

# UNIVERSIDAD PERUANA UNIÓN

FACULTAD DE INGENIERÍA Y ARQUITECTURA

Escuela Profesional de Ingeniería de Alimentos



*Una Institución Adventista*

**Desarrollo de un dispositivo y un sistema aplicativo de análisis  
de imágenes de impurezas macroscópicas de quinua  
(*Chenopodium quinoa Willd*).**

Por:

Shinthia Luna Quispe

Asesor:

MSc. José Manuel Prieto

Coasesor:

Ing. Joel Jerson Coaquira Quispe

**Juliaca, julio de 2019**

## DECLARACION JURADA DE AUTORIA DEL INFORME DE TESIS

MSc. José Manuel Prieto, de la Facultad de Ingeniería y Arquitectura, Escuela Profesional de Ingeniería de Alimentos, de la Universidad Peruana Unión.

DECLARO:

Que el presente informe de investigación titulado: "DESARROLLO DE UN DISPOSITIVO Y UN SISTEMA APLICATIVO DE ANÁLISIS DE IMÁGENES DE IMPUREZAS MACROSCÓPICAS DE QUINUA (*CHENOPODIUM QUINOA WILLD*)" constituye la memoria que presenta la bachiller Shinthia Luna Quispe para aspirar al título Profesional de Ingeniero de Alimentos ha sido realizada en la Universidad Peruana Unión bajo mi dirección.

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

Y estando de acuerdo, firmo la presente declaración en Juliaca a los dos días del mes de julio del año dos mil diecinueve.



MSc. José Manuel Prieto

Desarrollo de un dispositivo y un sistema aplicativo de análisis de imágenes de impurezas macroscópicas de quinua (*Chenopodium quinoa Willd*)

# TESIS

Presentada para optar el título profesional de Ingeniero de Alimentos

## JURADO CALIFICADOR



MSc. Carmen Rosa Apaza Humerez

Presidenta



Ing. Enrique Mamani Cuela

Secretario



Ing. Edgar Mayta Pinto

Vocal



Ing. Alex Danny Chambi Rodriguez

Vocal



Msc. José Manuel Prieto

Asesor

Juliaca, 2 de julio de 2019

## DEDICATORIA

*Este trabajo es dedicado en primer lugar a Dios, por haberme guiado y haberme permitido llegar hasta este momento tan importante de mi vida profesional, a mis docentes que me han brindado su apoyo durante los 5 años de mi carrera universitaria y para terminar a mi familia por ser el pilar mas importante y por demostrarme su amor y apoyo incondicional.*

**“Shinthia Luna Quispe”**

## **AGRADECIMIENTO**

Primero agradecer a Dios, quien me ayuda y me cuida día a día, a cada integrante de mi familia, a la Universidad Peruana Unión, a la Facultad de Ingeniería y Arquitectura y a la carrera profesional de Ingeniería de Alimentos.

Quiero agradecer a mi asesor, el Ing. Msc. Jose Manuel Prieto y Coasesor Ing. Joel Yerson Coaquira Quispe por brindarme la oportunidad de recurrir a su capacidad y experiencia, por la confianza y el tiempo para realizar este trabajo, también expresar mi sincero agradecimiento a mis Docentes: Ing. Enrique Mamani Cuela, Ing. Edgar Mayta Pinto, Ing. Ana M. Torres Jiménez, Ing. Msc. Carmen R. Apaza Humerez e Ing. Cesar Augusto Condori Mamani y para finalizar estaré eternamente agradecida con PRONABEC (Programa Nacional de Becas y Créditos) por haberme dado esta oportunidad de realizar mis estudios superiores estoy infinitamente agradecida.

## Tabla de contenido

	Pag
RESUMEN.....	xvi
ABSTRACT .....	xvii
CAPÍTULO I.....	18
PLANTEAMIENTO DEL PROBLEMA .....	18
CAPÍTULO II.....	20
2.1. Quinoa.....	20
2.1.1. Clasificación botánica .....	20
2.1.2. Partes del grano de quinua.....	21
2.1.3. Características del grano de quinua.....	22
2.2. Morfología.....	22
2.2.1. Raíz.....	22
2.2.2. Tallo.....	22
2.3. Condiciones agro climáticas del cultivo.....	22
2.3.1. Región de cultivo .....	22
2.3.2. Temperatura .....	22
2.3.3. Humedad y precipitación .....	23
2.3.4. Fotoperiodo .....	23
2.3.5. Suelos .....	23
2.3.6. Crecimiento y desarrollo .....	23
2.4. Propiedades físicas de la quinua .....	25
2.4.1. Forma .....	25
2.4.2. Tamaño .....	25
2.4.4. Densidad de los solidos.....	25
2.5. Caracterización de la calidad de quinua no procesada.....	26
2.5.1. Color del grano de quinua no procesada.....	26
2.5.2. Clasificación por el tamaño del grano.....	26

2.5.3.Aspectos físicos del grano.....	26
2.5.3.1. Granos enteros (no defectuosos).....	26
2.5.3.2. Granos defectuosos.....	27
2.5.3.3. Granos quebrados.....	27
2.5.3.4. Granos dañados.....	27
2.5.3.4.1. Granos infestados.....	27
2.5.3.4.2. Granos manchados.....	27
2.5.3.4.3. Granos germinados.....	27
2.5.3.4.4. Granos recubiertos ( perigonio).....	27
2.5.3.4.5. Granos inmaduros.....	27
2.5.3.4.6. Granos contrastantes.....	27
2.5.3.4.7. Impurezas.....	27
2.6. Cosecha.....	28
2.6.1.Tipos de cosecha.....	28
2.6.2.Siega.....	29
2.6.3.Secado.....	29
2.6.4.Trilla.....	29
2.6.5. Almacenamiento.....	29
2.7. Manejo de post cosecha.....	29
2.7.1. Humedad del grano.....	29
2.7.2.Tipos de secado:.....	29
2.7.3. Limpieza de los granos.....	29
2.7.4. Almacenamiento.....	30
2.8. Procesamiento industrial del grano de quinua.....	30
2.8.1. Limpieza.....	30
2.8.2. Secado.....	30
2.8.3. Selección.....	30
2.8.4. Acondicionamiento.....	30

2.8.4.1. Lavado por agitación y turbulencia .....	30
2.8.4.2. Método de fricción o rozamiento (Escarificado o pulido ).....	31
2.8.4.3. Método termomecánico en seco .....	31
2.8.4.4. Método químico.....	31
2.8.4.5. Método combinado.....	31
2.8.5. Secado .....	31
2.8.5.1. Secado natural.....	31
2.8.5.2. Secado artificial.....	31
2.8.6. Embalaje .....	32
2.8.7. Almacenamiento .....	32
2.9. Identificación de impurezas. ....	32
2.9.1. Análisis físico de impurezas.....	32
2.9.2. Dispositivos de reconocimiento de imágenes .....	33
2.9.2.1. Raspberry PI .....	33
2.10. Procesamiento digital de imágenes. ....	33
2.10.1. Software.....	33
2.10.1.1. Lenguaje Python .....	33
2.10.1.2. Librería Opencv .....	33
2.11. Inteligencia artificial .....	33
2.12. Deep learning .....	34
2.12.1. Redes neuronales convolucionales (CNN).....	35
2.12.1.1. Convolución .....	36
2.12.1.2. Pooling.....	37
2.12.2. Optimizador .....	38
2.12.2.1. Pendiente de gradiente estocástico (SGD) .....	38
2.12.2.2. Proceso de entrenamiento o aprendizaje .....	38
2.13. Evaluación de modelos de clasificación.....	38
2.14. Accuracy.....	39

2.15. Sensibilidad .....	39
2.16. Especificidad .....	39
2.17. Ratio de falsos positivos .....	39
2.18. Ratio de falsos negativos .....	39
2.18.1. Precisión .....	39
CAPÍTULO III.....	40
MATERIALES Y MÉTODOS.....	40
3.1. Lugar de ejecución .....	40
3.1.1. Materia prima.....	40
3.2. Materiales, equipos y reactivos.....	40
3.2.1. Materiales .....	40
3.2.2. Equipos .....	40
3.2.3. Reactivos.....	41
3.3. Metodología experimental.....	41
3.3.1. Descripción del diagrama de trabajo de investigación .....	42
3.3.2. Clasificación de granos de quinua no procesada.....	42
3.3.3. Adquisición de imágenes de las impurezas y granos defectuosos de la quinua.....	43
3.3.4. Determinación de propiedades físicas .....	44
3.3.4.3. Determinación de humedad de impurezas y granos defectuosos de quinua .....	45
3.3.5. Metodología para el reconocimiento de imágenes.....	45
3.3.5.1. Reconocimiento de patrones.....	45
3.3.6. Dispositivo .....	49
3.3.6.1. Implementación física .....	49
3.3.6.2. Implementación lógica .....	49
3.3.7. Adquisición de imágenes en el dispositivo .....	49
RESULTADOS Y DISCUSIONES.....	50
4.1. Determinación según el tipo de impureza y granos defectuosos de quinua no procesada.....	50

4.2. Análisis físico de quinua no procesada.....	51
4.3. Adquisición de imágenes de impurezas y granos defectuosos de quinua no procesada.....	52
4.4. Reconocimiento y adquisición de imágenes mediante el dispositivo.....	59
CAPÍTULO V.....	66
CONCLUSIONES Y RECOMENDACIONES.....	66
5.1. Conclusiones.....	66
5.2. Recomendaciones.....	66
REFERENCIAS.....	67
ANEXOS.....	72

## Índice de tablas

	Pag
Tabla 1. Composicion proximal de quinua .....	21
Tabla 2. Humedad, densidad (real y aparente), porosidad y calor específico de diferentes semillas.....	26
Tabla 3. Clasificación de impurezas y granos defectuosos de la quinua.....	43
Tabla 4. Clasificacion de impurezas y granos defectuosos de quinua.....	50
Tabla 5. Análisis físicos de impurezas Composicion proximal de quinua .....	51
Tabla 6. Reporte de la clasificación (verdaderos positivos/falsos positivos).....	62

## Índice de figuras

	Pag
Figura 1. Imagen de la sección longitudinal medial de las semillas de quinua .....	21
Figura 2. Fases de la maduración fisiológica de la quinoa.. .....	24
Figura 3. Tipos de cosecha.....	28
Figura 4. Arquitectura de red neuronal convolucional típica. ....	34
Figura 5. Esquema de una red convolucional .....	35
Figura 6. Imagen representada con matriz.....	35
Figura 7. Matriz de números .....	36
Figura 8. Convolución .....	36
Figura 9. Comparacion al aplicar diferentes filtros a una imagen. ....	37
Figura 10. Aplicación de pooling a varias mapas de característica. ....	38
Figura 11. Diagrama del trabajo de investigación. ....	41
Figura 12. Adquisicion de imágenes mediante el microscopio digital. ....	44
Figura 13. Modelo para el reconocimiento de imágenes. ....	47
Figura 14. Solucion de Arquitectura Deep Learning. ....	48
Figura 15. Modelo del dispositivo.....	49
Figura 16. Grano entero (No defectuoso).....	52
Figura 17. Grano vestida. ....	52
Figura 18. Grano dañado. ....	53
Figura 19. Grano inmaduro. ....	53
Figura 20. Grano aclarado inmaduro 2. ....	54
Figura 21. Grano germinado. ....	54
Figura 22. Grano quebrado.....	55
Figura 23. Granos contrastantes –Negra, Roja y Amarilla.....	56
Figura 24. Impureza inorgánica – (A) Piedra, (B) Terron.....	56
Figura 25. Impureza orgánica- Larva seca(Eurysacca quínoae). ....	57

