del 89%. Usando redes neuronales la proporción de éxito fue del 84%. Comprobando que el clasificador bayesiano tiene mayor éxito que la red neuronal al momento de detectar daños en el tubérculo de la papa.

INTRODUCCIÓN

La papa es originaria de la cordillera de los Andes, entre los países de Perú y Bolivia, además de ser uno de los principales alimentos producidos en el mundo y además es rica en almidón comestible, vitamina C, proteínas tiamina (Vitamina B1) y niacina (Vitamina B3) (Britannica). La calidad de la papa producida en el altiplano paceño es una de mejores por que los métodos utilizados para su cultivo son convencionales, es decir, no se usa injertos ni químicos que aceleren el proceso de crecimiento o tamaño del mismo. La recolección se hace de forma manual y selectiva arrancando todos los tubérculos de la planta, esta es una ardua labor ya que en una misma planta es posible encontrar tubérculos en diferentes estados de madurez.

Un proceso de separación de papas elimina las que no se pueden utilizar para el consumo humano, luego se procede a clasificarlas según el uso que se va a dar. El tiempo de clasificación de las papas es moroso, ya que considera periodos extensos de clasificación entre papas para la venta, para la transformación a tunta, para la transformación a chuño, papas pequeñas (se usa para ser semilla), sin embargo, esto no garantiza productos de alta calidad. La presencia de papas pequeñas (semillas) y papas para la venta afectan la calidad de papas para transformación a chuño o tunta tanto en su sabor como tamaño. Un problema que se tiene es al momento de entregar las papas a los mercados por parte de los mayoristas que adquieren la papa de los productores, es que un porcentaje medio de las papas pese daños de corte de cosecha o están podridas por gusanos, esto reduce la calidad de la papa. La presente propuesta de trabajo pretende reducir las papas con daños por corte y podridas por gusanos mediante el uso de visión artificial.

I. MARCO REFERENCIAL

1.1. Antecedentes

En los últimos años los avances tecnológicos han mejorado la capacidad de producción para distintas ramas, la variedad que hay en ellos es enorme, las empresas productoras de alimentos procesan gran cantidad de productos, teniendo que implementar maquinaria para distintos procesos, los cuales agilizan el trabajo y permite obtener mayor flujo de productos con respecto al tiempo.

Sin embargo en nuestro país todavía está en vías de desarrollo industrial, si bien poco a poco tiene progresos e implementación tecnológica en distintos rubros, teniendo aun presente la producción agrícola campesina como principal productor nacional, según la publicación de Tierra:” El 95 por ciento de las Unidades Productivas Agropecuarias (UPA) en Bolivia, corresponde a la agricultura familiar campesina (AF), mientras que el 5 por ciento tiene un carácter empresarial. Pese a esta importancia poblacional, los agricultores familiares cultivan solo el 40 por ciento de la tierra; en contraste, la agricultura empresarial ocupa el 60 por ciento de la tierra cultivada. El aporte de la AF a la seguridad alimentaria ha decrecido en las últimas décadas y al contrario, la agricultura empresarial ha incrementado su presencia.” (Tierra, 2016)

Existen investigaciones sobre la evaluación de nuevas variedades: “Evaluación de nuevas variedades de papa *Solanum tuberosum* L. para la producción de papa primor en la VII Región”(Ávila Figueroa, 2004), impacto en el mercado laboral: “Impacto del cambio tecnológico en el mercado laboral: el caso del cultivo de papa en el Partido de Balcarce” (Petrantonio, 1991). Pero sin hacer énfasis en la contribución a los consumidores finales de papa.

Actualmente las investigaciones sobre la mejora de la producción agrícola campesina son escasas, a pesar de que esta tiene un impacto del 95% de

unidades productivas agropecuarias en Bolivia.


La agricultura campesina indígena está estancada porque el factor dominante en los últimos 20 años ha sido la agricultura comercial a gran escala para la producción de materias primas de exportación, para el agro negocio", explicó el director ejecutivo de la Fundación Tierra, Gonzalo Colque.

De acuerdo con datos oficiales (Mundo, 2016), en Bolivia existen unas 800.000 unidades productivas campesinas. El 94 por ciento son pequeñas unidades que cultivan menos de 5 hectáreas, explicó a su vez la responsable de la Unidad de Desarrollo del Centro Investigación de Promoción del Campesinado (CIPCA), Pamela Cartagena.

La producción de papa ha ido en aumento, logrando el mayor registro de producción en el año agrícola 2016 – 2017 (Ver la Ilustración 1).

A pesar de tener grandes cantidades de producción de papa estos últimos años, la papa que llega a los mercados de los distintos barrios de la ciudad de La Paz y El Alto posee un porcentaje medio de papas dañadas por corte y podridas por gusanos, mejorando así la calidad de la papa que se pone a la venta para el consumidor final.

Ilustración 1 Producción de Papa en Bolivia



Fuente: CIFRAS N°606 Papa en Bolivia (IBCE, 2017).

1.2. Planteamiento del Problema

Los agricultores campesinos venden su producción de papa a los mayoristas en ferias, dichos mayoristas distribuyen la papa por los mercados de los barrios de las ciudades de La Paz y El Alto. Estas papas que son para el consumidor final tienen entre ellas papas dañadas, ya sea por corte de cosecha o podridas por gusanos, esto causa una molestia en los consumidores, ya que un porcentaje menor de los mayoristas y los vendedores finales separan las papas dañadas por corte o podridas por gusanos de las papas que están en buen estado, llegando a tener una calidad de papa menor de lo que se pudiera llegar a obtener.

1.3. Formulación del Problema

¿Se puede separar las papas dañadas de las están en buen estado para el consumidor final mediante el uso de visión artificial?

1.4. Objetivos

1.4.1. Objetivo General

Desarrollar un sistema de visión artificial que clasifique papas para el consumidor final en: papas dañadas y en buen estado para el consumidor humano.

1.4.2. Objetivos Específicos

- Analizar los criterios y juicios empleados actualmente para la clasificación de papas.
- Plasmar los criterios y juicios de clasificación de papas en una Red Neuronal.
- Plasmar los criterios y juicios de clasificación de papas en un Clasificador Bayesiano.

- Determinar que arquitectura de visión artificial se adecua mejor para la clasificación de papas.

1.5. Justificaciones

1.5.1. Justificación Científica

La aplicación de las nuevas tecnologías en el campo de la agricultura contribuye a una producción más rentable, garantizando de este modo la eficiencia productiva y mejorando sus indicadores de rentabilidad.

Los avances tecnológicos en visión artificial permiten desarrollar una agricultura de precisión, que busca una mayor eficiencia en la clasificación de papas.

1.5.2. Justificación Social

Contribuir con la mejora de calidad de la papa destinada para el consumo humano, para que se reduzca la cantidad de papas dañadas por corte de cosecha o podridas por gusanos e implementar nuevas tecnologías en la labor de clasificación de papas.

1.6. Límites y Alcances

1.6.1. Límites

Sólo se tomarán en la implementación del software, no el diseño mecánico ni la implementación electrónica, es decir, de la maquinaria física o hardware.

1.6.2. Alcances

La investigación se basará en el criterio y conocimiento de los agricultores campesinos del altiplano paceño, mayoristas y mercaderes de la ciudad de La Paz, es decir, se obtendrán datos cualitativos, debido a que no se presentan datos documentados sobre los criterios de clasificación.

De las distintas variedades de papas que existen en el altiplano paceño, el presente trabajo solo contempla la papa Wila Imilla (*Solanum Tuberosum subsp. Andigena*).

El entrenamiento y pruebas del clasificador bayesiano y del clasificador con redes neuronales, solo usaron imágenes de papas sucias, es decir, no se contempla a las papas limpias o lavadas, debido a que en todo el proceso de comercialización de la papa, el usuario final o consumidor es quien llega a realizar tal labor.

1.7. Modelos y Herramientas

1.7.1. Método Experimental

En la investigación de enfoque experimental el investigador manipula una o más variables de estudio, para controlar el aumento o disminución de esas variables y su efecto en las conductas observadas. Dicho de otra forma, un experimento consiste en hacer un cambio en el valor de una variable (variable independiente) y observar su efecto en otra variable (variable dependiente).

Esto se lleva a cabo en condiciones rigurosamente controladas, con el fin de describir de qué modo o por qué causa se produce una situación o acontecimiento particular. Los métodos experimentales son los adecuados para poner a prueba hipótesis de relaciones causales.

En la Tabla N°1 podemos ver de manera sintetizada las diferencias entre la metodología experimental y la metodología no experimental.

Al comenzar a realizar una investigación, hemos de delimitar las variables que deseamos analizar a través de la investigación y cuáles vamos a desechar, al igual que dejar claro cuáles podrían influir en nuestros resultados.

En el enfoque experimental, nos referimos a un concepto como la generalización que se deriva de la observación y análisis de unos acontecimientos u objetos.

El concepto de carácter científico tiene como objetivo principal que explique la realidad y que se interrelacione con otros conceptos.

Tabla N°1 Método Experimental y No Experimental

METODOLOGÍA EXPERIMENTAL	METODOLOGÍA NO EXPERIMENTAL
Se provocan (manipulan) los efectos	Los efectos ya se han producido
Se modifica la variable independiente y observamos los cambios (efectos) en la variable dependiente	No se modifican, sólo se seleccionan y observan
Orientación hacia el futuro	Orientación hacia el pasado
Aleatorización de grupos	Grupos naturales ya formados

Fuente: Javier Murillo

1.7.2. Herramientas

En entorno de desarrollo para la presente tesis será en la plataforma y lenguaje de programación de MATLAB, es un software muy usado en universidades y centros de investigación y desarrollo. (Goering, 2004).

Al momento de crear el conjunto de datos para el entrenamiento de los clasificadores, se empleó Excel para la eliminación de datos repetidos, dicho programa que permite la manipulación de libros y hojas de cálculo.

Para la elaboración de los datos de verdad (*Ground Truth Data*) se utilizó Adobe Photoshop, en su versión CC. Photoshop permitió la manipulación de imágenes y hacer un re color para comparar con los clasificadores del presente trabajo.

1.8. HIPÓTESIS

Hipótesis General: El sistema de clasificación de papas mediante visión artificial posee un buen desempeño de clasificación en la detección de los tubérculos dañados frente al sistema manual.

Variable Dependiente: Sistema de clasificación de papas mediante visión artificial.

Variable Moderante: buen desempeño de clasificación en la detección de los tubérculos

Variable Independiente: sistema manual

Criterio de Validación: Se entiende por buen desempeño a:

- La existencia de un mínimo del 60% de probabilidad de que el diagnóstico de clasificar una papa dañada sea correcto que el de una papa sana escogida al azar.

MARCO TEÓRICO

II. MARCO TEÓRICO

2.1. La Papa en Bolivia

2.1.1. Generalidades

La papa (*Solanum tuberosum*) es uno de los alimentos más importantes en la región Andina de Bolivia, los principales motivos son: su valor como cultivo de seguridad alimentaria y por su diversidad de papa nativas que se posee (Coca, 2015).

La papa es una planta herbácea anual que llega a crecer hasta un metro de alto. Con el paso del crecimiento de la planta de la papa, este desprende el almidón que se transfiere a los tallos subterráneos. Dichos tallos se engrosan para lograr formar un aproximado de 20 tubérculos cercanos a la superficie de la tierra. El número de tubérculos que pueden alcanzar su madurez va a variar según la humedad que tenga la planta y los nutrientes de la tierra, estos tubérculos pueden variar también en su forma como tamaño, con un peso aproximado de 300 gr cada uno. (CIP; Zeballos H., y otros, 2009).

2.1.2. Procesos de Producción de la Papa

A continuación se describirá las etapas de producción de la papa:

- **Clasificación y selección de la semilla**

En esta etapa se separa las papas dañadas y deformes de las que están sanas, así se mantiene una mejor calidad de producto.

- **Preparación del suelo de la siembra**

Se procede con el corte del abono verde por anticipación, para que este se seque y pueda unirse al suelo en el momento de hacer surcos. Las zanjas de la siembra deben tener una profundidad de entre 15 a 20 centímetros, así se obtiene

una mejor ventilación al suelo y al mismo tiempo contar con una cama suelta que otorga espacio al tubérculo más justa para la siembra

- **Crecimiento del cultivo**

En esta etapa podemos diferenciar tres sub etapas: emergencia, crecimiento vegetativo y reproductivo, madurez. En estas sub etapas también se desarrolla: El deshierbado, requerimientos de nutrientes y agua.

- **Sanidad del cultivo**

La administración completa sobre las plagas y enfermedades es la actividad que se maneja en esta etapa para un cultivo saludable. Mantener la salud del suelo y obtener semillas sanas son los principales elementos para un cultivo sano, según afirman expertos. De la misma forma el cuidado del cultivo se sostiene fertilizándolo y previendo las plagas y enfermedades. Estas prácticas de cultivo permiten el desarrollo sano del cultivo.

- **Cosecha y pos cosecha**

Comienza a partir de la extracción y manejo de la planta de la papa, como punto inicial se parte de la recolección, clasificación, elección, guardado, y por último la pos cosecha, que es el inicio de la elaboración de los derivados de la papa como ser el chuño y la tunta (Parada, 2016).

2.1.3. Comercialización de la papa de Agricultores campesinos

La Paz, Potosí, Cochabamba, Chuquisaca, Oruro, Tarija y Santa Cruz son los seis departamentos productores de mayor importancia de papa en Bolivia. Enfocándonos solo en la ciudad de La Paz y El Alto, por su alta densidad de población (entre ambas ciudades concentran el 67% de la población del departamento de La Paz) también así de abastecer a sí mismos de sus necesidades, se envía papa fresca desde Inquisivi y Arima, en el sur del departamento a la ciudad de Oruro y sus respectivos centros mineros.

El principal lugar donde los productores realizan la comercialización son las 'grandes ferias', en su mayoría en las provincias. En el caso del departamento de La Paz es: Achacachi, Moco Moco, Escoma, Patacamaya, Lahuachaca y El Alto. Dichas ferias se rigen por tradiciones antiguas, tiene días concretos de funcionamiento durante los días de la semana.

A dicha ferias se reúnen los productores llegando en servicio de camiones ruterios y los mayoristas con sus respectivos camiones de alto tonelaje. Según la oferta y la demanda se queda en acuerdo los precios de referencia y se procede con las transacciones y negociaciones. Tras concluir el punto anterior se continúa con el trabajo de carga hacia los camiones de alto tonelaje de los mayoristas. Cabe mencionar que en estas ferias acuden muchos productores y varios mayoristas; por lo tanto el mercado no se encubre. (Zeballos H., y otros, 2009)

2.1.4. Selección y Clasificación de las papas Pos Cosecha

2.1.4.1. Selección

En la selección de tubérculos se separa las papas sanas y apropiadas que se adecuan a las características típicas de la variedad de papas que se procese, de las papas dañadas por acción de insectos, magulladuras, problemas fitosanitarios.

Las papas deben ser sanas, maduras, poseer una buena presentación, separadas ya de las papas podridas por gusanos, con verrugas, deformes, etc.

Una vez separadas las papas sanas de las dañadas, se puede proceder con la separación de tubérculos-semilla, este proceso se puede realizar a mano o de forma mecánica.

2.1.4.2. Clasificación

En la sección de clasificación se separa de todas las papas sanas en: tubérculos-semilla, papas destinadas para el consumo humano, y en derivados

(transformaciones de la papa). Los criterios de la categorías se basa según al tamaño o el peso.

La Tabla N° 2 nos muestra la clasificación por su peso de las semillas.

Tabla N° 2 Clasificación por peso de las semillas

Categoría	Peso de la Papa	Destino
Gruesa	Mayor a 101 gramos	Semilla Fraccionada
Primera	Entre 81 – 100 gramos	Semilla Fraccionada
Segunda	Entre 61 – 80 gramos	Semilla Entera
Tercera	Entre 41 – 60 gramos	Semilla Entera
Cuarta	Entre 21 – 40 gramos	Semilla Entera

Fuente: Rodolfo Cahuana

La Tabla N°3 nos muestra la clasificación por su tamaño de las semillas.

Entre las papas nativas, los tubérculos de forma redondeada, ovaladas y otras similares, se clasifican por su peso, mientras tanto los tubérculos de forma alargada se clasifican por su longitud.

Después de la clasificación de los tubérculos-semilla, la clasificación por su uso se refleja en la Tabla N°4.

Tabla N°3 Clasificación por su tamaño de las semillas

Categoría	Longitud de la Papa	Destino
Gruesa	Mayor a 111 mm de longitud	Semilla Fraccionada
Primera	Entre 91 – 110 mm de longitud	Semilla Fraccionada
Segunda	Entre 71 – 90 mm de longitud	Semilla Entera
Tercera	Entre 51 – 70 mm de longitud	Semilla Entera
Cuarta	Entre 31 – 50 mm de longitud	Semilla Entera

Fuente: Rodolfo Cahuana

Tabla N°4 Clasificación de la utilidad por peso

Categoría	Peso de la Papa	Destino
Gruesa	Mayor a 121 gramos	Mercado
Primera	Entre 91 – 120 gramos	Mercado
Segunda	Entre 61 – 90 gramos	Consumo y Procesamiento
Tercera	Entre 31 – 60 gramos	Consumo y Procesamiento
Cuarta	Menor a 30 gamos	Derivados (Transformación)

Fuente: Rodolfo Cahuana

Mientras que si tomamos en cuenta la longitud en lugar de los pesos, la Tabla N°5 nos indica como clasificar.

Tabla N°5 Clasificación de la utilidad por tamaño

Categoría	Longitud de la Papa	Destino
Extra	Mayor a 131 mm de largo	Mercado
Primera	Entre 111 – 130 mm de largo	Procesamiento
Segunda	Entre 91 – 110 mm de largo	Consumo y Procesamiento
Tercera	Entre 71 – 90 mm de largo	Consumo y Procesamiento
Cuarta	Menor a 70 mm de largo	Derivado (Transformación)

Fuente: Rodolfo Cahuana

Para poder realizar un trabajo más fácil la clasificación por tamaños se puede hacer el uso de zarandas graduadas, para obtener tubérculos de papa uniformes.

Luego de la clasificación se procede a pesar las categorías y variedades, para así venderlos, almacenarlas en bolsas debidamente etiquetadas de acuerdo al reglamento específico de semilla con un peso de entre 50 a 70 kilos por bolsa. (Garcia Blanco, y otros, 2011)

2.2. Visión Artificial

2.2.1. Definición

La visión artificial también llamado Visión por Computador o Machine View, es la extracción y la interpretación automática de la información de imágenes de videos digitales.

Los sistemas de visión artificial se dividen en dos componentes básicos: Hardware y software.


El Hardware se divide en adquisición de imagen y sistema de iluminación. El sistema de iluminación otorga las condiciones de luz uniforme e independiente del medio, con ello se obtiene la facilidad de la extracción de los rasgos de interés

de una imagen a procesar. (Ordoñez Alquina, y otros, 2011). El software se compone por el procesamiento de la imagen.

2.2.2. Adquisición de Imagen

Una imagen digital es producida por sensores digitales presentes en cámara y otros dispositivos digitales que generan una imagen bidimensional (2D), es decir, un conjunto de $N \times M$ píxeles o colores o intensidades de un cierto valor que representa el espacio que queremos analizar. La imagen se adquiere a partir de una cámara que tomará una fotografía de la papa, esta imagen se pasará a la computadora para su procesamiento, como se muestra en la Ilustración 2.

Ilustración 2 Adquisición de imagen




Fuente: Elaboración propia

2.2.3. Procesamiento de imagen

Antes de extraer información directamente de la imagen, se acostumbra a hacer un procesamiento previo de la misma para conseguir otra que nos permita hacer el proceso de extracción de datos más sencillo y eficiente. Los procesos que se llevaran a acabo son: pre procesamiento de datos, detección de objetos, extracción de características, entrenamiento, clasificación. Como se muestra en la Ilustración 3.

Ilustración 3 Proceso de un sistema de visión artificial con inteligencia artificial



Fuente: Elaboración propia

- **Pre procesamiento de datos**

Se enfoca a todas aquellas técnicas de análisis de datos que permite mejorar la calidad de un conjunto de datos de modo que las técnicas de extracción de características se puedan obtener mayor y mejor información (mejor porcentaje de clasificación, reglas con más completitud, etc.).

A continuación, se mostrara algunos algoritmos de procesamiento de imagen usados frecuentemente en la visión artificial.

- **Escala de Grises**

En muchos casos, el color de la imagen non nos aporta ninguna información relevante para interactuar. Por lo tanto, en estas situaciones se acostumbra a descartar la información de color de la imagen transformándola en una imagen de tonos grises. De este modo, 'ahorramos' mucha información y los cálculos serán mucho más sencillos de computarizar. Por ejemplo, si estamos analizando el movimiento dentro de una imagen en color, nos podemos ahorrar aproximadamente 2/3 partes de los pixeles que se han de tratar si descartamos los componentes de color y trabajamos simplemente con la imagen de intensidad luminosa o niveles de grises.

- **Binarización por umbral**

El proceso de Binarización por umbral parte de una imagen en tonos de grises y, a partir de un valor definible de umbral de intensidad de luz llamado *threshold*, la imagen se transforma en una imagen binaria, es decir, con píxeles blancos o píxeles negros. El umbral que define que pixel será blanco o negro se puede regular según la necesidad, este algoritmo nos permite 'ahorrar' aún más la información y los cálculos necesarios serán más fáciles de procesar.

- **Otros procesos Morfológicos**

En muchas situaciones, una vez que hemos obtenido una imagen binaria (en blanco y negro), observamos que aparece ruido en la imagen, fruto de los cambios en la iluminación de ambiente y los pequeños reflejos de esta luz en diferentes objetos y cuerpos en la escena. Este ruido suele consistir simplemente en píxeles que aparecen caóticamente en la imagen y que pueden estorbar seriamente la capacidad de los algoritmos de visión para reconocer objetos y patrones gráficos. Para eliminar estos pequeños y molestos píxeles, hay una serie de algoritmos de 'limpieza' de la imagen que nos ayudan a cumplir la tarea de obtención de una imagen binaria lo más neta posible.

- **Mediana**

El algoritmo de la mediana se aplica sobre las imágenes en escala de grises y provoca una cierta suavización de la imagen útil a la hora de simplificar contornos y áreas irregulares. El algoritmo de la media divide la imagen en un conjunto de divisiones de radio definible y calcula el valor de luminosidad medio de cada una de las subdivisiones. Una vez calculado, sustituye los píxeles que hay dentro de cada división por una única mancha gris con el valor de luminosidad medio de los píxeles originales.

- **Erosionar y Dilatar**

Los algoritmos de erosión y dilatación se suelen aplicar en serie, sobre las imagen 'ruidosa' se aplica al algoritmo de erosión, que contrae los contornos de todas las áreas blancas un número determinado de píxeles y que elimina completamente las áreas de píxeles blancos más pequeñas e irrelevantes. Una vez aplicado el algoritmo de erosión, se aplica el algoritmo de dilatación, que ayuda a recuperar la medida original de las áreas importantes y que expande los contornos de las áreas blancas tantos píxeles como sea necesario. (Garcia).

- **Detección de Objetos**

Una vez la imagen pre procesada y mejorada para su respectivo trabajo, se utiliza algoritmos para ubicar el sitio u objeto de interés de la imagen, extrayéndolo y quitando la información que no posee características de relevancia.

- **Extracción de Características**

Para reconocer un objeto de la imagen es necesario extraer características que permitan representarlo y describirlo matemáticamente.

A pesar de que un objeto posea variedad de características solo se extraen las que aportan información para su respectiva clasificación ya que al utilizar información por demás, este puede llegar a perjudicar o a tener redundancias en el entrenamiento.

- **Entrenamiento**

En el entrenamiento se parte de una base de datos de criterios y características que aporte información para la clasificación, esta funciona con el uso de algún tipo de inteligencia artificial, más adelante se describe cuales se usaran para la clasificación de papas.

- **Clasificación**

Una vez entrenada la inteligencia artificial se puede proceder a clasificar la imagen y realizar su respectivo control de calidad para verificar si realmente llega a obtener un grado aceptable de éxito. Dicho control se presenta en el apartado del Marco Practico.


2.3. Modelos de Color

2.3.1. El Modelo HSV

El modelo de definición del color HSB (*Hue, Saturation, Brightness* – Matiz, Saturación, Brillo), también llamado HSV (del inglés *Hue, Saturation, Value* – Matiz, Saturación, Valor), basado en el trabajo de Albert Munsell (El árbol de Munsell) y sus estudios de la percepción humana del color, define los colores en función de sus tres propiedades (matiz, saturación y luminosidad).

El matiz que se muestra en la Ilustración 4, corresponde a un grado de ángulo cuyos valores posibles van de 0 a 359° (aunque para algunas aplicaciones se normalizan del 0 al 100%). Cada valor corresponde a un color. Ejemplos: 0° es rojo, 60° es amarillo y 120° es verde.


Ilustración 4 Matiz Simplificada del Modelo HSV



Fuente: Proyecta Color Chile (Ivanovic, 2018).

La saturación que se muestra en la Ilustración 5, corresponde a la distancia al eje oscuridad-luz. Los valores posibles van del 0 al 100%. A este parámetro también se le suele llamar “pureza” por la analogía con la pureza de excitación y la pureza de color. Cuanto menor sea la saturación de un color, mayor tonalidad grisácea habrá y más decolorado estará.


Ilustración 5 Saturación Simplificada del Modelo HSV



Fuente: Proyecta Color Chile (Ivanovic, 2018).

La luminosidad que se muestra en la Ilustración 6, corresponde a la altura en el eje oscuridad-luz. Los valores posibles van del 0 al 100%.