Figura 26. Impurezas orgánicas: (A) Perigonio. (B) Muni muni ( <i>Bidens pilosa</i> ), (C) Tallo de quinua y (D) Cebadilla falsa ( <i>Hordeum murinum</i> ). .....	57
Figura 27. Heces de rata. ....	58
Figura 28. Reconocimiento y segmentación de quinua vestida con perigonio.....	59
Figura 29. Reconocimiento y segmentación de muestras de quinua no procesada. ....	59
Figura 30. Segmentación y reconocimiento de muestras de quinua no procesada. ....	60
Figura 31. Curva de ROC de los Label's de impurezas y granos defectuosos de quinua	61
Figura 32. Matriz de confusión numéricamente.....	63
Figura 33. Dispositivo para la adquisición de imágenes.....	64

## Índice de anexos

	<b>Pag</b>
Anexo A. Lote de muestras de quinua no procesada .....	72
Anexo B. Pesado de muestra de quinua no procesada .....	72
Anexo C. Tamizado de muestra de quinua no procesada.....	72
Anexo D. Muestra de 100 g para selección y clasificación de impurezas de la quinua....	73
Anexo E. Selección y clasificación de quinua con impurezas.....	73
Anexo F. Selección y clasificación de impurezas.....	73
Anexo G. Impurezas de quinua clasificada en envases de polietileno de alta densidad...	74
Anexo H. Adquisición de imágenes.....	74
Anexo I. Determinación de densidad. ....	74
Anexo J. Dispositivo para adquisición de imágenes.....	75
Anexo K. Segmentación de las impureza muni muni ( <i>Bidens pilosa</i> ) y tallo del grano de quinua no procesada. ....	75
Anexo L. Reconocimiento y segmentación de muestras clasificadas (Quinua contrastada amarilla, quinua inmadura 2 y pajilla).....	76
Anexo M. Reconocimiento y segmentación de quinua de inmadura 2, quinua amarilla y negra.....	76
Anexo N. Reconocimiento y segmentacion de quinua contrastada, quebrada y larva seca.....	77
Anexo Ñ. Reconocimiento y segmentacion de quinua quebrada, contrastada negra y larva seca.....	77
Anexo O. Implementación del dispositivo.....	78
Anexo P. Dispositivo para la adquisición de imágenes (frontal ). ....	78
Anexo Q. Dispositivo para la adquisición de imagen (lateral).....	81
Anexo R. Dispositivo para la adquisición de imágenes (frontal).....	81

## Índice de ecuaciones

Ecuación 1. Accuracy.....	39
Ecuación 2. Sensibilidad.....	39
Ecuación 3. Especificidad.....	39
Ecuación 4. Ratio de falsos positivos.....	39
Ecuación 5. Ratio de falsos negativos.....	39
Ecuación 6. Precisión .....	39
Ecuación 7. Densidad real.....	44
Ecuación 8. Densidad aparente.....	45
Ecuación 9. Humedad.....	45

## RESUMEN

El objetivo de este trabajo de investigación fue desarrollar un dispositivo y un sistema aplicativo de análisis de imágenes de impurezas macroscópicas de quinua. La quinua no procesada fue seleccionada y clasificada, se determinaron humedad y densidad, adquiriendo imágenes de 480 píxeles, se desarrolló patrones para el reconocimiento de imágenes mediante el entrenamiento de redes neuronales convolucionadas. Se construyó un dispositivo mediante el tarjeta arduino 1 con rieles de transporte. Se obtuvieron 4856 imágenes de quinua no procesada; la humedad, densidad aparente y densidad real de las muestras variaron entre de 1.96% a 12.86%,  $0.00017 \text{ Kg/cm}^3$  a  $0.00159 \text{ Kg/cm}^3$  de la densidad real  $0.0005 \text{ Kg/cm}^3$  a  $0.00206 \text{ Kg/cm}^3$ . Las redes neuronales convolucionadas (CNN) aprendieron las imágenes adquiridas y se obtuvo los patrones, por tanto la clasificación tuvo una alta precisión de 91% de quinua amarilla y baja precisión 20% en tallos de quinua, en recall el mejor fue la muestra de muni muni (*Bidens pilosa*) 99%, la curva ROC demuestra 55 % de confiabilidad de reconocimiento de imágenes, se logró obtener un dispositivo para 5 g de muestra de quinua no procesada, al cual será aplicado para la mejora de control de impurezas y granos defectuosos de la quinua no procesada.

**Palabras clave:** Quinua, clasificación, reconocimiento de imágenes.

## ABSTRACT

The objective of this research work was to develop a device and an application system for analyzing images of macroscopic quinoa impurities. The unprocessed quinoa was selected and classified, humidity and density were determined, acquiring images of 480 pixels, it developed patterns for the recognition of images through the training of convolved neural networks. A device was built using the arduino 1 card with transport rails. We obtained 4856 images of unprocessed quinoa; the humidity, apparent density and real density of the samples varied between 1.96% to 12.86%, 0.00017 Kg / cm<sup>3</sup> to 0.00159 Kg / cm<sup>3</sup> of the real density 0.0005 Kg / cm<sup>3</sup> to 0.00206 Kg / cm<sup>3</sup>. The convoluted neural networks (CNN) learned the acquired images and the patterns were obtained, so the classification had a high accuracy of 91% of yellow quinoa and low accuracy 20% in quinoa stems, in recall the best was the sample of muni muni (*Bidens pilosa*) 99%, the ROC curve demonstrates 55% of image recognition reliability, it was possible to obtain a device for 5 g of unprocessed quinoa sample, to which it will be applied to improve the control of impurities and defective grains of quinoa not processed.

Keywords: Quinoa, classification, recognition of images.

## **CAPÍTULO I**

### **PLANTEAMIENTO DEL PROBLEMA**

La quinua (*Chenopodium quinoa* Willd.) es un grano alimenticio de origen andino de América del Sur, gracias a los microclimas y diferencias altitudinales que diversifican terreno agroecológicos se produce diferentes variedades y su tiempo de crecimiento es de aproximadamente de cinco meses dependiendo de la zona de cultivo (Zapana, 2017).

La cosecha de forma tradicional consta de cuatro etapas: siega (corte), emparve (formación de arcos), trilla (humedad 12 a 15%, separación de granos o limpieza de las panojas) y venteo (limpieza). Según los lugares de siembra también se realiza el tamizado (uso de mallas adaptadas por agricultores) y nuevamente realizan el venteo (Meyhuay, 1997)(Coila, Quispe, & Mujica, 1993).

Las buenas prácticas de cosecha de los granos de quinua permite eliminar la mayoría de impurezas físicas, sin embargo la operación de venteo (utilización de aire forzado para eliminar partículas de bajo peso específico) no garantiza la eliminación de todas las impurezas de bajo peso específico, lo que conlleva a bajos rendimientos de producción.

A nivel industrial el procesador desconoce la cantidad de impurezas en los granos de quinua (Quiroga & Escalera, 2010), por consiguiente la compra es determinada por volumen mas las impurezas que contengan los lotes.

Esto conduce a realizar varios procesos industriales para remover impurezas como: piedrecillas, ramas, pajas, heces de aves y ratones entre otras, generando costos adicionales al procesador industrial (Meyhuay, 1997).

Los controles de calidad de quinua no procesada y acopiada en campo se realiza en las plantas de procesamiento primario de forma manual demandando tiempo, estos controles se realizan de acuerdo a la NTP 205.062, en la mayoría de los casos requieren tiempos entre 4 a 5 horas de análisis por muestras de 100g.

Para la determinación de impurezas se han realizado estudios mediante la adquisición de imágenes en arroz (Tated & Morade, 2012), trigo (Elbatawi & Arafa, 2008), café (Montes, Chuctaya, Portugal-Zambrano, Gutiérrez-Cáceres, & Beltrán-Castañón, 2014), y aun no se ha investigado en granos de quinua antes de ser procesada.

La Norma Técnica Peruana NTP 205.062 está clasificado en términos del límite de calidad aceptable, tiene como objetivo inducir a los proveedores a través de una influencia

económica y de acuerdo a los compradores el límite aceptable en los granos de quinua, por tanto el beneficiario para el procesamiento industrial necesita saber la cantidad de impurezas que tiene los lotes para realizar el pago real, por ende el objetivo es desarrollar un dispositivo para análisis de impurezas macroscópicas de quinua no procesada mediante análisis de imágenes.

### **Objetivos específicos**

- Seleccionar y clasificar las impurezas y granos defectuosos de quinua según la NTP 205.062.
- Determinar las propiedades físicas de las impurezas y granos defectuosos de quinua clasificadas según la NTP 205.062.
- Adquirir imágenes de las impurezas y granos defectuosos de quinua ya seleccionadas.
- Desarrollar los patrones de reconocimiento de imágenes de las impurezas y granos de quinua defectuosos
- Construir el dispositivo de adquisición de imágenes.

## CAPÍTULO II

### REVISIÓN DE LA LITERATURA

#### 2.1. Quinua

La quinua (*Chenopodium quinoa* Willd) es un grano andino originario de la región andina de Sudamérica cerca del Lago Titicaca entre Perú y Bolivia donde se encuentra la mayor diversidad genética (Jacobsen & Mujica, 2002). Antes de la época prehispánica las semillas de quinua fueron una fuente alimenticia para la población andina, también fue usado con fines medicinales (Lutz & Bascuñán-Godoy, 2017). Sus propiedades nutricionales como el contenido de proteína tiene un promedio de 14.6% siendo de mayor valor en relación a otros cereales como: avena, arroz, cebada (Valencia, 2017).

##### 2.1.1. Clasificación botánica

El cultivo de la quinua fue descrito por un científico alemán Luis Willdnaw (Yupanqui, 2012).

Reyno: Vegetal

División: Fanerogamas

Clase: Dicotilodoneas

Subclase: Angiospermas

Orden: Centrospermales

Familia: Chenopodiaceae

Género: *Chenopodium*

Sección: Chenopodia

Subsección: Cellulata

Especie: *Chenopodium quinoa* Willd.

La composición proximal de la quinua de diferentes referencias y según el lugar de procedencia, se muestra en la Tabla 1. Al igual que los demás cereales la quinua tiene carbohidratos, grasas, minerales, fibra, vitaminas y buen contenido de proteína (Yupanqui, 2012).

Tabla 1

*Composición proximal de quinua (g/100 g materia seca)*

Análisis	Quinua		
	1	2	3
Humedad (%)	11.8		
Proteína (%)	14.4	14.2	13.1-16.7
Grasa (%)	6	6.7	5.5-7.4
		64.16	59.9-74.7
Carbohidratos (por diferencia) (%)	72.6		
Fibra (%)	4	7	7-11.7
Cenizas (%)	2.9	2.7	2.7-3.8

Fuente. <sup>1</sup>(Repo-Carrasco, Espinoza, & Jacobsen, 1993), <sup>2</sup>(Navruz-Varli & Sanlier, 2016), <sup>3</sup>(Vilcacundo & Hernández-Ledesma, 2017).

### 2.1.2. Partes del grano de quinua

Los granos de la quinua se presentan de diferentes formas: cónicos, cilindros y elipsoidales, menores a 2.6 mm de diámetro, alrededor de 350 semillas pesan 1 g y sus colores varían desde: blanco, amarillo pálido a rosa o negro. En la Figura 1, se identifica el endospermo (cotiledones y radícula), el perispermo (granos de almidón) y el pericarpio (capa externa que envuelve la semilla) que forman parte de este grano andino (Aranibar, 2011; Valcárcel-Yamani & Lannes, 2012).