Ilustración 6 Luminosidad o Valor Simplificado del Modelo HSV



Fuente: Proyecta Color Chile (Ivanovic, 2018).

2.3.2. El Modelo RGB


RGB es un modelo de color basado en la síntesis aditiva, con el que es posible representar un color mediante la mezcla por adición de los tres colores de luz primarios (rojo, verde y azul). El modelo de color RGB no define por sí mismo lo

que significa exactamente rojo, verde o azul, por lo que los mismos valores RGB pueden mostrar colores notablemente diferentes en diferentes dispositivos que usen este modelo de color. Aunque utilicen un mismo modelo de color, sus espacios de color pueden variar considerablemente.

Al mezclarse dos a dos, crean los colores secundarios. Al mezclarse luz verde con azul se obtiene el cian, con la luz roja y azul se logra el magenta y usando luz roja y verde observaremos un llamativo amarillo. Si la mezcla es en diferentes proporciones de estos colores básicos se van originando los diferentes tonos de la gama del espectro.

El modo Color RGB asigna un valor de intensidad a cada píxel. En imágenes de 8 bits por canal, los valores de intensidad varían de 0 (negro) a 255 (blanco) para cada uno de los componentes RGB (rojo, verde, azul) de una imagen en color. Por ejemplo, un color rojo fuerte podría tener un valor R de 246, un valor G de 20 y un valor B de 50. Si los valores de los tres componentes son idénticos, se obtiene un tono de gris neutro. Si los valores de todos los componentes son 255, el resultado es blanco puro, y negro puro si el valor es de 0, en la Ilustración 7 se muestra el espacio del modelo RGB.

Ilustración 7 Modelo aditivo de colores rojo, verde, azul.



Fuente: Mezcla Aditiva (Küppers, 1978)

Las imágenes RGB utilizan tres colores o canales para reproducir los colores en la pantalla. En imágenes de 8 bits por canal, los tres canales se convierten en 24 (8 bits x 3 canales) bits de información del color por píxel. En imágenes de 24 bits, los tres canales pueden reproducir hasta 16,7 millones de colores por píxel. En imágenes de 48 bits (16 bits por canal) y 96 bits (32 bits por canal), pueden reproducirse incluso más colores por píxel. Además de ser el modo por defecto en las imágenes digitales, el modelo RGB lo utilizan los monitores de los ordenadores para mostrar los colores.

Aunque RGB es un modelo de color estándar, puede variar el rango exacto de colores representados, según la aplicación o el dispositivo de visualización.

2.4. Datos de Verdad (*Ground Truth Data*)

En el contexto de la visión artificial, el *Ground Truth Data* (datos de verdad del terreno, en español) incluye un conjunto de imágenes y un conjunto de etiquetas en las imágenes y definen un modelo para el reconocimiento de objetos, incluyendo el conteo, ubicación y relaciones de las características clave. Las etiquetas se agregan mediante un análisis humano o automáticamente por imagen, según la complejidad del problema. La colección de etiquetas, como puntos de interés, esquinas, descriptores de características, formas e histogramas, forma un modelo.

Un modelo puede ser entrenado usando una variedad de métodos de aprendizaje automático. En tiempo de ejecución, las características detectadas se introducen en un clasificador para medir la correspondencia entre las características detectadas y las características modeladas. El modelado, la clasificación y el entrenamiento son problemas estadísticos y de aprendizaje automático, que están fuera del *Ground Truth data*, dicha tarea lo realizara las redes neuronales y el clasificador bayesiano en el presente trabajo. En cambio, aquí nos interesa el contenido y el diseño de las imágenes de ground truth.

Por lo tanto, la creación de un conjunto de datos *Ground Truth* puede incluir la consideración de las siguientes tareas principales:

Diseño del modelo. El modelo define la composición de los objetos, por ejemplo, el recuento, la fuerza y la ubicación relación de un conjunto de características *SIFT*. El modelo debe ser correctamente ajustado al problema y a los datos de imagen con el fin de ceder resultados significativos

Conjunto de entrenamiento. Este conjunto se recopila y etiqueta para que funcione con el modelo, y contiene imágenes positivas y negativas y características. Los negativos contienen imágenes y características destinadas a generar coincidencias falsas.

Equipo de prueba. Se recopila un conjunto de imágenes para evaluar el entrenamiento configurado para verificar la precisión del modelo para predecir el objeto correcto.

Diseño de clasificador. Esto está construido para cumplir con la aplicación objetivos de velocidad y precisión, incluida la organización de datos y buscando optimizaciones para el modelo.

Entrenamiento y prueba. Este trabajo se realiza usando varios conjuntos de imágenes para verificar el ground truth.

A menos que los datos del *Ground Truth* contengan una imagen cuidadosamente seleccionada y preparada contenido, los algoritmos no se pueden medir con eficacia. Por lo tanto, la verificación en el terreno está estrechamente relacionado con la causa raíz: no hay forma de mejorar lo que no podemos medir y no hacemos entender. Ser capaz de causar problemas de algoritmos y comprender el rendimiento y la precisión son los propósitos principales para establecer los datos de verdad del terreno. Un mejor *Ground Truth* permitirá un mejor análisis.

Los datos del *Ground Truth* varían según la tarea. Por ejemplo, en reconstrucción de imagen 3D o reconocimiento de rostros, se deben reconocer diferentes

atributos de los datos de verdad del terreno para cada tarea. Algunas tareas, como el reconocimiento facial, requieren segmentación y etiquetado para definir los objetos conocidos, como la ubicación de las caras, la posición y orientación de las caras, el tamaño de las caras, y atributos de la cara, como la emoción, el género y la edad. Otras tareas, como la reconstrucción 3D, necesita los píxeles brutos en las imágenes y una malla 3D de referencia o nube de puntos como ground truth.

Los conjuntos de datos del *Ground Truth* se clasifican en varias categorías:

- Sintético producido: las imágenes se generan desde la computadora modelos o representaciones.
- Real producido: una secuencia de video o imagen está diseñada y producido.
- Real Seleccionado: las imágenes reales se seleccionan de fuentes existentes.
- Anotación automatizada por máquina: análisis de características y aprendizaje método se utilizan para extraer características de los datos.
- Anotado por humanos: un experto define la ubicación de las características y objetos.
- Combinado: cualquier mezcla de los anteriores.

Muchos profesionales están firmemente en contra de usar conjuntos de datos sintéticos e insisten en usar conjuntos de datos reales. En algunos casos, se requieren imágenes de verdad de terrenos aleatorios; en otros casos, deben producirse imágenes de *Ground Truth* cuidadosamente guiadas y diseñadas, similares a creando una película con escenas y actores. Datos del *Ground Truth* aleatorios y naturales con artefactos impredecibles, como falta de iluminación, desenfoque de movimiento y transformación geométrica, a menudo es preferible.

Muchas computadoras exigen imágenes reales para el *Ground Truth* y variaciones aleatorias en las imágenes son importantes. Las imágenes reales son a menudo fáciles de obtener y / o fáciles de generar usando un video cámara o


incluso una cámara de teléfono celular. Pero crear conjuntos de datos sintéticos no es tan claro; eso requiere el conocimiento de los sistemas y herramientas de renderización de gráficos por computadora apropiados, por lo que la inversión de tiempo para aprender y usar esas herramientas puede superar sus beneficios.

Sin embargo, los conjuntos de datos sintéticos generados por computadora pueden ser una forma de evitar cuestiones de privacidad relacionadas con el uso de imágenes reales. (Krig, 2016).

2.5. Las Redes Neuronales

A continuación, se puede ver, en la Ilustración 8, un esquema de una red neuronal:

Ilustración 8 Ejemplo de una Red Neuronal totalmente conectada



Fuente: (Matich, 2001)

Esta figura está constituida por neuronas interconectadas y arregladas en 3 capas (esto último puede variar). Los datos ingresan por medio de la "capa de entrada", pasan a través de la "capa oculta" y salen por la "capa de salida". Cabe mencionar que la capa oculta puede estar constituida por varias capas.

2.5.1. La Función de entrada

La neurona acepta muchos valores de entrada como si fueran uno solo, este recibe el nombre de entrada global. Esto se logra a traves de la función de entrada, la cual se calcula partir del vector de entrada. La función de entrada se puede describir de la siguiente forma:

(1) Funcion de Entrada de una Red Neuronal

$$input_i = (in_{i1} \cdot w_{i1}) * (in_{i2} \cdot w_{i2}) * \dots (in_{in} \cdot w_{in}) \quad (1)$$

Donde:

*: Representa el operador apropiado (máximo, sumatoria, producto, etc.),

N: El número de entrada a la neurona N_i ,

w_i : El peso.

Los valores de entrada se multiplican por los peso anteriormente ingresados a la neurona. Por consiguiente, los pesos que generalmente no están restringidos cambian la medida de la influencia que tiene los valores de entrada.

2.5.2. La Función de activación

Una neurona biológica puede estar activa (excitada) o inactiva (no excitada); es decir, que tiene un “estado de activación”. Las neuronas artificiales también tienen diferentes estados de activación; algunas de ellas solamente dos, al igual que las biológicas, pero otras pueden tomar cualquier valor dentro de un conjunto determinado.

La función activación calcula el estado de actividad de una neurona; transformando la entrada global (menos el umbral, Θ_i) en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1).

La función activación, es una función de la entrada global ($g_{in} i$) menos el umbral (Θ_i). Las funciones de activación más comúnmente utilizadas son: Función Lineal, Sigmoide y Tangente Hiperbólica.

2.5.3. La Función de salida

El último componente que una neurona necesita es la función de salida. El valor resultante de esta función es la salida de la neurona i ($out i$); por ende, la función de salida determina qué valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente. Normalmente, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango $[0, 1]$ o $[-1, 1]$. También pueden ser binarios $\{0, 1\}$ o $\{-1, 1\}$.

Dos de las funciones de salida más comunes son: Función Identidad y Binaria. (Matich, 2001)

2.5.4. Entrenamiento de una Red Neuronal

El procedimiento utilizado para llevar a cabo el proceso de aprendizaje en una red neuronal se denomina entrenamiento. El Descenso del Gradiente es el que popularmente se impone sobre los demás por su facilidad y extensión de uso, hay muchos otros que pueden resultar interesantes, presentando diferentes características y rendimiento que los pueden hacer más, o menos, adecuados dependiendo de las características del problema concreto al que nos enfrentemos.


El problema de aprendizaje en las redes neuronales se formula en términos de la minimización de la función de error. Normalmente, esta función está compuesta por dos términos, uno que evalúa cómo se ajusta la salida de la red neuronal al conjunto de datos de que disponemos, y que se denomina término de error, y otro que se denomina término de regularización, y que se utiliza para

evitar el sobre aprendizaje por medio del control de la complejidad efectiva de la red neuronal.

Por supuesto, el valor de la función de error depende por completo de los parámetros de la red neuronal: los pesos sinápticos entre neuronas, como suele ser ya habitual, se pueden agrupar adecuadamente en un único vector de peso de la dimensión adecuada. Nuestro objetivo es encontrar el valor del error para obtener un mínimo global de la función error, convirtiendo el problema de aprendizaje en un problema de optimización.

En general, la función de error es una función no lineal, por lo que no disponemos de algoritmos sencillos y exactos para encontrar sus mínimos. En consecuencia, tendremos que hacer uso de una búsqueda a través del espacio de parámetros que, idealmente, se aproxime de forma iterada a un error mínimo de la red para los parámetros adecuados, tal como se indica en la Ilustración 9.

Ilustración 9 Función de error de una red neuronal



Fuente: (Caparrini, 2017)

De esta forma, se comienza con una red neuronal con algún vector inicial de parámetros (a menudo elegido al azar), a continuación se genera un nuevo vector de parámetros, esperando que con ellos la función de error se reduzca (aunque dependiendo del método elegido, no es obligatorio, y temporalmente se puede admitir un empeoramiento del error siempre y cuando conduzca a una disminución posterior más acusada). Este proceso se repite, normalmente, hasta haber reducido el error bajo un umbral tolerable, o cuando se satisfaga una condición específica de parada.

En el caso en que la función cumpla con condiciones suficientes de derivabilidad, podemos calcular las derivadas primera y segunda de esta función en cualquier punto, proporcionando, respectivamente, el vector gradiente (formado por las posibles derivadas parciales):

(2) Vector Gradiente

$$\frac{\partial f}{\partial w_i}, \text{ para } i = 1, \dots, n \quad (2)$$

Y la matriz Hessiana (formada por las posibles derivadas parciales de cada función del vector gradiente):

(3) Matriz Hessiana

$$H_{ij}f(w) = \frac{\partial^2 f}{\partial w_i \partial w_j}, \text{ para } i, j = 1, \dots, n \quad (3)$$

De esta forma, podemos utilizar una información adicional ya que sabemos que un punto (parámetros) óptimo (máximo o mínimo) el gradiente debe representarse por el vector nulo y, adicionalmente, para que sea mínimo deben verificarse algunas condiciones sobre el signo del Hessiano.

(4) Gradiente de Primer y Segundo Orden

$$\nabla f = \begin{pmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{pmatrix} \quad \mathbf{y} \quad \nabla^2 f = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{pmatrix} \quad (4)$$

Aunque el proceso de optimización es inherentemente multidimensional (ya que siempre tendremos más de un parámetro en la función de error), muchos de los algoritmos de optimización que se utilizan en el entrenamiento de redes neuronales hacen uso de una optimización unidimensional de la siguiente forma: primero se calcula una dirección de entrenamiento en la que se espera que el cambio del error sea máximo, y posteriormente se usa un factor de entrenamiento que indica la cantidad de movimiento en la que nos desplazaremos siguiendo esa dirección.

En este sentido, y considerando solo la función en esa dirección, los métodos de optimización unidimensional buscan el mínimo de la función unidimensional que se obtiene de restricciones únicamente a ese hiperplano. Algunos de los algoritmos que usan este método son el método de Brent, y el método de la sección dorada, que se basan en ir reduciendo la amplitud de un intervalo que contiene a ese mínimo hasta que la amplitud del intervalo está por debajo de una tolerancia predefinida.

Aunque los métodos de entrenamiento de redes neuronales más conocidos e implementados son aquellos basados en propiedades de derivabilidad de la función de error, se debe recordar que también existen otros métodos que pueden resultar muy interesantes bajo determinadas circunstancias (algunas veces por obligación, como por ejemplo que la función no sea derivable), como

son los Algoritmos Genéticos, el Templado Simulado, las Colonias de Hormigas, o PSO. (Caparrini, 2017)

2.6. Clasificador Bayesiano

En general, se usan probabilidades de modo informal para expresar la información o la incertidumbre que se tiene acerca de observaciones de cantidades desconocidas. Sin embargo, el uso de probabilidades para expresar la información se puede hacer de modo formal. Desde el punto de vista matemático se puede demostrar que con el Cálculo de Probabilidades se puede representar de modo numérico el conjunto de racional de creencias, de modo que existe una relación entre probabilidad y e información y la regla de Bayes proporciona un modo natural de actualización de las creencias cuando aparece nueva información. Este proceso de aprendizaje inductivo por medio de la regla de Bayes es la base de la Inferencia Bayesiana.

De manera general, los métodos bayesianos son métodos de análisis de datos que se derivan de los principios de la inferencia bayesiana. Estos métodos, proporcionan

1. Estimadores de los parámetros que tienen buenas propiedades estadísticas.
2. Una descripción parsimoniosa (simple) de los datos observados.
3. Estimación de los datos missing y predicciones de futuras observaciones.
4. Una metodología computacional potente para la estimación, selección y validación de modelos.

La metodología bayesiana consta de tres pasos fundamentales (Marin Diazaraque, 2003).

1. Especificar un modelo de probabilidad que incluya algún tipo de conocimiento previo (a priori) sobre los parámetros del modelo dado.
2. Actualizar el conocimiento sobre los parámetros desconocidos condicionando este modelo de probabilidad a los datos observados.

3. Evaluar el ajuste del modelo a los datos y la sensibilidad de las conclusiones a cambios en los supuestos del modelo.

La diferencia fundamental entre la estadística clásica (frecuentista) y la bayesiana es el concepto de probabilidad. Para la estadística clásica es un concepto objetivo, que se encuentra en la naturaleza, mientras que para la estadística bayesiana se encuentra en el observador, siendo así un concepto subjetivo. De este modo, en estadística clásica sólo se toma como fuente de información las muestras obtenidas suponiendo, para los desarrollos matemáticos, que se pueden tomar tamaños límite de las mismas. En el caso bayesiano, sin embargo, además de la muestra también juega un papel fundamental la información previa o externa que se posee en relación a los fenómenos que se tratan de modelizar.

El concepto básico en estadística bayesiana es el de probabilidad condicional:

Para dos sucesos A y B:

(5) Teorema de Bayes

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)} \quad (5)$$

Se puede aplicar esta definición también a variables discretas o continuas. Desde el punto de vista bayesiano, todas las probabilidades son condicionales porque casi siempre existe algún conocimiento previo o experiencia acerca de los sucesos. (Marín Diazaraque, 2003)

2.6.1. Entrenamiento Bayesiano

Es uno de los clasificadores más utilizados por su simplicidad y rapidez. Se trata de una técnica de clasificación y predicción supervisada que construye modelos que predicen la probabilidad de posibles resultados. Constituye una técnica supervisada porque necesita tener ejemplos clasificados para que funcione, como ya veremos.

Para el correspondiente entrenamiento se debe seguir un algoritmo de clasificación, cabe destacar dos partes en el algoritmo. La primera es la construcción del modelo, y la segunda clasificar un nuevo ejemplo con dicho modelo.

2.6.2. Creación del Modelo Bayesiano

En primera instancia se debe calcular las probabilidades a priori de cada clase, siendo cada clase un grupo al cual se va a clasificar. Hay varias formas de establecer la probabilidad a priori a cada clase. La más intuitiva es que todas ellas tengan la misma probabilidad, es decir, 1 dividido entre el número de clases. Si contamos con la opinión de un experto, puede que éste nos proporcione dichas probabilidades. En varios casos se considera cada clase equiprobable.

Para cada clase, se debe realizar un recuento de los valores de atributos que toma cada ejemplo. Se debe distribuir cada clase por separado para mayor comodidad y eficiencia del algoritmo. Se crea una tabla (un otro contenedor) para cada clase y se hace un recuento de valores.

Aplicar la Corrección de Laplace, para que los valores "cero" no den problemas. Lo más simple es sumar una unidad a cada valor de la tabla o contenedor.

Finalmente se normaliza para obtener un rango de valores $[0,1]$. Para normalizar se toma cada valor de cada atributo y se divide por la suma de los valores de la fila.

2.6.3. Clasificación con el Modelo Bayesiano

Para cada clase disponible, se determinan los valores de probabilidad de cada valor de los atributos del nuevo ejemplo, posterior a ello se le aplica la fórmula de Bayes, se debe aplicar para cada clase su probabilidad, tomando así la clase más probable de todas como el grupo clasificado.

2.7. Tabla de Consulta (*Look Up Table*)

En el tema de edición de imagen y videos, una LUT es una tabla para buscar los datos de color de salida correspondientes a los datos específicos de un color de entrada. En otras palabras, es el cambio intencional de color de una imagen. El uso de LUT's permite combinar e integrar el tono de color, reproducir el color deseado de las imágenes grabadas y crear un aspecto único lleno de originalidad, independientemente del dispositivo de salida.


El uso de LUT's es común actualmente en la producción de shows de televisión y películas cinematográficas, donde un aspecto específico es requerido por el director.

LUT puede ser llamada de varias formas: "lut", "Cubo", "tabla" y "L. U. T", dependiendo de la industria. Sin embargo, no es más que una tabla que muestra el valor de salida correspondiente a un valor de entrada. Cuando se usa una LUT en el procesamiento de imágenes, su función es convertir un conjunto de tres valores de RGB en un conjunto de RGB diferente. (Gonzalez, 2018)

En la Ilustración 10 está un ejemplo de una LUT de una sola dimensión (1D LUT), el cual tiene una única entrada y salida, respectivamente. El eje X es la entrada y el eje Y es la salida.

Si el valor de entrada es 80, su valor de salida se convertirá en 50 (● A). De la misma manera, si el valor de entrada es 170, su valor de salida se convertirá en 220 (● B).

Ilustración 10 Concepto de una Tabla de Consulta



Fuente: (Gonzalez, 2018).

Si la entrada es de 8 bits, necesitaremos 256 valores de salida correspondientes a 256 valores de entradas: de 0 a 255. La representación de estas combinaciones está mostrada en la Figura 2. Esto es lo que llamamos LUT (1D LUT).

En este ejemplo, la columna de la izquierda en la Ilustración 11 muestra los valores de entrada, y los valores de salida correspondientes están en la columna de la derecha. Básicamente estamos buscando valores en una tabla, por lo tanto, el acrónimo *LUT* significa *Look Up Table*.

Ilustración 11 Ejemplo de una Tabla de Consulta

Valor de Entrada	Valor de Salida
0	5
1	6
2	8
3	10
...	...
79	47
80	50
81	53
...	...
169	218
170	220
171	222
...	...
252	248
253	250
254	252
255	254

Fuente: (Gonzalez, 2018).

Convirtamos RGB = (80, 80,80) usando una 1D LUT. El valor de entrada 80 correspondiente al valor de salida es 50; por lo tanto, veremos que la salida convertida es RGB = (50, 50,50).

Ahora, dando una visualización al ejemplo de conversión donde cada valor R, G, B usa una LUT diferente. Como muestra la Ilustración 12, esto utiliza tres LUT: R-LUT (rojo), G-LUT (verde), y B-LUT (azul), respectivamente.

Usando tres LUT's, la entrada (● C) RGB = (80, 80,80) la salida se convertirá en RGB = (50, 75,25). Así, puede ver que cada valor R, G, B se convertirá en un valor diferente.

Ilustración 12 Ejemplos del Uso de 3 Tablas de Consulta

LUT para R.		LUT para G.		LUT para B.	
Valor de Entrada	Valor de Salida	Valor de Entrada	Valor de Salida	Valor de Entrada	Valor de Salida
0	5	0	10	0	0
1	6	1	12	1	0
2	8	2	13	2	1
3	10	3	15	3	1
79	47	79	72	79	25
80	50	80	75	80	25
81	53	81	77	81	26
252	242	252	251	252	234
253	245	253	252	253	236
254	248	254	253	254	238
255	251	255	255	255	240

256 Valores

3 Conjuntos

Fuente: (Gonzalez, 2018).

MARCO PRÁCTICO

III. MARCO PRÁCTICO

En el presente apartado se reflejara los procesos implementados para la creación de la inteligencia artificial y sus respectivos entrenamientos, con el fin de llegar a clasificar las papas, adquiridas a partir de un proceso de adquisición de imágenes que también se detallaran más adelante.

3.1. Sistema General

En la Ilustración 13 se observa el diagrama general del sistema propuesto en el presente trabajo. En la sección de Selección de papas, se toma la papa *Willa Imilla*, ya que esta es la de mayor consumo en la ciudad de La Paz, además de la mayor producción en las provincias del departamento de La Paz.


Una vez ya decidido la clase de papa con la cual se va a trabajar, esta es llevada al Sistema de Adquisición, el cual se utilizara tanto para tomar fotografías para el Sistema en línea y fuera de línea.

En el sistema fuera de línea se almacenaran las imágenes en el ordenador, mientras que el sistema en línea registrara las imágenes en tiempo real, procesándolas en ese mismo instante, más adelante se detalla cómo cada sistema procesas las imágenes adquiridas.

El diseño de dicho diagrama se encuentra en la Ilustración 14, pudiendo observas la similitud que poseen ambos sistemas, teniendo procesos inicialmente similares, a pesar de adquirir las imágenes de distintos dispositivos ambos, utilizan el mismo sistema.


Los resultados finales solo se obtienen del sistema fuera de línea, ya que este posee datos de verdad (*Ground Truth Data*), con dichos datos se puede realizar una comparativa de los clasificadores con una clasificación hecha por un humano, y así obtener el grado de éxito que poseen los clasificadores mediante visión artificial.

Ilustración 13 Diagrama Sistema General



Fuente: Elaboración propia

Ilustración 14 Diseño del Sistema General



Fuente: Elaboración propia

3.2. Selección de la Papa

Existe una gran variedad de papas presentes en el altiplano paceño, dicha variedad afecta tanto al tamaño, forma y color de las papas cultivadas. Esta variación no es mínima, es decir, el cambio entre tipos de papas es alto, existiendo papas con formas ovoides (*Solanum tuberosum ssp. Andigena*, Papa Icari) y otras con forma cilíndrica (*Solanum x ajanhuiri*, Papa Ajahuiri) corta o alargada. Así también en las tonalidades de su superficie llega a ser desde un

morado vivo (*Solanum x ajanhuiri*, Papa Larama Yari) hasta pasar por tonos amarillos (*Solanum x juzepczukii*, Papa Janq'o Q'aysalla). Provocando que un solo clasificador pueda clasificar todas la variedad de papa, por ello solo se usó un solo tipo de papa.

La papa empleada para el presente trabajo es la *Willa Imilla* (*Solanum tuberosum ssp. Andigena*). Dicha papa tiene una forma más ovoide con tonos rojizos y en algunas ocasiones con manchas amarillas. Los tubérculos utilizados en el presente trabajo se obtuvieron del “Mercado Rodríguez”, el cual se ubica en Zona 1, Zoilo Flores, La Paz. Este mercado popular abastece verduras, carnes, frutas y otros insumos a la población de la ciudad de La Paz.

3.2.1. Característica de una Papa Dañada

Se entiende como papa dañada un tubérculo que posee heridas como en la Ilustración 15, dichas heridas deben estar presentes en la superficie, provocadas por cualquier tipo de instrumento de agricultura como ser corte de una pala, pico, etc.