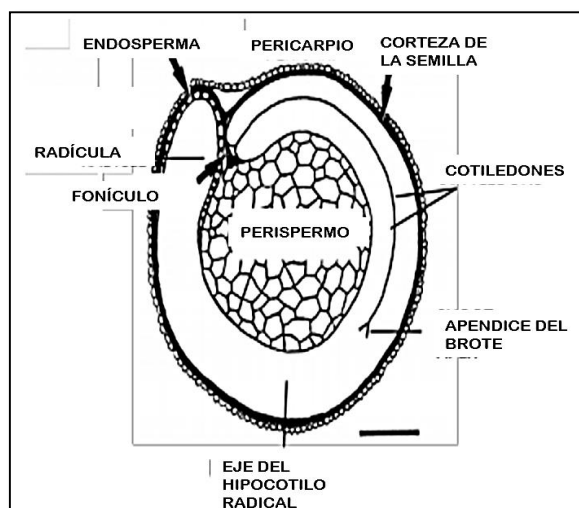


Figura 1. Imagen de la sección longitudinal medial de las semillas de quinua

Fuente: (Aranibar, 2011).

### **2.1.3. Características del grano de quinua**

La quinua tiene un embrión que es mas grande que los demás cereales, razón por lo cual tiene un alto contenido en aminoácidos. El endospermo de la quinua tiene (64.5%) ligeramente inferior al del trigo (70.1%)(Valcárcel & Lannes, 2012)

#### **2.1.3.1. Saponina**

La saponina es un glucosido triterpenoide o esteroide que exhibe ciertas características propias que sirven para identificación y caracterización entre ellas la formación de espuma en soluciones acuosas, produce hemólisis de glóbulos rojos, alta toxicidad para peces y anfibios y formación de compuestos moleculares con colesterol y otros hidroesteroides; no todas las saponinas poseen necesariamente todas estas características, sino depende de las especies (Aranibar, 2011).

## **2.2. Morfología**

### **2.2.1. Raíz**

Es de tipo pivotante, que tiene una raíz principal, su longitud de las raíces es 0.8 a 1.5 m. Es determinante el tipo de suelo, humedad, nutrición y otros factores para su crecimiento y desarrollo (Meyhuay, 1997)

### **2.2.2. Tallo**

La unión del cuello de la raíz con el tallo es de forma cilíndrica, y mientras más se aleja del suelo es anguloso. La corteza tiene firmeza y es compacta ya que tiene tejidos lignificados y fuertes. El tallo es suave cuando es joven, en su fase de maduración se vuelve esponjosa, seca y en la cosecha se cae quedando un vacío en el tallo.

En su época de floración es de color verde, púrpura, rosado y naranja. Y en cuanto a su maduración es de color crema o rosado(Meyhuay, 1997).

## **2.3. Condiciones agro climáticas del cultivo**

### **2.3.1. Región de cultivo**

El grano de quinua fue domesticada hace miles de años, que abarcan desde la costa (0-500 m.s.n.m.) hasta la sierra alta, Suni o Altiplano (3500 a 4000 m.s.n.m.), de esta forma surgió variedades de quinua llamadas ecotipos. (Meyhuay, 1997).

### **2.3.2. Temperatura**

Se adapta a diferentes climas, caluroso y seco como de la costa, climas lluviosas o secas así como en los valles interandinos, lluviosos y fríos y secos de la sierra, donde su

óptimo crecimiento es de 15 a 25°C. No es impedimento las heladas y altas temperaturas durante su fase vegetativa y formación de inflorescencia.(Meyhuay, 1997).

### **2.3.3. Humedad y precipitación**

En la región andina la precipitación es desde septiembre-octubre a mayo – junio. La precipitación anual varía de acuerdo al lugar, se cultiva dentro de un rango de precipitación de 300 mm a 1000 mm, siendo el óptimo de 500 mm a 800mm. La falta de humedad afecta la producción: germinación emergencia, tiene que ver el establecimiento de cultivo, y su fase de crecimiento y llenado de fruto que ve por la productividad (Meyhuay, 1997).

### **2.3.4. Fotoperiodo**

El fotoperiodo está relacionado al lugar de origen, dado que es compleja y puede afectar el rendimiento. Son sensibles al fotoperiodo las variedades de Perú y Bolivia y los de menor sensibilidad son las quinuas que son los del nivel de mar (Meyhuay, 1997).

### **2.3.5. Suelos**

La quinua crece en diferentes tipos de suelos, donde los mejores son los del buen drenaje franco, semi profundo con un alto carga de materia orgánica. Para que no dificulten el establecimiento inicial del cultivo evitar suelos con problemas de anegamiento o inundación.


El pH del suelo es distinto donde varía desde 4.5pH (en los valles interandinos del Norte de Perú) hasta 9.0 de pH (altiplano peruano boliviano y los salares de boliviano). (Meyhuay, 1997).

### **2.3.6. Crecimiento y desarrollo**

Fases fenológicas del cultivo de la quinua se reconocen fácilmente, consta de 12 etapas (Haros & Schoenlechner, 2017).

- 1) Aparición: 7 -10 días después de la siembra, los cotiledones se ven sobre la superficie del suelo.
- 2) Dos hojas verdaderas: 15-20 días después de la siembra; la epicotíleo crece hacia arriba y da lugar a una verdadera romboide deja con philotaxis alternos.
- 3) Cuatro hojas verdaderas: 25-30 días después de la siembra, hojas de cotiledones, dos hojas verdaderas y el segundo par de hojas está creciendo.
- 4) Seis hojas verdaderas: 35-45 días después de la siembra. Tres pares de hojas visibles; alterno philotaxis. Las hojas de cotiledones se vuelven amarillas.
- 5) La ramificación con ocho hojas verdaderas: 45-50 días después de la siembra; Inflorescencia se desarrolla, protegida por las hojas que cubren la panoja.

- 6) Iniciación de la panícula: 55-60 días después de la siembra, inflorescencia emerge el rodaje, donde rodea numerosas hojas pequeñas, que cubren tres cuartas partes de su superficie, hojas basales se vuelven amarillas y el tallo se va convirtiendo en grueso y largo.
- 7) Formación de panículas: 65-70 días después de la siembra, inflorescencia emerge por encima de las hojas y el glómulo, en la base de las cuales se encuentran los botones florales.
- 8) Comienzo de la floración: 75 a 80 días después de la siembra, la flor hermafrodita apical se abrirá, donde se ve los estambre de pie separado.
- 9) Antesis: 90-100 días después de la siembra, 50% de las flores estará abierta en la mañana hasta el mediodía, y en la noche se cierran.
- 10) Vía etapa grano: 100-130 días después de la siembra, se forma la fruta, y cuando se presiona aparece un fluido blanco lechoso.
- 11) Etapa de grano masa: 130 -160 días después de la siembra, el fruto da una textura parecida a una masa cuando se presiona
- 12) La madurez fisiológica: 160 – 180 días después de la siembra, el fruto exhibe resistencia cuando se presiona. Las hojas se vuelven de color amarillo y seguidamente se da la defoliación.



*Figura 2.* Fases de la maduración fisiológica de la quinoa. A) Flor hermafrodita en antesis; B) flor hermafrodita preantesis; C) flor femenina; D) Estambres previo a la dehiscencia, cara externa e interna, respectivamente; E) fruto cubierto por el perigonio, caras dorsal y ventral, respectivamente.

Fuente:Cogliatti & Heter, (2017)

## **2.4. Propiedades físicas de la quinua**

Las propiedades físicas son importantes para determinar y clasificar: forma, tamaño, densidad, diámetro, porosidad, etc. En la tabla 2 se presenta propiedades físicas de algunos granos.

### **2.4.1. Forma**

Según Haros & Schoenlechner (2017), indican que la forma redonda y esférica es uno de los criterios para determinar la perfil de un objeto. La forma redonda es la medida aguda de una esquina de un sólido. La esfericidad tiene una relación del área superficial de una esfera.

### **2.4.2. Tamaño**

Se refiere al espacio que abarca dentro de los límites. Donde se puede expresar por longitud, ancho y espesor. Dado que muchas semillas tienen diferentes formas geométricas y pocas de ellas son uniformes geoméricamente (Zapana, 2017).

### **2.4.3. Color**

La mayoría de las variedades de quinua son de color castaño, también existen de color blanco a amarillo y demás colores como: rojo, negro, rosado etc., el análisis de los colores se realiza mediante las densidades de color rojo (R), verde (G) y azul (B), (Medina, 2010) (Jacobsen & Mujica, 2002) (Castro, Oblitas, Chuquizuta, & Avila-George, 2017).

### **2.4.4. Densidad de los sólidos**

Los alimentos granulados (granos, harina, polvo y guisantes) café, almidón y leche se estudia de cada una que incluye el volumen vacío entre las unidades individuales. Los sólidos secos o polvos sin poros internos presentan densidades de 1400 kg/m<sup>3</sup> y 1500 Kg/m<sup>3</sup> (Lewis, 1993; Hayqui 2016; Yupanqui 2012).

Tabla 2.

*Humedad, densidad (real y aparente), porosidad y calor específico de diferentes semillas*

Producto	Humedad (%)	Densidad (kg/m <sup>3</sup> )		Diámetro(mm)	Porosidad	Calor específico KJ kg-1 °C-1
		Absoluta	Aparente			
Cebada	7.5-8.2	1374-1415	565-650	3.9	0.3545	
Avena	8.5-8.8	1350-1378	358-511			
Arroz	8.6-9.2	1358-1386	561-591			
Trigo	6.2-8-5	1409-1430	790-819	3.92	0.4175	
Café		1120	630	15.4	0.4384	
Quinua		1380	940	2.02	0.321	
Quinua Blanca de Juli		1236.74	680.781	2.46 -2.55	0.45	0.785
Quinua Kamiri		1237.569	694.754	2.46 -2.55	0.44	0.766
Frijol		1150	560	7.17	0.5143	
Cañihua Ramis				1.24		
Cupi				1.035		
Cebada UNA -80				10.75		
Grignon				9.73		
Común				11.48		
Habas Gigante 1ra. Clase				25.76		
Gigante 2da. Clase				23.1		

Fuente: (Yupanqui, 2012) (Medina, Skurtys, & Aguilera, 2010).

## **2.5. Caracterización de la calidad de quinua no procesada.**

Esta norma solo aplica a la quinua procesada (perlada), sin embargo en Perú no existe una norma para quinua trillada en campo.

Por tanto esta NTP 205.062 emplea los conceptos de la clasificación de color, tamaño, forma de impurezas y en función a su aspecto físico.

### **2.5.1. Color del grano de quinua no procesada.**

Es el color del pericarpio y del episperma, presentes en los granos de quinua antes de ser procesado, se divide en granos blancos y granos de color.

### **2.5.2. Clasificación por el tamaño del grano.**

El tamaño del grano se determina por su diámetro, expresado en milímetros, se clasifican de esta manera: granos grandes, granos medianos y granos pequeños.

### **2.5.3. Aspectos físicos del grano.**

#### **2.5.3.1. Granos enteros (no defectuosos)**

Estos granos no presentan ningún tipo de alteración en su forma física.

### **2.5.3.2. Granos defectuosos**

Son granos de quinua que presentan alteración en su forma física.

### **2.5.3.3. Granos quebrados**

Son pedazos de granos, los tamaños son menores a las tres cuartas partes del grano, ocasionado por acción mecánica.

### **2.5.3.4. Granos dañados**

Son granos enteros o quebrados que en su forma o estructura difieren de los demás, que fueron alterados por agentes físicos, químicos o biológicos, son:

#### **2.5.3.4.1. Granos infestados**

Granos que fueron dañados por microorganismos patógenos ( bacterias y hongos), por roedores o insectos y puede contener insectos vivos y/o muertos, como también sus larvas y/o excrementos.

#### **2.5.3.4.2. Granos manchados**

Son granos enteros o quebrados que presentan una coloración diferente a la normal de la variedad o ecotipo, a causa de los fenómenos químicos, biológicos o ambientales.

#### **2.5.3.4.3. Granos germinados**

Presentan un desarrollo inicial de la radícula (embrión), por presencia de humedad.

#### **2.5.3.4.4. Granos recubiertos ( perigonio)**

Conservan la envoltura (perigonio) o parte de la flor adherida al grano, antes o después del beneficiado.

#### **2.5.3.4.5. Granos inmaduros**

Granos que no alcanzaron su madurez fisiológica, caracterizado por su pequeño tamaño, coloración verduzca y de menor peso.

#### **2.5.3.4.6. Granos contrastantes**

Son granos de la quinua que predominan por su aspecto y color dentro del proceso de selección.

#### **2.5.3.4.7. Impurezas**

Son materias extrañas, se dividen en dos grupos como impurezas orgánicas que son restos de cascarillas, partes de tallos, hojas, granos de otras especies y otras materias orgánicas e impurezas inorgánicas que corresponden a la presencia de piedrecilla, arenilla, tierra y otras materias orgánicas.

## 2.6. Cosecha

La planta de la quinua durante su crecimiento consta de panojas que se ramifican de las ocho hojas verdaderas desde los 45 días después de la siembra, su iniciación se da a partir de los 55 días, posteriormente aparece la inflorescencia por encima de las hojas y el glomérulo, y en la base se encuentran los botones florales, a los 75 días después de su siembra la flor hermafrodita se abrirá, a los 90 días se abren el 50% de las flores hasta el mediodía, y en la noche se cierran (Haros & Schoenlechner, 2017).

La cosecha debe ser bien planificada. Debido a que puede degenerarse por factores climáticos y seres vivos.

El punto óptimo para cosechar es determinado por la humedad que debe de ser menor a 45% (Jacobsen & Mujica, 2002).

Al demorar la cosecha es como si estuviera almacenado en el medio ambiente, y se pierden por granizadas, desgrane por exceso de secado en la planta, ataques de aves y lluvias inesperadas (FAO, 2013).

### 2.6.1. Tipos de cosecha

La cosecha se debe programar en forma oportuna, existen tres tipos de cosecha como se muestra en la Figura 3, los tipos son: cosecha manual, cosecha manual mecánica y cosecha mecánica.

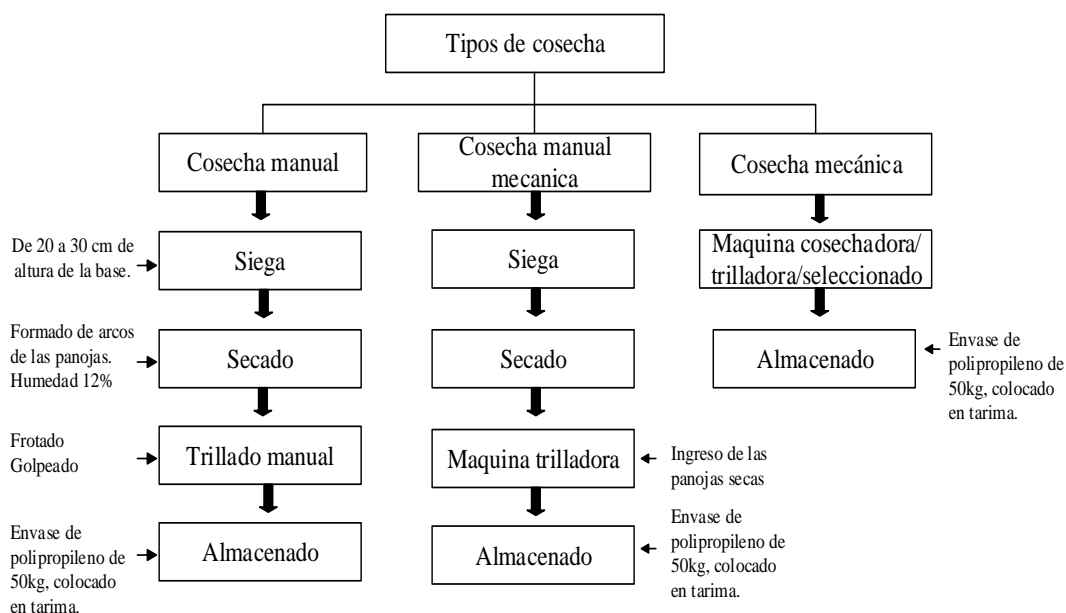


Figura 3. Tipos de cosecha.

Fuente: (Abugoch et al., 2009).

### **2.6.2. Siega**

Cortar con una hoz las plantas de quinua a unos 20 a 30 cm del suelo y en horas de la madrugada cuando las plantas están húmedas. No se deben de arrancar las plantas de raíz porque arrastra piedrecilla y arenillas, para la siega debe estar alrededor de 30% - 45% de humedad (Johana & Ballén, 2018).

### **2.6.3. Secado**

Deben ser apiladas con las panojas hacia arriba, formando arcos o parvas, donde las panojas deben de tener una humedad de 12% para un adecuado trillado, el secado se debe realizar sobre mantas de lona (Johana & Ballén, 2018).

### **2.6.4. Trilla**

En el proceso de trillado existen dos tipos: manual y mecánico, manualmente las plantas de las parvas tienen que colocarse sobre mantas y se tienen que frotar o golpear, con garrotes o palos, también el trillado se realiza mediante máquinas de trillado. Para poder separar los granos de los demás materias, y para solo retener los granos de quinua se pueden aplicar equipos manuales o mecánicos con tamices especiales y el viento (Johana & Ballén, 2018).

### **2.6.5. Almacenamiento**

Las semillas de quinua se deben de colocar en envases apropiados y colocarlos muy limpios y ventilado sobre una tarima (Johana & Ballén, 2018).

## **2.7. Manejo de post cosecha**

Esto se realiza desde el momento en que la semilla de quinua llega a su completa madurez fisiológica.

### **2.7.1. Humedad del grano**

Debe tener una humedad en un rango de 10 a 12%, el secado de grano ayuda a prevenir la germinación de las semillas y el crecimiento de bacterias y hongos y retarda el desarrollo de ácaros e insectos (FAO, 2013)

### **2.7.2. Tipos de secado:**

- Secado natural empleando los rayos solares y el viento.
- Secado artificial con secadores apropiados donde se adaptan a la humedad de la semilla de quinua.

### **2.7.3. Limpieza de los granos**

El grano seco se debe de proceder a la selección con clasificadores de granos con mallas y cribas, para retirar las impurezas, algunos equipos clasifican por tamaño o grado de quinua, facilitando su comercio (Johana & Ballén, 2018).

#### **2.7.4. Almacenamiento**

Las semillas de quinua serán guardadas a una humedad de 12%. Estos deben ser colocados en sacos sobre una tarima para evitar el contacto con el piso del almacén. Los grupos de sacos deben tener una distancia de 80 cm de la pared y del techo 150 cm (Meyhuay, 1997) .

### **2.8. Procesamiento industrial del grano de quinua**

#### **2.8.1. Limpieza**

Este proceso se encarga de eliminar las impurezas que vienen acompañando al grano. Se trabajan con con herramientas como: zarandas oscilantes, zarandas rotativas, separadores por gravedad (densimétrica) y separadores neumáticos (mediante aire) (Moreno & Sanchez, 2013).

#### **2.8.2. Secado**

La humedad no debe superar el 12%, para el secado se utilizan como: secadores solares, gas, biogás y leña (Moreno & Sanchez, 2013).

#### **2.8.3. Selección**

Se realiza por tamaño del grano, los pequeños (< de 1.4 mm) esto se asigna para productos de molienda y para productos que se transforman a partir de harina, los medianos ( entre 1.4 a 1.69 mm) su uso es para sémola, expandidos, hojuelas, quinua pop y entre otros y el grano de quinua grande (entre 1.7 a 2.0mm) y extra grande (mayor a 2.00 mm ) para los perlados y embolsados como grano natural. Se utilizan como equipos como: zaranda oscilantes, zarandas rotativas, mesas gravimétricas y seleccionadoras ópticas (Moreno & Sanchez, 2013).

#### **2.8.4. Acondicionamiento**

##### **2.8.4.1. Lavado por agitación y turbulencia**

Se remoja la quinua por 30 min, con la finalidad de facilitar la desaponificación, con el agua los cristales de saponina se disuelven, para su posterior eliminación.

El lavado se ejecuta con un equipo con camisa de calentamiento a vapor y un agitador turbina de lamina plana; luego son sometidos al proceso de fricción húmeda, al cual la fricción es intensa entre los granos y con la pared, después se seca y empaca (Meyhuay, 1997).

#### **2.8.4.2.Método de fricción o rozamiento (Escarificado o pulido )**

Consiste en la separación del epispermal (descascarado) y otros compuestos que se encuentran en la corteza, donde ahí se concentra el contenido de saponina, que le da un sabor amargo y astringente, impropio para poder ser utilizado en la alimentación, el pulido produce quinua de superior calidad, dándole un aspecto mas liso y limpio, siendo así la quinua perlada. Esto se realiza a través de medios mecánicos abrasivos como:

- Acción combinada de paletas o tambores giratorios y tamiz estacionario
- Maquina flanqueadora y piladora de arroz de conos concéntricos (Meyhuay, 1997).

#### **2.8.4.3.Método termomecánico en seco**

Es sometido a calor seco ( 80 a 90°C) los granos de quinua durante 10 minutos, luego se extrae la cascara mediante fricción en seco, después se tamiza y empaca (Meyhuay, 1997).

#### **2.8.4.4.Método químico**

Son sometidas a una solución de hidróxido de sodio al 10% a 100°C durante 1.5 minutos, luego pasa al lavado y secado (Meyhuay, 1997).

#### **2.8.4.5.Método combinado**

Se somete los granos de quinua a medios mecánicos abrasivos (pulidoras y peladoras en seco), después se lava los granos de quinua para extraer la saponina residual, luego se realiza el secado de los granos húmedos de quinua, se tamiza y empaca (Meyhuay, 1997).

#### **2.8.5. Secado**

El secado debe alcanzar la humedad comercial (12 – 14%), si supera este rango puede originar fermentaciones que malogren la calidad del producto (Meyhuay, 1997).

##### **2.8.5.1.Secado natural**

Este tipo de secado se realiza extendiendo los granos en capas finas expuestas a la acción del aire (sol o sombra), durante 15 minutos. La humedad relativa no debe ser mayor a 70%, y los granos son removidos frecuentemente para su exposición uniforme.

El secado natural se recomienda en condiciones atmosféricas propicias y para cantidad pequeña de producción (Meyhuay, 1997).

##### **2.8.5.2.Secado artificial**

Es necesario cuando se trabaja en condiciones atmosféricas desfavorables ( humedad relativa alta o la lluvia), también cuando existe una gran cantidad de grano en un tiempo relativamente corto.

Consiste en exponer a los granos a una corriente de aire, antes tiene que ser calentado.

Tipos de secado artificial:

- Secadores estáticos o discontinuos, son baratos, solo procesa cantidades pequeñas.
- Secadores continuos, de gran capacidad de secado, son costosos, requieren un infraestructura más compleja, abarca a grandes cantidades de producción (Meyhuay, 1997).