Ilustración 15. Papa Dañada: Papa con Cortes por Material de Agricultura



Fuente: Elaboración propia

Así también aquellos tubérculos con gusanos en su interior como la Ilustración 16, pero solamente en el caso de que agujero por donde ingreso el gusano sea visible sin hacer un corte a la papa o lavarla.

Ilustración 16. Papa Dañada: Papa herida por Gusanos




Fuente: Ernesto Cisternas, INA La Cruz (Acuña, y otros, 2015).

3.2.2. Características de Color de una Papa

El color es la principal característica para identificar los daños presentes en la variedad de tubérculos que se utilizó en este trabajo. Existen otras variedades donde el color del tubérculo maduro no es rojo sino que puede ser amarillo o morado. Para la variedad Boliviana Wila Imilla utilizada en este trabajo, el color de la piel varía entre rojo entero, rosado, y en algunas ocasiones segmentos amarillos.

En la Ilustración 17 están graficados los pixeles sanos (puntos amarillos con borde rojo) y dañados (puntos marrones con borde café) del tubérculo en dos distintos ángulos de visión, pudiendo apreciar que ambos conjuntos no son separables linealmente con un hiperplano, la región de la intersección llega a provocar errores en el entrenamiento tanto de la red neuronal y el clasificador bayesiano.

Ilustración 17 Píxeles de Papa en el Plano RGB



Fuente: Elaboración propia

3.3. Sistema de Visión Artificial

3.3.1. Adquisición de la imagen

El sistema de adquisición implementado constaba de:

- La cámara Posterior del Smartphone Sony Xperia Z2 de 20.7 MP (modelo de la cámara: D6503), para el sistema offline.
- Cámara Web Logitech C922 Pro Stream Webcam, para el Sistema online.
- Dos focos FSL LED de 9w y 870 lm, para ambos sistemas.
- Fondo de plástico PVC de color blanco, para ambos sistemas.

Las imágenes almacenadas son la vista superior de los tubérculos dispuestos individualmente sobre un fondo blanco e iluminados con luz LED, como se muestra en la Ilustración 18. Para la iluminación, la luz de los dos focos LED se orientó directamente sobre el tubérculo ya que usando solo la luz del ambiente el brillo de la luz no era suficiente haciendo las imágenes oscuras y creando sombras. A pesar de la implementación de los dos focos LED, el haz de luz era tenue en los bordes de la imagen, pero esta no afecta demasiado a comparación de las imágenes sin los focos. El fondo era de plástico PVC blanco, ya que el uso

de cartulinas y otros tipos de papel de color blanco provocaba que con el uso se generen machas no removibles del fondo. Se utilizó el color blanco para producir alto contraste entre el tubérculo y el fondo, y facilitar la segmentación. Las imágenes están almacenadas en formato JPG, con una resolución real de 1920x1080 píxeles y 1080x1920 píxeles, con 24 bits por píxel, el tiempo de exposición utilizado es 1/320 segundos y un ISO de 50. En la Ilustración 19 se muestra un ejemplo de una imagen adquirida.

Ilustración 18 Adquisición de la Imagen



Fuente: Elaboración Propia.

Ilustración 19 Fotografía de Papa




Fuente: Elaboración Propia.

3.4. Sistema Fuera de Línea (*Offline System*)

Un sistema fuera de línea, como su nombre indica, trabaja fuera del proceso en tiempo real, es decir, con procesos a partir de datos ya adquiridos previamente. Se propone el siguiente sistema para realizar la comparación de clasificadores (Ver Ilustración 20).

Ilustración 20 Diagrama Sistema Fuera de Línea




Fuente: Elaboración propia

Las imágenes adquiridas son todas las fotografías tomadas según la Ilustración 21, a partir de ellas se crean un segundo grupo, para el entrenamiento de los clasificadores, dicho grupo se toma la misma cantidad de imágenes de papas sanas y dañadas de forma aleatoria. La detección de la papa se enfoca a la segmentación del área de interés, es decir ubicar la posición del tubérculo en la imagen para proceder a la extracción de la misma, de dicha imagen en la cual solo se encuentra el tubérculo, se procede a la extracción de sus características, en este caso los colores RGB de la papa segmentada. Una vez segmentada, en las imágenes se procede a entrenar los clasificadores, una vez concluida el

entrenamiento se guarda el algoritmo para clasificar la papa. Dicho algoritmo se utiliza para clasificar todas las imágenes almacenadas, y finalmente el clasificador nos da como resultado el estado de la papa, clasificando el daño presente en las imágenes.

Ilustración 21 Diseño del Sistema Fuera de Línea



Fuente: Elaboración propia

3.4.1. Imagen Almacenada en el Computadora

Se tomó fotografías desde una vista superior a la papa, utilizando el Smartphone Sony Xperia Z2, guardando las imágenes en la memoria externa tipo SD. Dicha memoria SD es puesta en el Ordenador en el cual se ha realizado el trabajo y se realizó una copia de las imágenes para así trabajar con el clasificador.

3.4.2. Detección de la Papa mediante el Modelo HSV

Para poder detectar el tubérculo se implementó el modelo de color HSV. Debido a que en sus 3 dimensiones (Matiz, Saturación y Luminosidad) el tubérculo

sobresale con respecto al fondo, con una mayor diferencia en la dimensión de saturación. En la Ilustración 22 se muestra el modelo HSV, mostrando cada dimensión de forma individual. La información aportada por el modelo HSV muestra distinta información por cada dimensión. La dimensión que más llega a diferenciar la papa del fondo es la de saturación, teniendo valores cercanos al 100% en el fondo y valores próximos al 0% donde está ubicado el tubérculo.

Ilustración 22 Tubérculo en el Modelo HSV



Fuente: Elaboración propia

Así también en la dimensión de la Matiz, se tiene valores cercanos al 100% en la ubicación del tubérculo, y valores próximos al 50% en el fondo.

El método implementado para la detección del tubérculo utiliza los máximos y mínimos de cada dimensión en el modelo HSV, en la Tabla N°6 se muestra los valores máximos y mínimos que detectan el tubérculo en las fotografías del presente trabajo.

Tabla N°6 Máximos y Mínimos de la Detección del Tubérculo

	MIN	MAX
<i>Matiz</i>	0 %	98.5%
<i>Saturación</i>	0 %	14 %
<i>Luminosidad</i>	30 %	100%

Fuente: Elaboración propia


Con los parámetros utilizados en la Tabla N°6 se logró detectar los tubérculos con fallas mínimas en los bordes de la papa, sin embargo la existencia de un exceso de tierra cercana a la papa, puede causar una mala detección.

Sabiendo que en la imagen va a estar solo una papa y un poco de suciedad de la papa como ser tierra y/o polvo, se procedió a detectar el fondo mediante mínimos y máximos, como se explicó anteriormente, para luego invertir la selección y así obtener al tubérculo, en la Ilustración 23 se muestra el proceso ya indicado.

A pesar de la detección de la papa, se puede observar en la en la Ilustración 24 que existe ruido en la imagen, es decir, segmentos blancos que no son papa.

Como se puede observar la imagen original esta apropiada para que el detector pueda obtener buenos resultados, queda un pequeño sector que no es papa en la parte de las esquinas debido al efecto de la iluminación y también alrededor de la papa debido a la tierra que lleva el tubérculo.

Ilustración 23. Selección del Fondo y su Inverso



Fuente: Elaboración Propia.

Ilustración 24. Detección de Ruido al Segmentar el Tubérculo



Fuente: Elaboración Propia.

Para este caso se necesita eliminar esos objetos pequeños por lo que se realizará la siguiente operación morfológica.

(6) Proceso Morfológico - Detección de Tubérculo

$$((A \ominus B) \oplus B1) \quad (6)$$

Donde A es la imagen binaria, B es un elemento estructurante tipo disco de 8x8 y B1 es elemento estructurante tipo disco de 5x5. El erosionado ($\ominus$) se aprecia en la Ilustración 25. Y el dilatado ($\oplus$) en la Ilustración 26.

Ya con este proceso la mayoría de las imágenes con las cuales se ha trabajado detectan solo la papa, en algunas ocasiones se mantiene manchas grande de tierra, para tal caso, al saber que solo se posee una papa, se selecciona el conjunto blanco más grande presente en la imagen, por tanto al no existir manchas de tierra más grande que el tubérculo presente en la imagen, la selección se realiza de manera correcta e ignorando los rastros de ruido presentes.

Ilustración 25. Erosión con un E. E. de 8x8



Fuente: Elaboración Propia.

Ilustración 26. Dilatación con un E. E. de 5x5



Fuente: Elaboración Propia.

3.4.3. Extracción de Características

Como se muestra en la Ilustración 26 se tiene una nueva imagen binaria, llegando a ser el color negro en representación todo lo que “no es papa”, y en color blanco lo que “es papa”. El proceso de detección nos deja dos capas de imágenes, la primera es la imagen binaria que se ilustra anteriormente, y la segunda es la imagen original. Se procede a obtener las coordenadas del segmento blanco más grande presente en la imagen, es decir donde se ubica el tubérculo, para así recortarlo y reemplazar los pixeles blancos por los pixeles reales de la imagen original, como se demuestra en la Ilustración 27.

Ilustración 27. Recorte de la Imagen a solo el Tubérculo



Fuente: Elaboración Propia.

Con esta nueva imagen más pequeña y además de solo tener al tubérculo en primer plano, se realiza un recorrido pixel a pixel para su correspondiente clasificación, así también para su entrenamiento.

3.4.4. Entrenamiento mediante el Modelo RGB

En la fase de entrenamiento para los clasificadores, tanto la red neuronal como el clasificador bayesiano, se utilizó el modelo RGB para el entrenamiento. En el caso de la red neuronal este genera una capa de entrada de 3 neuronas, una por cada dimensión de color y en el clasificador bayesiano nos da una gaussiana de tres dimensiones.

Para poder tener una base de entrenamiento, se seleccionó tanto de papas sanas como dañadas, un área del tubérculo de distintas imágenes, es decir, se tomó una imagen, de dicha imagen con una inspección visual se selecciona un área donde toda la área seleccionada este compuesta de pixeles de papa sana o de papa dañada, según cual muestra de sea obtener.


Una vez obtenido las muestras de papa sana y dañada, se eliminó los pixeles repetidos en cada muestra de forma independiente, de la muestra de papas sanas se eliminó los pixeles repetidos y así también en los pixeles dañados, esto debido a que dos imágenes de tubérculos pueden tener el mismo color de papa sana o dañada. Esta eliminación evitar el tener que entrenar repetitivamente el mismo valor.

3.4.5. Entrenamiento de la Red Neuronal

Para la creación de la red neuronal se utilizó una muestra de entrenamiento, utilizando 50% de la muestra. Asignando el valor de [1,-1] para pixeles de papa dañada y sana respectivamente.


El modelo de la red neuronal es un perceptrón multi capa como se ve en la Ilustración 28, con dos capas ocultas de 3 neuronas y una capa oculta de solo una neurona, utilizando las funciones de transferencia *tansig*, *tansig* y *puerlin* respectivamente, la cual devuelve valores de entre [1;-1], lo cual se adapta correctamente al presente trabajo. En la Ilustración 29 se muestra el entrenamiento de dicha Red Neuronal en maltab.

Ilustración 28 Red Neuronal, perceptrón Multi Capa



Fuente: Elaboración propia

Ilustración 29. Entrenamiento de la Red Neuronal



Fuente: Elaboración propia

Una vez creado y entrenado el modelo con los registros RGB de píxeles de papa dañada y sana, se tomó una muestra seleccionada de forma aleatoria de 10 píxeles para ilustrar el entrenamiento, dicha muestra se detalla en la Tabla N°7.

El modelo ya entrenado toma la imagen del tubérculo ya detectado, y analiza todos sus pixeles, creando una nueva imagen donde la entrada es el pixel como tal y la salida es un nuevo pixel que se asigna según la Tabla N°8.

Tabla N°7. Muestra del Entrenamiento de la Red Neuronal

Muestra	Entrenamiento	RGB	Valor Deseado	Valor Obtenido
1	1718	[200 173 120]	-1	-0.999999995970836
2	2626	[207 184 117]	-1	-0.992550822085943
3	4428	[70 70 44]	-1	-1.031465457137765
4	2218	[165 144 97]	-1	-1.466992055520585
5	1432	[206 186 127]	-1	-1.028481445446521
6	485	[117 93 57]	1	-0.716341554027938
7	472	[37 40 31]	1	1.018821095187313
8	616	[104 78 41]	1	0.997781166661551
9	872	[106 83 33]	1	0.802271514517134
10	639	[154 133 88]	1	1.003187938290170

Fuente: Elaboración propia


Tabla N°8. Reasignación de Pixeles Clasificados

Pixel de la Papa Detectada	Nuevo Valor Clasificado
Papa Dañada	Rojo [255;00;00]
Papa Sana	Amarillo [255;255;00]
Fondo, manchas, etc.	Negro [00;00;00]

Fuente: Elaboración propia


Para una tener una interpretación correcta de la Tabla N°8. La Ilustración 38, Ilustración 39 y la Ilustración 40 muestran el tubérculo detectado (izquierda), seguido de su clasificación con la red neuronal (derecha).