#### **2.8.6. Embalaje**

El manejo adecuado de empaque y embalaje ayudan a prevenir las perdidas de factores físicos, químicos, biológicos y humanos (Meyhuay, 1997).

#### **2.8.7. Almacenamiento**

Se deben conservar en condiciones apropiadas para asegurar su calidad organolépticas y sanitaria.

La degradación de los granos se ve afectada por factores ambientales:

- Humedad
- Temperatura
- Contenido de oxígeno

### **2.9. Identificación de impurezas.**

Las impurezas están conformada por partículas orgánicas como tipos de granos, paja, cascara y de otras partículas inorgánicas como piedras y piezas de metal. Al cual es muy importante la identificación de todas las materias extrañas para sus siguientes operaciones como: manipulación, almacenamiento y procesamiento. (Vithu & Moses, 2016).

La identificación a través de un sistema de visión computacional se está haciendo muy popular en todas las áreas de la investigación empezando, en cuanto a la tecnología para los alimentos se da más para hacer un seguimiento de control de calidad de los productos (Da Wen, 2017).

#### **2.9.1. Análisis físico de impurezas**

Los análisis físicos es uno de los principios que demanda la mayoría de los procesos consecutivos en la industria alimentaria. Son aprovechados como una guía para diseñar equipos y métodos para operaciones en la producción de semillas como siembra, cosecha, procesamiento y control.

Se separan según a su forma, tamaño, densidad, textura superficial, porosidad, color elasticidad, ángulo de reposo, diámetro equivalente, (CECAGRO, 2016).

## **2.9.2. Dispositivos de reconocimiento de imágenes**

Son pequeños ordenadores portátiles, existen áreas de sistema de visión computacional donde los sistemas de cámaras permiten visualizar al cual los sistemas de cámara como por ejemplo equipos de tomografía computarizada (TC), la resonancia magnética (RMN), la tomografía computarizada por emisión de fotón único (SPECT) (Da Wen, 2017).

### **2.9.2.1.Raspberry PI**

Dispositivo de precio bajo que se desarrollo en Reino Unido de la fundación de Raspberry Pi Camera de la Universidad de Cambridge, su comercialización comenzó a partir del año 2012, este dispositivo se realizo con el objetivo de estimular la enseñanza informática y reconocimiento de fresas según su grado de maduración. Tiene varios componentes electrónicos, cuenta con una cámara de resolución máxima de 5 MP X [12](Delgado et al., 2017).

## **2.10.Procesamiento digital de imágenes.**

### **2.10.1. Software**

#### **2.10.1.1.Lenguaje Python**

Es un lenguaje de programación de alto nivel, que permite trabajar con rapidez e integrar sistemas mas efectivas, esto fue desarrollado en el Instituto Nacional de Investigación de Matemáticas y Ciencias de la Computación por Guido van Rossum (Delgado et al., 2017).

#### **2.10.1.2.Librería Opencv**

Es una librería gratis, contempla el procesamiento de imágenes, complejos como el reconocimiento de gestos, la posición de objetos y estimación del movimiento. Por tanto, OpenCV brinda bibliotecas de datos estadísticos y dinámicos( arboles, grafos, matrices etc), dado que su desarrollo es fácil e intuitivo, de esta manera se aplica en dos sistemas operativos Microsoft R Windows y Linux (Arévalo et al., 2004).

## **2.11.Inteligencia artificial**

La Inteligencia Artificial (IA) abarca subcampos, que van desde el aprendizaje y la percepción y especificas como: diagnóstico de enfermedades, escritura de poesía, demostración de los teoremas matemáticos y el ajedrez, donde la IA sintetiza y automatiza tareas intelectuales y es, por lo tanto, relevante para cualquier tipo de actividad intelectualmente humana.(Russel & Norvig, 2014).

La tecnología IA recientemente desarrollada, resalta en ciertos patrones, existen muchas limitaciones, dado que la mayoría de la cantidad de los datos son grandes (Lu et al., 2018).

## 2.12. Deep learning

El Deep Learning (Aprendizaje profundo) se basa en el tema de aprendizaje de varios niveles de representación y abstracción, con el objetivo de ayudar a dar sentido a los datos como texto, sonido e imágenes (Deng & Yu, 2014), adiciona materiales para realizar análisis avanzadas para procesar y analizar grandes datos de fabricación (Wang, Ma, Zhang, & Gao, 2018).

Deep learning (DL) es una parte de investigación de Machine Learning, que se introdujo con la finalidad de acercarse a Machine Learning a como: la inteligencia artificial.

Esto se centra en la creación de nuevas características y representaciones de datos a partir de datos en bruto, entonces estos datos son importantes para el aprendizaje profundo. Los algoritmos de aprendizaje profundo es una entrada con mucho compromiso para la investigación en la adquisición automatizada de representaciones de datos complejos a altos niveles de abstracción.

Las soluciones de DL de excelentes resultados en las siguientes aplicaciones: procesamiento de lenguaje, visión de computadora y reconocimiento de voz (Najafabadi et al., 2015). Dado que el aprendizaje profundo se da con convoluciones. Como presenta en la Figura 4.

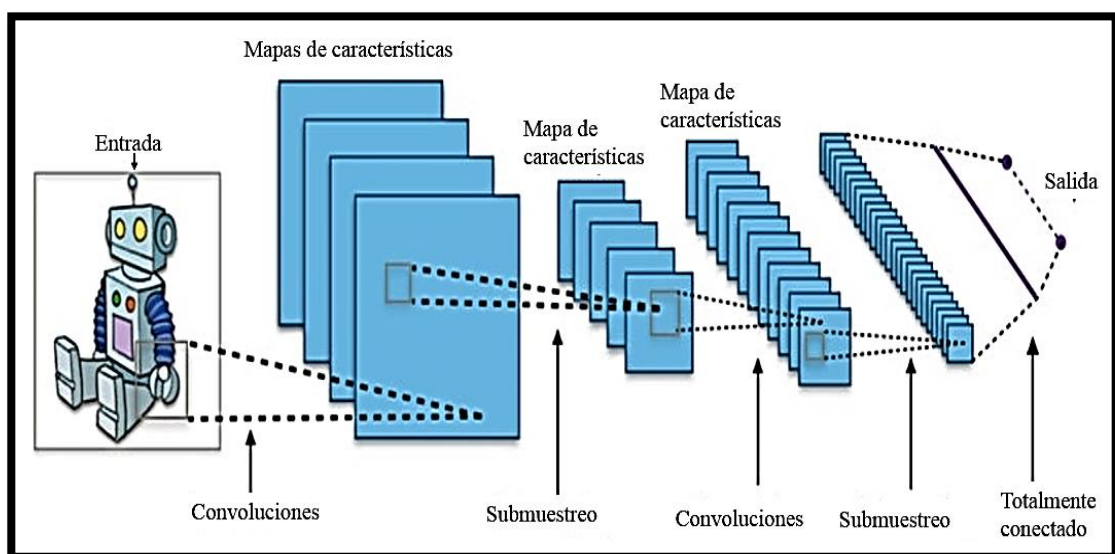


Figura 4. Arquitectura de red neuronal convolucional típica.

Fuente: (Macuga, 2017).



En la Figura 6 la imagen se puede representar mediante una matriz con valores por cada pixel.

### 2.12.1.1. Convolución

El propósito de una convolución en la redes convolucionales es extraer sus características de la imagen de ingreso. En la figura 7 se muestra una matriz de números de una imagen.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

Figura 7. Matriz de números.

Es un paradigma de procesamiento de información que modela en función a lo que hace el cerebro, las redes neuronales artificiales están formadas por un número de elementos, de procesamiento o neuronas.

La convolucion se realiza de esta manera como se muestra en la Figura 8.

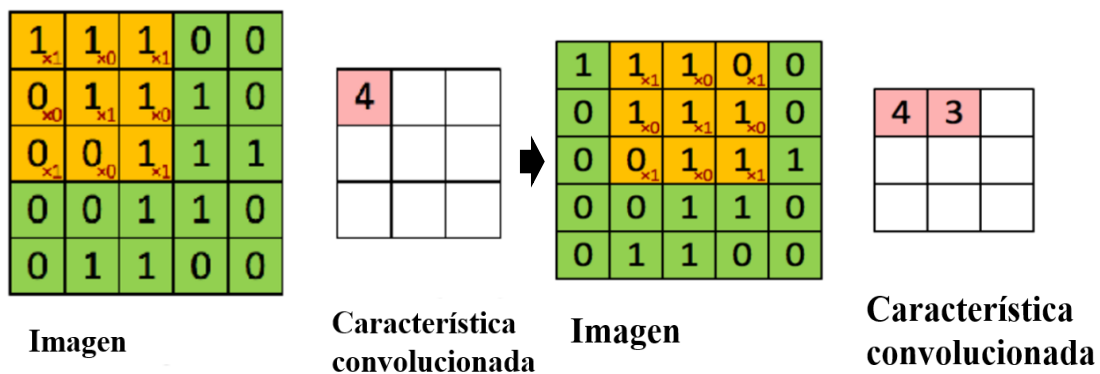



Figura 8. Convolución.

Esto consiste en desplazar el área naranja al área verde (siendo la imagen original (verde), con un salto de un pixel, y para cada posición se calcula la multiplicación entre la dos matrices y luego se suman las salidas de la multiplicación, para obtener un patrón, también como se aprecia en la Figura 8 para obtener un entero rosa. La matriz de 3 x 3 solo se fija en una parte de la imagen de entrada en cada paso.

La matriz de 3 x 3 se llama filtro o karnel y la matriz formada al realizar la convolucion (rosa) se llama característica convolucionada. Los filtros actúan como detectores de características de la imagen entrada.

Se producen diferentes valores en características convolucionadas, aplicadas con varios filtros para una sola imagen de ingreso como se presenta en la Figura 9.

Imagen de entrada → 








Operación	Filtro	Imagen convolucionada
Identificar	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	
Detección de bordes	$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$	
	$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	
	$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	
Nitidez	$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$	
	$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	
Desenfoque Gaussiano	$\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$	

Figura 9. Comparacion al aplicar diferentes filtros a una imagen.

En la Figura 9, se muestra los efectos de la convolución de la imagen de entrada, se puede observar operaciones como: detección de bordes, nitidez y desenfoque modificando los valores de la matriz aplicando de los filtros para la operación de convolucion, en cada filtro detectan diferentes características de una imagen (Casas, 2017).

### 2.12.1.2. Pooling

También se le llama subsampling reduce las dimensiones de cada mapa de características pero retiene la información mas importante.

Existen diferentes tipos de pooling: suma, media, máximo etc. El pooling se aplica separado para cada mapa de características, donde se obtiene tres mapas de salida de tres mapas de entrada.

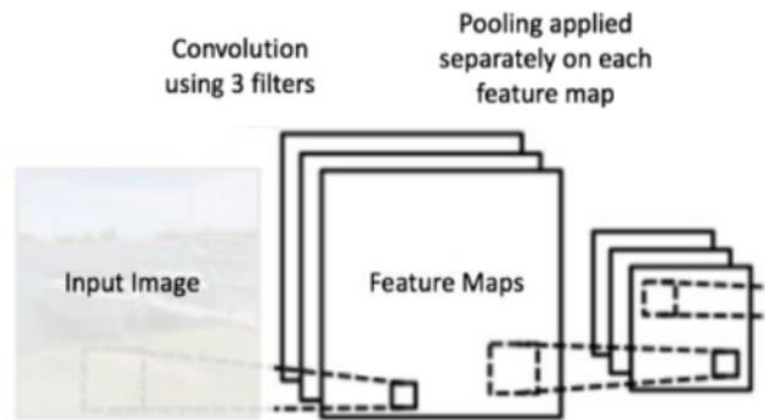


Figura 10. Aplicación de pooling a varias mapas de característica.

Pooling reduce progresivamente el tamaño de espacio de la imagen de entrada, por tanto pooling convierte la imagen de entrada mas pequeñas y manejables, reduce el numero de parámetros y cálculos en la red (Casas, 2017).

## 2.12.2. Optimizador

### 2.12.2.1. Pendiente de gradiente estocástico (SGD)

Se utiliza el conjunto de entrenamiento completo para actualizar los parámetros coincidir de manera eficiente, hacia un minimo absoluto.

### 2.12.2.2. Proceso de entrenamiento o aprendizaje

El proceso de adquisición de imagen se distinguen en dos etapas: la primera es captura, se trata en utilizar dispositivo óptico para obtener para obtener información del entorno o información relativa a una escena, y el segundo se conoce como digitalización, y consiste en transformar varios elementos continuos en una imagen digital (Holger et al., 2017), la segmentación es la siguiente fase, trata en separar las áreas de interés de un entorno o escena deseado.

## 2.13. Evaluación de modelos de clasificación

Para buscar una mejor evaluación de modelo de predicción se utilizó la técnica de la matriz de confusión, la cual ha permitido evaluar modelos de clasificación supervisados a través de las siguientes terminologías:

True positives (TP) : Es la predicción positiva correcta de los labels de la quiniua.

True negative (TN): Es la predicción negativa correcta de los labels de la quiniua.

False positives (FP): Es la predicción positiva incorrecta de los labels de la quinoa.

False negatives (FN): Es la predicción negativa incorrecta de los labels de la quinoa.

#### 2.14. Accuracy

Es la métrica más común que se utiliza para identificar problemas de clasificación esta medida es porcentaje de las predicciones correctas de dicho modelo (Casas, 2017).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad \text{Ecuación 1}$$

#### 2.15. Sensibilidad

Es el ratio de los positivos correctos predichos sobre el total del número de positivos predichos (Casas, 2017).

$$Recall = \frac{TP}{TP+FN} \quad \text{Ecuación 2}$$

#### 2.16. Especificidad

Es el ratio de los negativos correctos predichos sobre el total del número de negativos predichos (Casas, 2017).

$$Specificity = \frac{TN}{TN+FP} \quad \text{Ecuación 3}$$

#### 2.17. Ratio de falsos positivos

Es el ratio de predicción negativas que fueron confundidas como predicciones positivas del total del número de predicciones negativas (Casas, 2017).

$$FP = \frac{FP}{TN+FP} \quad \text{Ecuación 4}$$

#### 2.18. Ratio de falsos negativos

Es el ratio de predicción positiva que fueron confundidas como predicciones negativas del total del número de predicciones positivas (Casas, 2017).

$$FN = \frac{FN}{TP+FN} \quad \text{Ecuación 5}$$

##### 2.18.1. Precisión

Es la medida que cuantifica la precisión del clasificador, es decir, cuantas instancias fueron predichas (Casas, 2017).

$$Precision = \frac{TP}{TP+FP} \quad \text{Ecuación 6}$$

## **CAPÍTULO III**

### **MATERIALES Y MÉTODOS**

#### **3.1. Lugar de ejecución**

Este trabajo se desarrolló en las instalaciones de Centro de Investigación en Ciencia de Alimentos (CICAL) de la EP de Ingeniería de Alimentos de la Universidad Peruana Unión filial Juliaca, situado en salida Arequipa km 06 –Chullunquiani, ubicado a 3825 m.s.n.m.

##### **3.1.1. Materia prima**

- Granos de quinua no procesada, fueron adquiridas según su alto grado de contaminación de: Lampa, Azangaro, Arapa, Cabana, Cabanillas, Acora, Taraco, Juli, llave y Ayaviri del departamento de Puno.

#### **3.2. Materiales, equipos y reactivos**

##### **3.2.1. Materiales**

- Probeta 10 ml (Pirex)
- Probeta de 5 ml. (Pirex)
- Placas petri de vidrio (mediano).
- Pinzas metálicas.
- Frascos con tapa de polietileno de alta densidad (15ml).
- Serie de tamices estándar N° 12, 14 y 16 (ALPHALABS, A.S.T.M -11, Perú).
- Microscopio digital de aumento de 500X
- Tornillo sin fin
- Motor de paso
- Microcontrolador tarjeta arduino 1
- Driver para motor de paso DRV 8825
- Fuente de energía
- Melamina
- Software Python
- Librería OpenCV
- Algoritmo VGGnet

##### **3.2.2. Equipos**

- Estufa (KERT LAB, ODHG-9030B, USA).
- Balanza analítica, (PIONEER, Modelo Incal, U.S.A).

- Microscopio digital, (GRUPO ELITE, 500X, China).
- Reflector, iluminación 25 watts.
- Lupa de aumento de 3x.
- Computadora (HP Corei 5, China).

### 3.2.3. Reactivos

- Tolueno 99% ( J.T., Baker, Mexico)
- Agua destilada.

### 3.3. Metodología experimental

La clasificación de la quinua no procesada de variedad blanca se desarrolló mediante el método tradicional, análisis físicos, adquisición de imágenes, reconocimiento de patrones y el dispositivo se realizaron de acuerdo al Flujograma, como se muestra en la Figura 11.

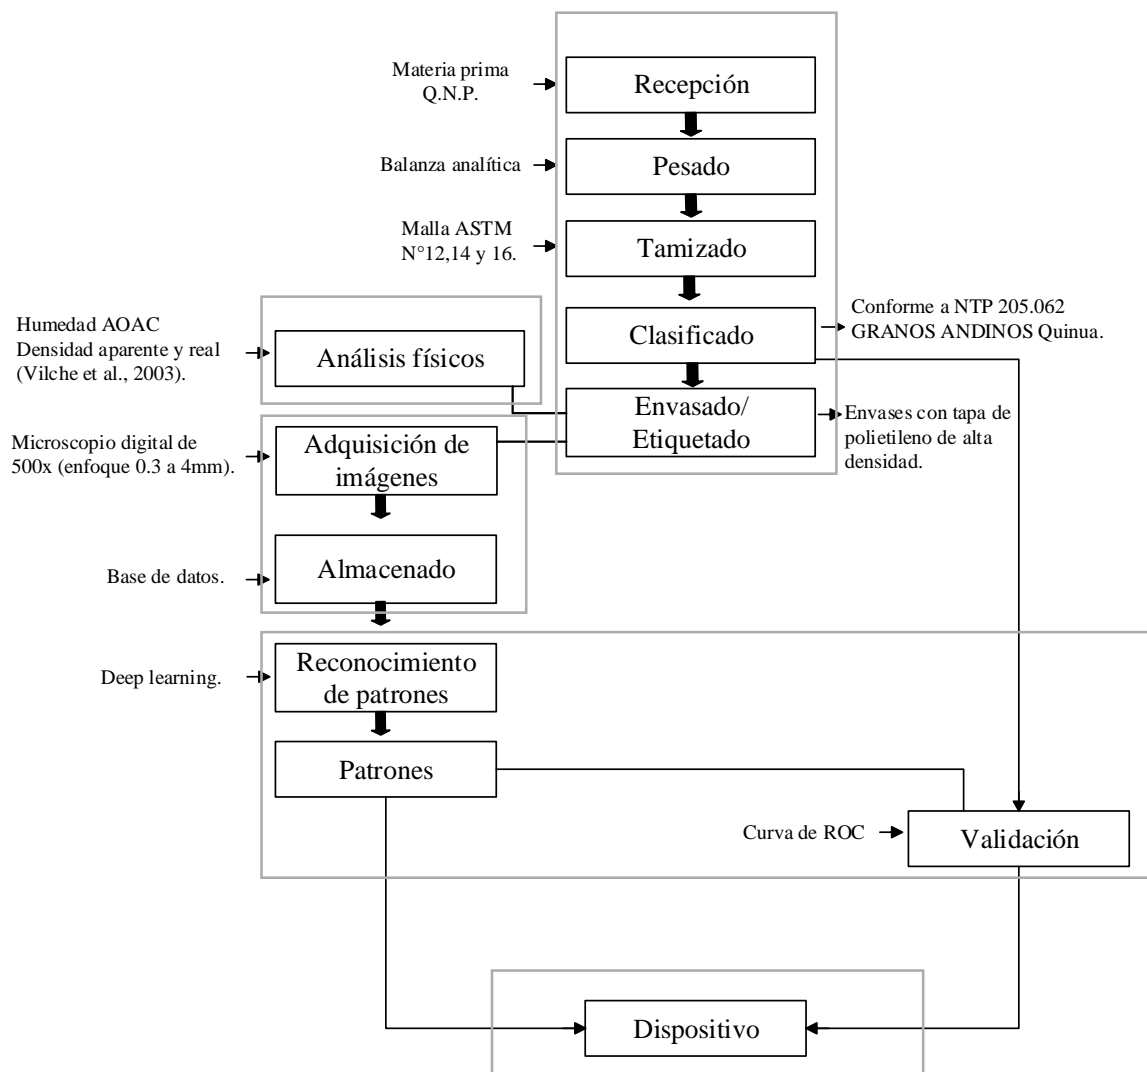


Figura 11. Diagrama del trabajo de investigación.

### **3.3.1. Descripción del diagrama de trabajo de investigación**

#### **a. Recepción**

Se recibió el grano de quinua trillada de 100g de la variedad blanca.

#### **b. Pesado**

Se utilizó una balanza analítica para el pesado de 100 g.

#### **c. Tamizado**

Se trabajó con tamices de A.S.T.M. para la clasificar por tamaño.

#### **d. Clasificado**

Esto se realizó manualmente con la guía de NTP 205 062.

#### **e. Envasado y etiquetado**

Se envasó en material de polietileno de alta densidad, con su etiquetado correspondiente.

#### **f. Adquisición de imágenes**

Se realizó mediante un microscopio digital con cable USB.

#### **g. Almacenado**

Se almacenó en base de datos.

#### **h. Reconocimiento de patrones**

Se utilizó las redes neuronales convolucionadas (CNN).

#### **i. Patrones**

Una vez aplicada las redes neuronales convolucionadas (CNN) se pasó a obtener los patrones, se obtiene un patrón de una matriz.

#### **j. Validación**

Se realizó con la curva ROC, con una matriz de confusión para ver, el grado de confusión.

#### **k. Dispositivo**

Se diseñó un dispositivo de acuerdo a la capacidad de reconocimiento mediante el microscopio digital.

### **3.3.2. Clasificación de granos de quinua no procesada.**

La clasificación se realizó por el método tradicional mediante la NTP 205.062 (2014).

Tabla 3.

*Clasificación de impurezas y granos defectuosos de la quinua.*

Parámetros	Unidad
Granos enteros	%
Granos quebrados	%
Granos dañados	%
Granos germinados	%
Granos recubiertos (vestidos)	%
Granos inmaduros (verdes)	%
Granos contrastantes	%
Impurezas totales(pajilla, cubiertas, muni muni)	%
Piedrecillas	%
Insectos (enteros, partes o larvas)	%

Fuente: (Norma Técnica Peruana, 2014).