Ilustración 30. Ejemplo 1 de Clasificación con la Red Neuronal




Fuente: Elaboración propia

Ilustración 31. Ejemplo 2 de Clasificación con la Red Neuronal



Fuente: Elaboración propia

Ilustración 32. Ejemplo 3 de Clasificación con la Red Neuronal



Fuente: Elaboración propia

3.4.6. Entrenamiento del Clasificador Bayesiano

Se usó las imágenes de entrenamiento para obtener un clasificador en que estén las clases:

Ilustración 33 Clases de Clasificación - Bayesiano

Clase (K)	Id (k)
<i>Papa Dañada</i>	1
<i>Papa Sana</i>	2
<i>Otro</i>	0

Fuente: Elaboración propia

Teniendo un conjunto {C} de colores RGB de N_k muestras de colores de cada clase $k \in \{1,2\}$ (se exceptúa la clase 0), pertenecientes a las distintas imágenes de entrenamiento, es posible obtener sus estadísticas de primer y segundo orden (media y matriz de covarianza).

(7) Vector de Medias

$$\mu_k = \frac{1}{N_k} * \sum_{i=1}^{N_k} c_i^k \quad (7)$$

(8) Clases del Clasificador Bayesiano

$$k \in \{1,2\} \quad (8)$$

Siendo μ_k un vector de 1x3 debido a que el sistema en el cual se trabajó las imágenes de entrenamiento es RGB, es decir 3 colores. N_k Es el total de muestras de entrenamiento de cada clase k y c_i^k los pixeles de la muestra.

(9) Matriz de Covarianzas

$$\Sigma_k = \frac{1}{N_k} * \sum_{i=1}^{N_k} (c_i^k - \mu_k)^T * (c_i^k - \mu_k) \quad (9)$$

Σ_k Es la covarianza compuesta por una matriz de 3x3, ya que trabajamos con 3 dimensiones, para esta ecuación se utiliza la μ_k de cada clase. Al ser μ_k un vector para obtener su cuadrado se debe transponer una parte del mismo.

Luego, se puede definir el clasificador como:

(10) Clasificador Bayesiano

$$\kappa(c) = \begin{cases} p_1(c) & p_1(c) > p_{umbral} \\ 0 & \text{otherwise} \end{cases} \quad (10)$$

Para entrenar el clasificador debe definir a que clase pertenece cada pixel de las imágenes del conjunto de entrenamiento.

(11) Función de Probabilidad

$$p_k(c) = \frac{1}{(\sqrt{(2\pi)} * |\Sigma_k|)^d} * e^{-\frac{1}{2} * Q_k(c)} \quad (11)$$

Para cada clase k se obtiene $p_k(c)$, siendo d en número de dimensiones a trabajar, en este caso 3 debido al RGB. $Q_k(c)$ Es una subocupación que se detalla a continuación.

(12) Sub Función de Probabilidad

$$Q_k(c) = (c - \mu_k) * \Sigma_k * (c - \mu_k)^T \quad (12)$$

$Q_k(c)$ Debe generar un solo número y no una matriz. Para ello se reordena la multiplicación para evitar errores de multiplicación de matrices, por tanto se pone entre $(c - \mu_k)$ la covarianza Σ_k , así obtenemos una multiplicación de $1 \times 3 * 3 \times 3 * 3 \times 1$ y por regla de matrices el resultado nos da un matriz de 1×1 , es decir un solo número.

p_{umbral} Es un parámetro del clasificador que define el tamaño de las clases. Según crezca o disminuya p_{umbral} el tamaño de una clase disminuye o aumenta.

Ya para la clasificación se toma la clase más probable de las dos que se generan, además de que la probabilidad de Daño sea superior a p_{umbral} , por cada pixel como se muestra en la Tabla N°9. En la Tabla N°9 se puede apreciar 10 ejemplos de entrenamiento del total que existen en el entrenamiento, se tomó de la misma muestra al azar del clasificador con redes neuronales. p_{umbral} Toma el valor $1e-10$, este número se generó a partir de pruebas hechas comparando los resultados con los datos de verdad, dichos datos se mencionan en el siguiente punto.

Tabla N°9. Muestra de clasificación del entrenamiento Bayesiano


Muestra	RGB	Prob. Sano	Prob. Dañado	Clasificación Deseada	Clasificación Obtenida
1718	[200 173 120]	6.5e-07	3.2e-09	Sano	Sano
2626	[207 184 117]	5.7e-07	2.4e-09	Sano	Sano
4428	[70 70 44]	1.3e-08	2.8e-07	Sano	Dañado
2218	[165 144 97]	1.2e-06	6.3e-08	Sano	Sano
1432	[206 186 127]	2.2e-07	3.9e-10	Sano	Sano
485	[117 93 57]	2.6e-07	1.1e-07	Dañado	Sano

472	[37 40 31]	1.1e-10	2.3e-06	Dañado	Dañado
616	[104 78 41]	1.2e-08	1.2e-06	Dañado	Dañado
872	[106 83 33]	1.1e-08	1.1e-06	Dañado	Dañado
639	[154 133 88]	7.3e-07	4.7e-08	Dañado	Sano

Fuente: Elaboración propia


Tal como se hizo en el clasificador con redes neuronales, en este clasificador se creó una nueva imagen donde la entrada es el pixel como tal y la salida es un nuevo pixel que se asigna según la Tabla N°8. Para una interpretación correcta de la Tabla N°8, la Ilustración 34, Ilustración 35 y la Ilustración 36 muestran el tubérculo detectado (izquierda), seguido de su clasificación con el clasificador bayesiano (derecha).

Ilustración 34. Ejemplo 1 de Clasificación con el clasificador Bayesiano




Fuente: Elaboración propia

Ilustración 35. Ejemplo 2 de Clasificación con el clasificador Bayesiano



Fuente: Elaboración propia

Ilustración 36. Ejemplo 3 de Clasificación con el clasificador Bayesiano




Fuente: Elaboración propia

3.4.7. Datos de Verdad (Ground Truth Data)

Para el presente trabajo el *Ground Truth* construido para las imágenes de prueba y de entrenamiento fue con: anotación por humanos, es decir, junto a expertos se seleccionó las áreas de interés del tubérculo, dichas áreas son el daño presente en las papas. Ya que en ciertas áreas dañadas, desde la visualización de la imagen, puede ser tomada como sano debido a la tonalidad y cantidad de iluminación que existe, esto provoca una confusión para los clasificadores, ya que un mismo pixel puede ser tanto una área dañada como sana, esto causado tanto por el factor del entorno de iluminación y/o la cantidad de tierra presente en el tubérculo.

En las Ilustración 37 (inciso B), se muestra un ejemplo del *Ground Truth* construido, marcando de negro el fondo, amarillo para las áreas sanas de la papa, y rojo para el daño presente. En el Inciso A, se encuentra la imagen de la papa de la cual se construyó el ground truth.

Ilustración 37 *Ground Truth* de un Tubérculo



Fuente: Elaboración propia

3.4.8. Eliminación de Impurezas del Clasificador de la Red Neuronal

Una vez clasificada la papa, dicha clasificación debe pasar por un proceso de limpieza el cual elimina los errores producidos por el ruido que puede tener la imagen del tubérculo. Para la eliminación de las impurezas o limpieza se binariza el tubérculo clasificado, tomando al daño con valor 1 y 0 a las partes sanas. Ya la imagen binarizada se emplea el siguiente proceso morfológico.


(13) Proceso Morfológico - Impurezas Red Neuronal

$$(((A \bullet B) \ominus B1) \oplus B2) \quad (13)$$

Donde A es la imagen binaria, B es un elemento estructurante tipo disco de 5x5, B1 es elemento estructurante tipo disco de 4x4 y B2 es elemento estructurante tipo disco de 9x9. El resultado del cierre ($\bullet$), erosionado ($\ominus$) y dilatado ($\oplus$) se muestra en la Ilustración 38, Ilustración 39 e Ilustración 40, con el tubérculo


detectado (izquierda), seguido del *Ground Truth* (centro) de dicho tubérculo y su limpieza del clasificador de red neuronal (derecha).

Ilustración 38. Ejemplo 1 de Clasificación Limpio con la Red Neuronal




Fuente: Elaboración propia

Ilustración 39. Ejemplo 2 de Clasificación Limpio con la Red Neuronal



Fuente: Elaboración propia

Ilustración 40. Ejemplo 3 de Clasificación Limpio con la Red Neuronal



Fuente: Elaboración propia

3.4.9. Eliminación de Impurezas del Clasificador Bayesiano


Una vez clasificada la papa, dicha clasificación debe pasar por un proceso de limpieza el cual elimina los errores producidos por el ruido que puede tener la imagen del tubérculo. Para la eliminación de las impurezas o limpieza se binariza el tubérculo clasificado, se emplea el mismo método que se usó para la red neuronal, es decir, se toma el daño con valor 1 y 0 a las partes sanas. Ya la imagen binarizada se emplea el siguiente proceso morfológico.

(14) Proceso Morfológico - Impurezas Clasificador Bayesiano

$$(((A \circ B) \oplus B1) \ominus B2) \quad ((14))$$


Donde A es la imagen binaria, B es un elemento estructurante tipo disco de 5x5, B1 es elemento estructurante tipo disco de 4x4 y B2 es elemento estructurante tipo disco de 9x9. El resultado de la apertura ($\circ$), dilatación ($\oplus$) y erosionado ($\ominus$) se muestra en la Ilustración 41, Ilustración 42 e Ilustración 43, con el tubérculo detectado (izquierda), seguido del *Ground Truth* (centro) de dicho tubérculo y su limpieza del clasificador de red neuronal (derecha).

Ilustración 41. Ejemplo 1 de Clasificación Limpio con el clasificador Bayesiano




Fuente: Elaboración propia

Ilustración 42. Ejemplo 2 de Clasificación Limpio con el clasificador Bayesiano



Fuente: Elaboración propia

Ilustración 43. Ejemplo 3 de Clasificación Limpio con el clasificador Bayesiano




Fuente: Elaboración propia

3.5. Sistema en Línea (*Online System*)

A diferencia del sistema offline, en un sistema online los datos que se procesan se los adquieren en ese mismo instante de su funcionamiento, dejando el sistema que se propuso anteriormente obsoleto, por tanto se propone el siguiente sistema (Ver Ilustración 44).


La nueva imagen adquirida se obtiene según la Ilustración 45, luego se detecta y extrae las características de la misma manera que el sistema offline. Ya obtenido el clasificador entrenado, este llega a tener un imperfecto, el cual es que realiza el proceso de clasificación muy lenta para un sistema online, llegando a tardar entre 10 a 20 segundos procesar una imagen de una papa, esto se debe al proceso matemático que se lleva a cabo pixel a pixel, por tanto se usa una Tabla de Consulta, la cual solo realiza un proceso de indexación, con esto el tiempo de clasificación de tubérculos pasa a ser entre 0.7 a 1.5 segundos por imagen, siendo un tiempo aceptable, comparado al anterior. Una vez clasificada dicha imagen es mostrada en tiempo real en pantalla, tras concluir este proceso se vuelve a adquirir una nueva imagen.

Ilustración 44 Diagrama del Sistema Online



Fuente: Elaboración propia

Ilustración 45 Diseño del Sistema Online



Fuente: Elaboración propia

3.5.1. Imagen en Tiempo Real

Se tomó fotografías desde una vista superior a la papa, utilizando la Cámara Web *Logitech C922 Pro Stream*, transmitiendo un video a tiempo real al programa propuesto, dicho programa guarda un *frame* (imagen) del video por cada segundo transmitido, en el transcurso de un segundo aproximadamente, el programa clasificada el tubérculo con los dos clasificadores mencionados en el presente trabajo .

3.5.2. Detección de la Papa y Extracción de Características

Tanto para la detección de la papa y la extracción de características son los mismos empleados que el sistema fuera de línea, debido a que la adquisición de la imagen es la misma, es decir, ambas usan el mismo sistema de adquisición, además de tomar la fotografía del mismo Angulo y altura con respecto a la papa.

En la detección se procede a ubicar la papa mediante máximos y mínimos usando el modelo de color HSV. Así también la extracción de caracterizas, se realiza un recorte de la imagen para así obtener solo la imagen y desechar el fondo que no es de utilidad en este trabajo, y usando el modelo RGB para la clasificación directa y ya no así su entrenamiento, ya que el sistema en línea utiliza el clasificador entrenado del sistema fuera de línea.

Una diferencia presente entre ambos sistemas en el aspecto de detección y extracción de características, es que el sistema en línea redimensiona la imagen original adquirida, es decir, debido al tamaño de la imagen tomada de la cámara web, dicha imagen tiene una dimensión de 1920x1080. Teniendo un total de 2.073.600 pixeles para trabajar, debido a esta alta cantidad el proceso es lento, llegando a durar 10 segundos como promedio mínimo, para evitar este problema se reduce las dimensiones a 480x270, dando un total de 129.600 pixeles, al momento de detectar dicha dimensión se hace más pequeña, permitiendo obtener una clasificación en el tiempo de un segundo en promedio.