### **Procedimiento**

- Se tomó 1 kg de muestra de quinua de un lote, y fueron transportados en bolsas de plástico y se almacenó en un lugar fresco y seco.
- Se realizó una homogenización previa de la muestra final, luego se separó una parte representativa de 100 g para la evaluación física.
- La separación de impurezas y granos defectuosos se realizó mediante el uso de tamices de A.S.T.M. luego se clasificó manualmente por unidad de acuerdo a sus características según la NTP205.062 con la ayuda de una lupa de aumento de 3X y reflector de 25 watts para visualizar con mas claridad las muestras, se caracterizó de acuerdo a la Tabla 5, desglosando las impurezas orgánicas e inorgánicas.
- Las impurezas y granos defectuosos clasificadas se colocaron en un recipiente con tapa de alta densidad y su respectivo etiquetado.
- Se pesó en una balanza analítica cada impureza y granos defectuosos de quinua y se expresó en porcentaje.

### **3.3.3. Adquisición de imágenes de las impurezas y granos defectuosos de la quinua.**

El proceso para la adquisición de imagen se realizó mediante un microscopio digital, se trabajó con una laptop para visualizar las imágenes, la laptop es de 700MHz y superior, 20 M HD Space CD ROM Driver, 128 MB RAM, Direct X VGA Tarjeta Interfaz de PC: USB2.0

## Procedimiento

- Una vez clasificadas se retiró de 300 a más unidades de cada muestra adquirida.
- Se instaló el software (Microscopy digital) para la adquisición de imágenes en la laptop.
- Se insertó cable USB del microscopio a la laptop.
- Se adquirió las imágenes sobre una superficie blanca y sin brillo, manipulando con una pinza metálica las muestras para colocar al enfoque del microscopio y se visualizó mediante la laptop, una vez enfocado se procedió a la captura con la laptop.



Figura 12. Adquisición de imágenes mediante el microscopio digital.

### 3.3.4. Determinación de propiedades físicas

#### 3.3.4.1. Densidad real

##### Procedimiento

- Se realizó mediante el método de desplazamiento de tolueno, se pesó un 1g (masa) de muestra de cada impureza y granos defectuosos de quinua, se utilizó una probeta de 10 ml (precisión de 0.1 ml), se llenó 3ml del solvente de tolueno, después se sumergieron 1 g de las muestras clasificadas, por un tiempo de 10 segundos, y se anotó la diferencia el desplazamiento del tolueno siendo el volumen real de la muestra, y se aplicó la Ecuación 4 para determinar la densidad real (Vilche, Gely, & Santalla, 2003).

$$\text{Densidad} = \frac{\text{Masa}}{\text{Volumen real de la muestra}}$$

Ecuación 7

#### 3.3.4.2. Densidad aparente

##### Procedimiento

- Se realizó mediante la metodología de Singh y Goswami (1996), se pesó 1 g de muestra de cada impureza y granos defectuosos de quinua, se usó una probeta de 10 ml y se dejaron caer a velocidad constante la muestra de 1g, y se anotó la altura

que abarco la muestra en la probeta, se determinó con la Ecuación 5 (Vilche et al., 2003).

$$\text{Densidad aparente} = \frac{\text{Masa}}{\text{Volumen global de la muestra}} \quad \text{Ecuación 8}$$

### 3.3.4.3. Determinación de humedad de impurezas y granos defectuosos de quinua

El contenido de humedad se determinó por el método descrito por AOAC. 925.10, (1990).

#### Procedimiento

- Se realizó por desecación en estufa a 65°C con una muestra de 5 g, hasta lograr peso constante durante 12 h, se realizó con la Ecuación (6).

$$\text{Humedad (\%)} = \frac{\text{peso inicial} - \text{peso final}}{\text{g de muestra}} \times 100 \quad \text{Ecuación 9}$$

### 3.3.5. Metodología para el reconocimiento de imágenes

#### 3.3.5.1. Reconocimiento de patrones

Se empleó con el lenguaje de algoritmo de Python para el reconocimiento, donde se determinó forma, tamaño y color, se almacenó las imágenes en base de datos. Como se puede ver en la Figura 14.

Se almacenó los datos a las redes neuronales para el aprendizaje y la aplicación de los algoritmos, utilizando la librería Open CV, con el lenguaje Python, según (García, 2013).

Los pasos para el reconocimiento de imágenes de las muestras fueron los siguientes:

- Paso 1: definición del alcance del problema a resolver, en este caso se observó el propósito del algoritmo en relación al reconocimiento de patrones, es decir, que se espera predecir, qué métricas de evaluación será usadas para medir o confirmar si el algoritmo está cumpliendo con el propósito del alcance, y si los Label serán usados para este reconocimiento.
- Paso 2: consiste en la preparación de los datos que serán procesados, en este caso la obtención de imágenes de las muestras (impurezas) son reconocidas con sus características esperadas. Las imágenes fueron agrupadas en datos de entrenamiento y datos de validación.
- Paso 3: aprendizaje supervisado clasificando los tipos de imágenes, luego se definió el algoritmo de detección de objetos (VGGnet) del cual se realizó el entrenamiento

calculando en cada etapa (EPOCH) la menor pérdida de las características de los datos y la mejor precisión de predicción, así mismo con ayuda de la librería OPEN CV se logró realizar la segmentación (cálculo de los objetos) a ser identificados. Para la validación del algoritmo se usó la Curva de Roc, donde nos indica los parámetros de precisión de sensibilidad y exactitud.

Los pasos para adquirir la neurona, ya aprendida se muestra con los pseudocódigos:

1. Imput Imagen Train [ ]
2. Imagen.format [64,64] = Kernel
3. Imagen Scale [64/64] = Kernel
4. Imagen. Fill mode [Nearest ] = Kernel
5. Imagen class model [categorical] = Kernel
6. Imagen. model [64,3 x 3] [Relu] = Imagen – patrón
7. Imagen. model [2 x 2 ][Max pooling] = Imagen – patrón
8. Imagen. model [128, 3 x 3 ] [Relu]=Imagen – patrón
9. Imagen. model [256, 3 x 3 ] [Relu ] = Imagen – patrón
10. Imagen.model [256, 3 x 3 ] [Flaten ] = Imagen – patrón
11. Imagen. loss [ 'categorical\_crosseutropy']
12. Imagen. optimizar [SGD] = Imagen patrón.
13. Imagen. output \_= quinua.h5.

Servidor

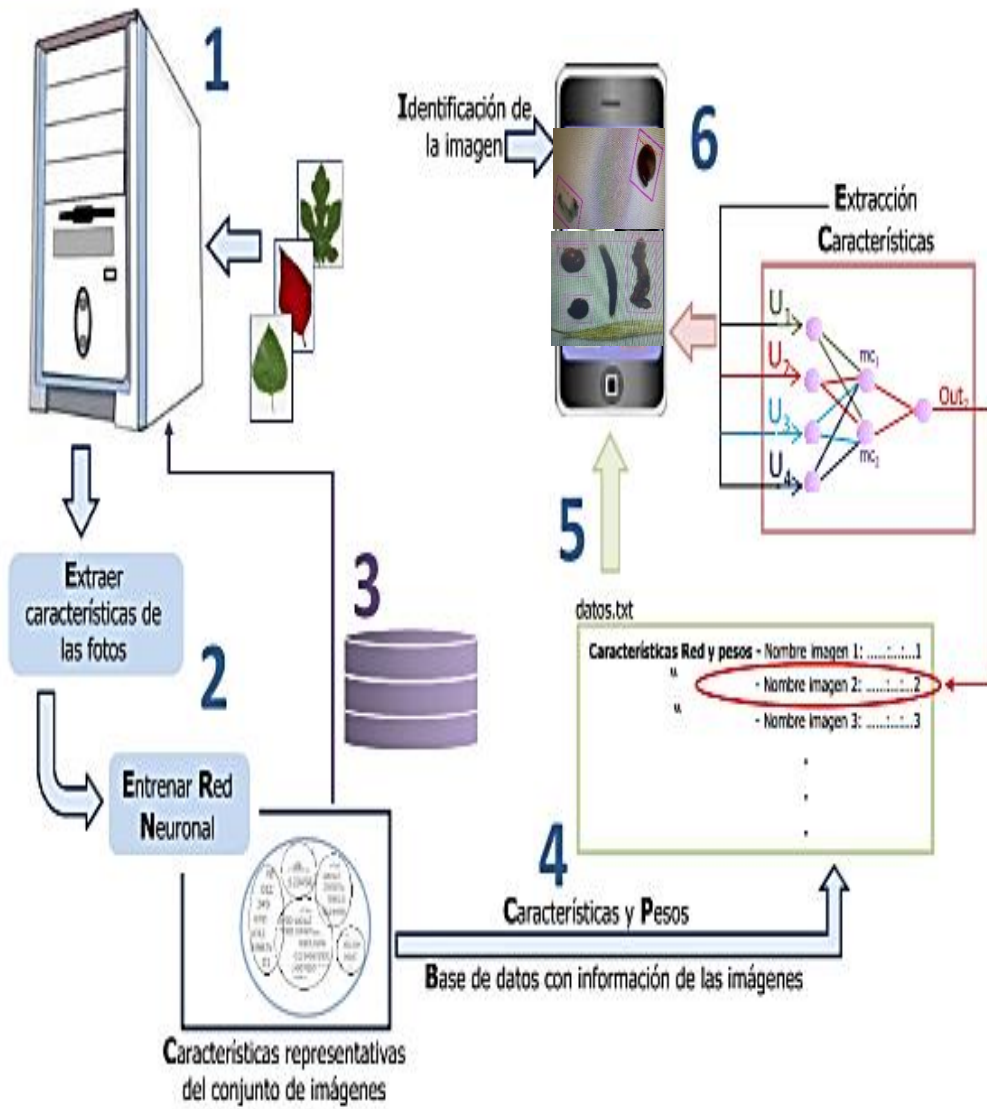


Figura 13. Modelo para el reconocimiento de imágenes.

Fuente: (Garcia, 2013).