3.5.3. Tabla de Consulta (*Look Up Table*)

En el caso del clasificador bayesiano, el proceso es lento, se debe realizar la operación de la gaussiana de tres dimensiones en 2 ocasiones, tanto para el caso de “daño” y el caso de “sano” o “no daño”, lo que puede ser una operación muy lenta cuando se realiza pixel a pixel. Lo ideal en este caso es armar una Tabla de Consulta, LUT (*look up table*), es decir un vector asociativo, que se usa para sustituir una rutina de computación con una simple indexación de los vectores. Son muy útiles a la hora de ahorrar tiempo de procesamiento, porque sacar un valor de memoria es mucho más rápido que hacer una operación computacional.

Ahora ocurre otro problema con el que se tropezó, ya que un color, por ejemplo R tiene un rango de 0 a 255, ósea 256 posibles valores, entonces para tener todas las combinaciones de colores se necesitaría $256 \times 256 \times 256 = 16.777.216$, más de 16 millones de combinaciones lo cual tardaría mucho tiempo en obtener la Tabla de Consulta.

Para esto se optó por una solución muy sencilla, se obtendrá un muestro de los 16 millones, es decir se tomará datos cada cierto volumen de rango, en este caso de 16 en 16 en cada eje, entonces se tendrá 4096 valores por cada color RGB, de los cuales se harán una sumatoria de dichos valores para que el nuevo valor del color RGB sea solo uno. Como resultado se tiene $16 \times 16 \times 16 = 4096$ combinaciones en una matriz 3D, que fácilmente puede ser consultada para obtener resultados. En la Ilustración 46 se tiene el espacio original de 16 millones de colores y a la derecha el nuevo espacio de 4096 colores, de los cuales cada color representa 4096 colores del espacio original.

Ilustración 46 Compresión del Espacio RGB



Fuente: Elaboración propia

3.5.4. Eliminación de Impurezas

De igual forma que se hizo en la detección y la extracción de características, el proceso de eliminación de impurezas del sistema en línea es similar en varios aspectos a del sistema fuera de línea.

Entre las similitudes que poseen ambos sistemas, está el hecho que ambos utilizan el modelo RGB para su clasificación, ya que los clasificadores fueron entrenados bajo este modelo de color. Así también, el clasificador de Red Neuronal no se ve alterado en su proceso para el sistema en línea. El clasificador de Red Neuronal guarda en una variable neuronal la red entrenada para clasificar el tubérculo, dicha red recibe un vector con todos los píxeles de la imagen, y la red devuelve otro vector con los píxeles clasificados.

En el caso del clasificador bayesiano este si posee diferencias con respecto a su versión para el sistema fuera de línea, ya que este emplea la Tabla de Consulta para su clasificación. Además de consultar dicha tabla, se debe realizar un proceso previo, ya que la Tabla trabaja con 16 valores por dimensión, mientras que los píxeles de la imagen a clasificar trabajan en un sistema de 256 valores por dimensión, haciendo necesario la conversión de los valores para poder usar de manera correcta la Tabla de Consulta.

Para la redimensión de los valores del pixel, se le divide entre 16 (debido a que la una dimensión tiene 16 valores, este se divide entre el valor máximo de la dimensión original, es decir 256; obteniendo $256/16=16$). Tras la división se redondea ignorando los decimales obtenidos, y se le suma una unidad. Con esta redimensión se obtiene los valores para la Tabla de Consulta, a excepción del número 256, ya que al redimensionar, este toma el valor de 17, sobrepasando los valores disponibles, para este único caso, 256 se lo vuelve 16 para evitar error de indexación.

3.6. Resultados del Sistema Fuera de Línea

Para la comparativa de los resultados de ambos clasificadores, se utiliza la notación de la matriz de confusión como se muestra en la Tabla N°10, así para facilitar la definición de los parámetros de desempeño.


Tabla N°10. Matriz de confusión, Clasificador de dos clases

	Verdadero	Falso
Verdadero	Verdadero Positivo (VP)	Falso Positivo (FP)
Falso	Falso Negativo (FN)	Verdadero Negativo (VN)

Fuente: Elaboración propia

Dichos valores se generan comparando cada clasificador con el ground truth, en la Ilustración 47 se muestra como se obtuvieron los valores de la matriz de confusión, este proceso se realizó por cada imagen que se tenía para las pruebas, es decir se obtuvieron 200 matrices, 100 del clasificador con redes neuronales y 100 con el clasificador bayesiano, por cada umbral, se realizaron pruebas con 11 distintos umbrales por cada clasificador, en total 22 umbrales. El total de matriz obtenidas son 2200, 100 imágenes por 2 tipos de clasificadores por 11 umbrales distintos de cada clasificador.

Ilustración 47 Relación *Ground Truth* - Matriz de Confusión



Fuente: Elaboración propia

Para una mejor explicación de los resultados se le asignaron nombres o abreviaturas a los umbrales usados más adelante, siendo M el umbral medio, S los umbrales superiores o de mayor valor al medio e I para los umbrales inferiores al umbral medio. Dicho umbral medio es el primer umbral con el cual se empezó a trabajar y a partir de este se obtuvieron los demás. En la Tabla N°11 se muestra lo anteriormente explicado.

Tabla N°11 Umbrales de los Clasificadores

Abrev.	Umbral Red Neuronal	Umbral Bayesiano
I5	-1.0000002348	5e-12
I4	-1.00000023473	1e-11
I3	-1.00000023471	3e-11
I2	-1.000000234705	5e-11
I1	-1	9e-11
M	0	1e-10
S1	1	2e-10
S2	1.00000518	4e-10
S3	1.000005195	7e-10
S4	1.0000052	1e-09
S5	1.000005205	5e-09

Fuente: Elaboración propia

Ya obtenida las matrices de confusión de ambos clasificadores, se obtiene los siguientes indicadores que se reflejan en la Tabla N°12.

En el caso de las papas sanas, estas no presentan daño alguno, es decir, la cantidad de daño presente es Cero. Esto provocó que los indicadores de desempeño den resultados Indeterminados, debido a la división por cero, en los casos de PVP, PFN y TPP.

Debido a esta dificultad, los resultados finales que se reflejan en la curva ROC que se menciona más adelante, solo contemplan las matrices obtenidas a partir de las imágenes de tubérculos dañados, es decir, la mitad de la muestra total.

Aunque no se contempla en los resultados finales las papas sanas, en la Tabla N°13 se muestra los promedios obtenidos de los indicadores de desempeño por cada umbral del clasificador con redes neuronales, y así también en la Tabla N°14 están los mismos resultados pero del clasificador bayesiano.

Tabla N°12. Indicadores de Desempeño

Indicador	Formula	Uso
Proporción de Verdaderos Positivos	$PVP = \frac{VP}{(VP + FN)}$	Efectividad , Sensibilidad
Proporción de Falsos Negativos	$PFN = \frac{FN}{(VP + FN)}$	Error Positivo
Proporción de verdaderos Negativos	$PVN = \frac{VN}{(VN + FP)}$	Especificidad
Proporción de Falsos Positivos	$PFP = \frac{FP}{(VN + FP)}$	Error Negativo, falsa alarma
Taza de Predicción Positivos	$TPP = \frac{VP}{(VP + FP)}$	Precisión

Taza de Predicción Negativa	$TPN = \frac{VN}{(VN + FN)}$	
Área bajo la Curva	$AUC = \frac{(VP + VN)}{(VP + VN + FP + FN)}$	Exactitud

Fuente: Elaboración propia

Como se puede observar en la Tabla N°13, a partir de los umbrales superiores a -1 el AUC, es casi perfecto llegando a cubrir casi el 100%. Con umbrales negativos el clasificador empieza a generar errores, llegando a fallar al momento de detentar los sectores sanos, como indica la variable PVN.

Tabla N°13 Indicadores Papas Sanas - Clasificación Red Neuronal

Umbral	PVP	PFN	PVN	PFP	TPN	TPP	AUC
I5	-	-	0,05863	0,94137	0,94137	-	0,05874
I4	-	-	0,07872	0,92128	0,92128	-	0,07883
I3	-	-	0,11134	0,88866	0,88866	-	0,11145
I2	-	-	0,14919	0,85081	0,85081	-	0,14930
I1	-	-	0,99961	0,00039	0,00039	-	0,99950
M	-	-	0,99961	0,00039	0,00039	-	0,99951
S1	-	-	0,99991	0,00009	0,00009	-	0,99980
S2	-	-	1	0	0	-	0,99989
S3	-	-	1	0	0	-	0,99989
S4	-	-	1	0	0	-	0,99989
S5	-	-	1	0	0	-	0,99989

Fuente: Elaboración propia

Tabla N°14 Indicadores Papas Sanas - Clasificador Bayesiano

Umbral	PVP	PFN	PVN	PFP	TPN	TPP	AUC
I5	-	-	1	0	0	-	0,9998908
I4	-	-	1	0	0	-	0,9998908
I3	-	-	1	0	0	-	0,9998908
I2	-	-	1	0	0	-	0,9998908
I1	-	-	1	0	0	-	0,9998908
M	-	-	1	0	0	-	0,9998908
S1	-	-	1	0	0	-	0,9998908
S2	-	-	1	0	0	-	0,9998908
S3	-	-	1	0	0	-	0,9998908
S4	-	-	1	0	0	-	0,9998908
S5	-	-	1	0	0	-	0,9998908

Fuente: Elaboración propia

A diferencia del clasificador con redes neuronales, la clasificación bayesiana no llega a sufrir cambios en la detección de papas sanas, como se podrá observar en la Tabla N°14 a pesar de los distintos umbrales el PVN es el 100%, y el AUC no baja del 99.9%.

En la Tabla N°15 se muestra los promedios obtenidos de los indicadores de desempeño de las imágenes de papas dañadas, esto por cada umbral del clasificador con redes neuronales, y así también en la Tabla N°16 están los mismos resultados pero del clasificador bayesiano.

Tabla N°15 Indicadores de Desempeño - Clasificación Red Neuronal

Umbral	PVP	PFN	PVN	PFP	TPN	TPP	AUC
I5	0,99566	0,00434	0,01166	0,98834	-	0,51771	0,51809
I4	0,97650	0,02350	0,06265	0,93735	-	0,52343	0,53208
I3	0,94545	0,05455	0,18592	0,81408	0,74628	0,54547	0,58057
I2	0,90668	0,09332	0,39752	0,60248	0,80468	0,59825	0,66828
I1	0,87044	0,12956	0,86168	0,13832	0,86584	0,88433	0,91795
M	0,84465	0,15535	0,88196	0,11804	0,84847	0,90102	0,91596
S1	0,81597	0,18403	0,89962	0,10038	0,82580	0,91867	0,91121
S2	0,67146	0,32854	0,90461	0,09539	0,65863	0,90877	0,80593
S3	0,58872	0,41128	0,91163	0,08837	0,62073	0,90320	0,74947
S4	0,51511	0,48489	0,92599	0,07401	0,59560	0,89943	0,70356
S5	0,10648	0,89352	0,99121	0,00879	0,50080	-	0,51477

Fuente: Elaboración propia

Igual que sucede con varios umbrales al momento de clasificar las papas sanas, se producen resultados indeterminados en algunos casos, en el umbral 1.000005205 la Taza de Falsos Positivos (TFP), es indeterminado debido a que al menos un resultado en alguna imagen resulto indefinido, esto a causa que en dicha imagen, el clasificador obtuvo un 100% de daño o 100% de sano al tubérculo. Las mejores exactitudes (AUC) para el clasificador con redes neuronales son -1, 0 y 1, teniendo una exactitud de 91.7% 91.5% 91.1% respectivamente, todas superior al 90%, siendo el clasificador denominado como muy bueno. Además de la exactitud, tiene una efectividad mayor al 81% en los tres casos mencionados, es decir, detecta un 81% del daño real existente, así también una especificidad mayor al 86%, es decir, de la parte sana presente en el tubérculo se obtiene correctamente un 86%.

Tabla N°16 Indicadores de Desempeño - Clasificador Bayesiano

Umbral	PVP	PFN	PVN	PFP	TPN	TPP	AUC
I5	0,98048	0,01952	0,51225	0,48775	0,94973	0,67448	0,79076
I4	0,97240	0,02760	0,58366	0,41634	0,94411	0,70606	0,82179
I3	0,95002	0,04998	0,70789	0,29211	0,92851	0,77349	0,87115
I2	0,93300	0,06700	0,76100	0,23900	0,91513	0,80709	0,88824
I1	0,90110	0,09890	0,81766	0,18234	0,89325	0,84593	0,90220
M	0,89736	0,10264	0,82479	0,17521	0,89022	0,84992	0,90419
S1	0,84034	0,15966	0,88863	0,11137	0,84986	0,89951	0,91092
S2	0,77263	0,22737	0,93441	0,06559	0,80243	0,93598	0,90323
S3	0,70372	0,29628	0,96034	0,03966	0,75688	0,95789	0,88473
S4	0,65577	0,34423	0,97168	0,02832	0,72682	0,97067	0,86847
S5	0,32376	0,67624	0,99811	0,00189	0,55797	-	0,70080

Fuente: Elaboración propia

En el caso del clasificador bayesiano, también sufre resultados indeterminados el un extremo de sus umbrales, en el umbral 5e-9. Pero con respecto a su exactitud (AUC), 4 umbrales superan el 90%, y 10 de los 11 son mayores al 75%, cantidad mínima para ser denominado un clasificador bueno, En relación con el clasificador con redes neuronales, este solo supera el 75% de exactitud en 4 de los 11 umbrales usados. En los umbrales centrales, es decir I1, M y S1 se tiene una efectividad superior al 84%, 3% mayor que la red neuronal, y una especificidad mayor al 81%, siendo 5% inferior a la especificidad de la red neuronal en los umbrales centrales. Pudiendo llegar a concluir que el clasificador bayesiano tiene mayor grado de éxito en la detección de daño presente en un tubérculo que la red neuronal.


3.7. Comprobación de la Hipótesis

La hipótesis planteada en este trabajo indica que:

“El sistema de clasificación de papas mediante visión artificial posee un buen desempeño de clasificación en la detección de los tubérculos dañados frente al sistema manual.”

En la Ilustración 48 se graficaron las curvas ROC para las dos inteligencias artificiales de clasificación, siendo cada coordenada el resultado final de cada umbral de los dos clasificadores.

Ilustración 48 Curva ROC de los Clasificadores



Fuente: Elaboración propia

Como se podrá la curva azul, perteneciente al clasificador con redes neuronales es inferior en general a la curva roja, perteneciente al clasificador bayesiano, aun así en un segmento optimo, ambos clasificadores se llegan a cruzar, existiendo

diferencias mínimas. El clasificador con redes neuronales tiene una exactitud máxima del 91.795% y el clasificador bayesiano 91.092%, pero la red neuronal tiene un PVN inferior del bayesiano. Siendo la red neuronal superior al clasificador bayesiano en un solo punto de corte, aparte de este punto, el clasificador bayesiano supera a la red neuronal.

Mediante la curva ROC ilustrada, se obtuvo que el desempeño de clasificación es la mayor área bajo la curva (AUC). Por lo tanto, el clasificador bayesiano cubre una mayor área con una proporción de efectividad del 89.736% y el clasificador con red neuronal, cuya efectividad es 84.465%, en ambos casos, los dos clasificadores superan el 60% mínimo especificado en los criterios de validación.

Por tanto el clasificador bayesiano y el clasificador con redes neuronales aceptan la afirmación planteada en la Hipótesis. Estando hasta un 29% por encima del valor mínimo requerido para que la afirmación planteada sea cumplida.

IV. CONCLUSIONES Y TRABAJOS FUTUROS

4.1. Conclusiones

En los umbrales medios de ambos clasificadores, los resultados del AUC son muy similares, con una variación inferior al 2%, pero en lo que cabe a los umbrales superiores, es decir, los umbrales del S2 al S5, el clasificador bayesiano posee resultados entre 70% y 90%, con respecto al clasificador con redes neuronales que su rango de variación es inferior, ya que ronda entre 51% y 80%. Ahora bien en los umbrales Inferiores, es decir, los umbrales del I2 al I5, el clasificador bayesiano mantiene alto índices de éxito, teniendo un rango entre 79% y 88%, pero el clasificador con redes neuronales empeora con respecto al clasificador bayesiano y así también con sus mismo umbrales superiores, estando con un rango de exactitud entre 51% y 66%. El clasificador Bayesiano es una técnica de clasificación sencilla, tiene pocos parámetros que se pueden

obtener con un análisis cuidadoso de la información estadística de las muestras. El clasificador con redes neuronales es una técnica más compleja ya que requiere la asignación de muchos parámetros y como no hay un algoritmo específico para la selección de estos, se produce incertidumbre en cuanto al óptimo funcionamiento del clasificador. Sin embargo, ofrece ventajas tales como: capacidad para aprender de los patrones, separación de clases que no son linealmente separables, robustez ante datos ruidosos, adaptabilidad, procesamiento paralelo, entre otras.

El clasificador bayesiano tiene mejor desempeño según las dos técnicas utilizadas para la comparación de los clasificadores como son: índices de desempeño usando la matriz de confusión y las curvas ROC. Con base en los índices de desempeño obtenidos con la matriz de confusión el clasificador bayesiano presenta mayor efectividad, especificidad y precisión, además de menor error. Y analizando los clasificadores con las curvas ROC, el clasificador bayesiano también llega a ser mejor para la clasificación de los tubérculos que el clasificador con redes neuronales.

Debido a la inconsistencia y variabilidad que existen en las papas, ya sean la misma clase, estas al momento de ser clasificadas, pueden llegar a producir errores debido a la cantidad presente de tierra que tiene encima, esto varía según la cosecha, ya que en algunos casos se puede recolectar las papas cuando la tierra está seca, llegando al mercado informal papas con poca cantidad de tierra y polvo, mientras que el caso de realizar una cosecha con humedad en el ambiente o la tierra, este llega apegar mayor cantidad de tierra encima de la papa, dicha papa puede llegar a tapar los denominados “ojos de la papa” o algún agujero causado por gusanos, en ambos casos ya no se serían posibles verificar en la clasificación.

Otro factor influyente además de la cantidad de tierra presente en una papa, es el tiempo de exposición al sol o la sequedad presente en su superficie, una papa

con daños causado por corte de cosecha puede llegar a tener un tono muy similar a la superficie de la papa, esto a causa de la sequedad, una papas lastimada superficialmente en un ambiente seco, llega a tener daños solo en la cascara, manteniendo una papa sana por dentro, pero una papa lastimada superficialmente en un ambiente húmedo, el agua y la humedad llegan a penetrar en interior del tubérculo, llegando a podrir desde dentro. Esta variación complica una clasificación eficaz, una alternativa a estos posibles problemas es una clasificación espectral de la papa o mediante otro tipo de sensores complementarios.

4.2. Trabajos Futuros

Como continuación de este trabajo, existen diversas líneas de investigación que quedan abiertas y en las que es posible continuar trabajando. Durante el desarrollo de esta tesis han surgido algunas líneas futuras que se han dejado abiertas y que se esperan investigar en un futuro; son el resultado de cuestiones que han ido surgiendo durante la realización de la misma.

A continuación se presentan algunos trabajos futuros que pueden desarrollarse como resultado de esta investigación, que no han podido ser tratados con la suficiente profundidad en el presente trabajo. Entre los posibles trabajos futuros se destacan:

- Variación en el Lumen presente en el módulo de iluminación, todas las fotografías tomadas para el este trabajo, se usó un par de bombillas LED de 9W de potencia, dándonos un lumen de 87lm. El empleo de bombillas de distintas potencia, nos permitirá obtener diferentes cantidades de lúmenes en las imágenes, con ello se podría calcular la cantidad optima de luz para clasificar un tubérculo.
- Cambio en el “Elemento Estructurante” para los procesos morfológicos, como se mencionó en varios apartados del documento, para la eliminación

impurezas y para la detección del tubérculo se empleó procesos morfológicos, dichos procesos dependen de un elemento estructurante, también llamado *strel*, dicho *strel* es una matriz binaria, en el que los pixeles verdaderos se incluyen en el cálculo y los pixeles falsos no. Matlab posee 10 tipos de *strel* para trabajar, de los cuales se usó el llamado *disc*. Una investigación a futuro puede determinar cuál de los 10 tipos se adecua mejor para el presente trabajo.

- Resolución optima de la imágenes a procesar, en el presente trabajo se trabajó con dos cámaras distintas, el lente usado por ambas fue de 13MP y una resolución de Full HD, es decir, 1920x1080. Esta resolución nos proporciona más de 2 millones de pixeles a procesar, por tanto se aconseja hacer una investigación para determinar si una resolución más baja otorgaría una clasificación similar, o si la pérdida de calidad implicaría una mala clasificación, de la misma forma, sin una mayor resolución permitirá detectar mejor los detalles.

BIBLIOGRAFÍA

Acuña, Ivette y Paz Castro, María . 2015. Manual Interactivo de la Papa INIA. [En línea] 4 de Agosto de 2015. [Citado el: 4 de Septiembre de 2018.] <http://manualinia.papachile.cl/?page=manejo&ctn=78>.

Ávila Figueroa, Patricio Alejandro. 2004. Tesis Latinoamericanas. [En línea] 18 de 10 de 2004. [Citado el: 14 de 06 de 2017.] <http://www.tesislatinoamericanas.info/index.php/record/view/241799>.

Britannica, The Editors of Encyclopædia. britannica. www.britannica.com. [En línea] [Citado el: 03 de 07 de 2017.] <https://www.britannica.com/plant/potato>.

Caparrini, Fernando Sancho. 2017. Universidad de Sevilla. *Universidad de Sevilla*. [En línea] Dpto. de Ciencias de la Computación e Inteligencia Artificial, 23 de Abril de 2017. [Citado el: 18 de Enero de 2018.] <http://www.cs.us.es/~fsancho/?e=165>.

CIP. CIP. International Potato Center. [En línea] [Citado el: 14 de Agosto de 2017.] <https://cipotato.org/potato/how-potato-grows>.

Coca, Morante. 2015. *Estado Actual de la Producción de papa [Solanum Tuberosum] en la región Andina boliviana*. s.l. : Revista Latinoamericana de la Papa, 2015. Vol. 19.

García Blanco, Ruth Afra y Santander Pacoricona, Olivia. 2011. *Manual Técnicas de Manejo, Selección Y Clasificación de Papas Nativas*. Puno, Perú : Gobierno Regional Puno, 2011.

García, Eloi Maduell i. *Visión Artificial*. España : Fundación para la Universitat Oberta de Catalunya.

Goering, Richard. 2004. *Matlab edges closer to electronic design automation world*. s.l. : EE Times, 2004.

Gonzalez, Bernardo. 2018. BMSS Tech. [En línea] BMSS Tech Tecnología y Soluciones de Panamá, S.A, 1 de Enero de 2018. [Citado el: 7 de Junio de 2018.] <http://bmsstech.com/que-es-una-lut/>.

IBCE. 2017. Instituto Boliviano de Comercio Exterior. [En línea] 15 de Mayo de 2017. [Citado el: 4 de Septiembre de 2018.] <http://ibce.org.bo/publicaciones-ibcecifras.php>.

Ivanovic, Ingrid Calvo. 2018. Proyecta Color Chile. [En línea] Enero de 2018. [Citado el: 4 de Septiembre de 2018.] <http://proyectacolor.cl/aplicacion-del-color/modelos-de-color/modelo-hsb/>.

Krig, Scott. 2016. *Computer Vision Metrics*. USA : Springer, 2016.

Küppers, Harald. 1978. *Fundamentos de la teoría de los Colores*. Barcelona : Editorial Gustavo Gili, 1978.

Marin Diazaraque, Juan Miguel. *Estadística Bayesiana*. Madrid, España : Universidad Carlos li de Madrid.

Matich, Damián Jorge. 2001. *Redes neuronales: Conceptos Basicos y Aplicaciones*. Rosario, Argentina : Universidad tecnología Nacional, 2001.

Mundo, Sputnik. 2016. Sputnik Mundo. [En línea] 01 de 04 de 2016. [Citado el: 14 de 06 de 2017.] <https://mundo.sputniknews.com/americalatina/201604011058262441-bolivia-agricultura-campesina-marginada/>.

Ordoñez Alquina, Edison Paul y Quillupanqui Luj, Gloria Alexandra. 2011. *Diseño e implementacion de un sistema de clasificacion de rosas aplicando vision artificial con labview*. Quito, Ecuador : Escuela Politecnica Nacional, 2011.

Parada, Mirian. 2016. <http://boyaca.extra.com.co>. *El Diario de Todos EXTRA*. [En línea] 5 de Julio de 2016. [Citado el: 14 de Agosto de 2017.]

<http://boyaca.extra.com.co/noticias/local/etapas-del-proceso-productivo-de-la-papa-220487>.

Petrantonio, María Marcela. 1991. Tesis Latinoamericanas. [En línea] 10 de 1991. [Citado el: 14 de 06 de 2017.] <http://www.tesislatinoamericanas.info/index.php/record/view/72554>.

Tierra. 2016. Tierra ORG. [En línea] 21 de 09 de 2016. [Citado el: 14 de 06 de 2017.] <http://www.ftierra.org/index.php/sseguridad-alimentaria-con-soberania/726-la-agricultura-familiar-campesina-frente-a-la-agricultura-empresarial>.

Zeballos H., Hernan, y otros. 2009. Economía de la Papa en Bolivia. *Economía de la Papa en Bolivia 1998-2007*. Cochabamba, Bolivia : Fundacion PROINPA, 2009.