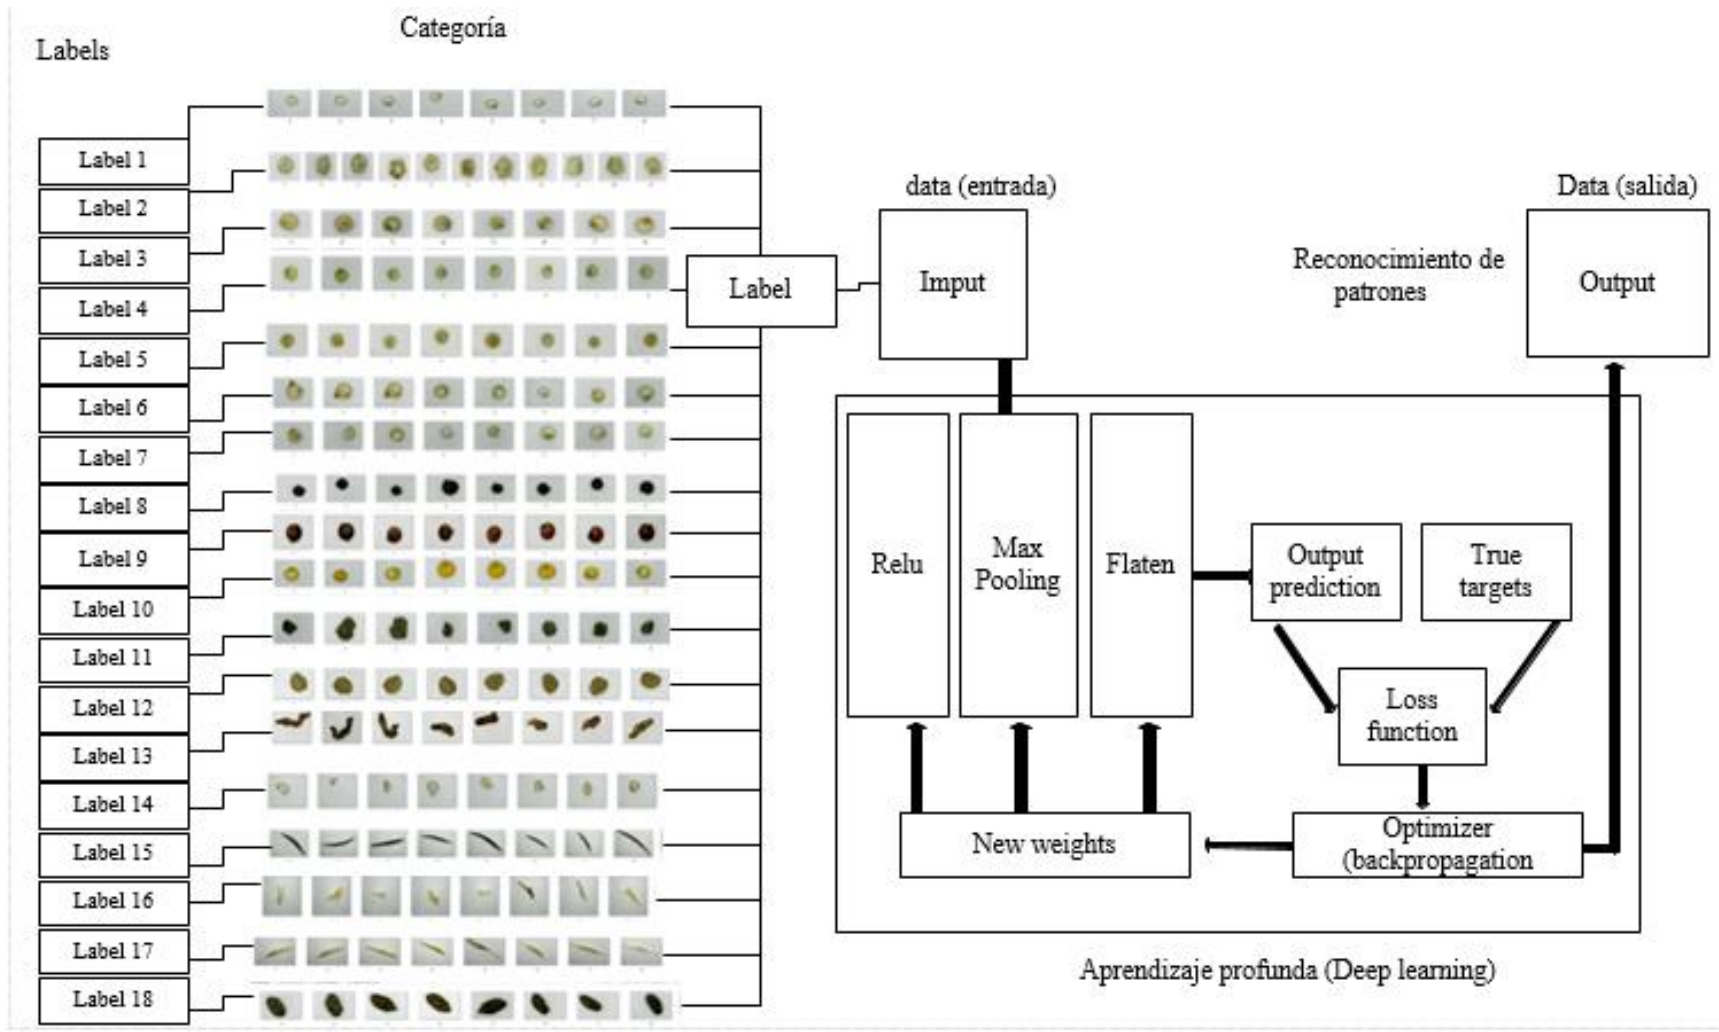


Figura 14. Solucion de Arquitectura Deep Learning.

### 3.3.6. Dispositivo

Se diseñó y elaboró de acuerdo a los parámetros proporcionados según las imágenes adquiridas, para su elaboración se utilizó materiales disponibles en el ámbito local. La elaboración consta de dos partes fundamentales:




Figura 15. Modelo del dispositivo.

- Implementación física (hardware).
- Implementación lógica (software).

#### 3.3.6.1. Implementación física

Se hizo con un largo mínimo de 810 mm para el porta muestras de quinua no procesada, considerando 30mm de distancia para posicionamiento de la cámara en cada extremo, tiene porta muestras de 870mm siendo este el largo del dispositivo, para el ancho se consideró 20mm x 2 hileras, obteniendo un ancho mínimo de 40 mm, estableciéndose en 80mm de ancho. Finalmente el porta muestras es de 870 mm x 80 mm (87cm x 8 cm).

#### 3.3.6.2. Implementación lógica

La programación del microcontrolador se realizó con el software Arduino IDE versión 1.6.5, con lenguaje de programación C++.

#### 3.3.7. Adquisición de imágenes en el dispositivo

Se tomó 5 g de 100g de muestra representativa de quinua no procesada, después se colocó al porta muestras para la adquisición de imágenes, mediante la Curva ROC de las impurezas y de granos defectuosos de quinua se palido el reconocimiento de patrones.

## CAPÍTULO IV

### RESULTADOS Y DISCUSIONES

#### 4.1. Determinación según el tipo de impureza y granos defectuosos de quinua no procesada.

Se determinó y se adaptó según la NTP 205.062 para la clasificación, se realizó mediante método tradicional, esta clasificación es de la obtención 10 Kg de quinua no procesada de diferentes zonas como (Lampa, Azángaro, Arapa, Cabana, Cabanillas, Acora, Taraco, Juli, llave y Ayaviri) adquiriendo 1kg por zona, para el análisis de clasificación se tomó una muestra representativa de 100g de la muestra de 1Kg zona, por tanto el promedio para el análisis es de 1Kg y los resultados se muestra en la Tabla 4.

Tabla 4.

*Clasificación de impurezas y granos defectuosos de quinua.*

N°	Muestras	Promedio (%)	
1	Quinua buena	67.181	± 4.861
2	Quinua cubierta	8.057	± 4.806
3	Quinua dañada	11.423	± 0.690
4	Quinua inmadura 1	0.003	± 0.005
5	Quinua inmadura 2	7.787	± 6.702
6	Quinua germinada	0.241	± 0.388
7	Quinua quebrada	2.182	± 0.165
8	Quinua negra	0.125	± 0.121
9	Quinua roja	0.098	± 0.113
10	Quinua amarilla	0.073	± 0.078
11	Piedra	0.050	± 0.081
12	Terron	0.053	± 0.029
13	Larva seca( <i>Eurysacca quínoae</i> )	0.029	± 0.015
14	Perigonio	0.803	± 0.600
15	Muni muni ( <i>Bidens pilosa</i> )	1.090	± 0.628
16	Tallo de quinua	0.108	± 0.093
17	Pajilla ( <i>Hordeum murinum</i> )	0.660	± 0.306
18	Hece de rata	0.036	± 0.057

En la Tabla 4 la quinua entera representa mayor porcentaje del promedio de la clasificación con 67.18% y 0.003 % de menor porcentaje es grano inmaduro 1.

#### 4.2. Análisis físico de quinua no procesada.

En la Tabla 5 presenta los resultados del análisis de la humedad, densidad aparente y densidad real de las impurezas.

Tabla 5.

*Análisis físico de impurezas y granos defectuosos de quinua.*

N°	Muestras	Humedad (%)	Densidad Aparente (Kg/m <sup>3</sup> )	Densidad Real (Kg/m <sup>3</sup> )
1	Quinua buena	10.84 ± 0.12	716.02 ± 0.00	1113.81 ± 0.00
2	Quinua cubierta	11.34 ± 0.08	419.50 ± 0.04	1002.03 ± 0.00
3	Quinua dañada	9.80 ± 1.52	657.36 ± 0.05	1115.44 ± 0.00
4	Quinua inmadura 1	10.97 ± 0.12	849.78 ± 0.01	1019.73 ± 0.01
5	Quinua inmadura 2	12.86 ± 0.22	836.72 ± 0.00	1115.63 ± 0.00
6	Quinua germinada	9.53 ± 0.43	715.71 ± 0.00	1113.33 ± 0.00
7	Quinua quebrada	10.10 ± 1.65	589.47 ± 0.04	1238.65 ± 0.06
8	Quinua negra	10.55 ± 0.44	835.78 ± 0.00	1114.37 ± 0.00
9	Quinua roja	10.84 ± 0.12	815.96 ± 0.04	1116.67 ± 0.00
10	Quinua amarilla	11.38 ± 0.03	835.83 ± 0.00	1003.00 ± 0.00
11	Piedra	1.96 ± 0.37	1592.40 ± 0.14	2062.18 ± 0.04
12	Terron	2.35 ± 0.37	835.08 ± 0.00	1002.10 ± 0.00
13	Larva seca ( <i>Eurysacca quínoae</i> )	10.70 ± 0.72	310.34 ± 0.01	1020.75 ± 0.01
14	Perigonío	10.40 ± 1.98	322.44 ± 0.02	1007.23 ± 0.01
15	Muni muni ( <i>Bidens pilosa</i> )	8.33 ± 0.20	210.90 ± 0.01	891.84 ± 0.17
16	Tallo de quinua	11.14 ± 0.44	171.09 ± 0.01	501.37 ± 0.00
17	Pajilla ( <i>Hordeum murinum</i> )	11.83 ± 0.07	278.46 ± 0.00	1002.47 ± 0.00
18	Hece de rata	7.15 ± 0.23	485.95 ± 0.03	1002.23 ± 0.00

Según la tabla 5 la quinua inmadura 2 presenta de 12.8%. de mayor humedad y la impureza de piedra con 1.96% de baja humedad, la densidad aparente esta en un rango de 1592.40 Kg/m<sup>3</sup> a 171.09 Kg/m<sup>3</sup> siendo la piedra y el tallo de quinua, y densidad real esta dentro 2062.18 Kg/m<sup>3</sup> a 501.37 Kg/m<sup>3</sup> representando la piedra y el tallo de quinua.

### 4.3. Adquisición de imágenes de impurezas y granos defectuosos de quinua no procesada.

La Figura 16 muestra el grano entero, de esta muestra se adquirió 253 imágenes mediante el microscopio digital.



*Figura 16.* Grano entero (No defectuoso).

El grano entero se caracteriza de forma circular, color blanco y abarca de 1.6 a 2.4 mm de diámetro, en el borde tiene la coloración de sésamo, el punto medio es la región de la unión, no presenta ningún tipo de alteración en su forma física (Norma Técnica Peruana, 2014).



*Figura 17.* Grano vestida.

En la Figura 17 se tiene el grano de quinua vestida con envoltura llamado perigonio, de esta impureza se adquirió 292 imágenes; al cual tiene una parte de la flor adherida al grano, con presencia de 5 líneas que inicia del centro, de forma pentágono irregular, el tamaño que abarca es mayor a 2.2 mm diámetro, color beige, cubre todo el grano de quinua, y presenta fragilidad en su estado seco.

La presencia de esta impureza se debe a un mal manejo de secado que no se elimina con el proceso de trillado, muchos de ellos no llegan a la humedad de 12 a 15% por consecuencia en el trillado los perigonios con alta humedad no se desprenden del grano (Meyhuay, 1997),(Nieto & Vimos, 1992), (Coila et al., 1993).



*Figura 18.* Grano dañado.

En la Figura 18 el grano dañado presenta forma circular, el tamaño que abarca es 2 mm de diámetro, de color beige entre amarillo y puntos negros, el grano tiene una coloración muy diferente a la variedad del ecotipo, se adquirió de esta impureza 292 imágenes, la caracterización de esta muestra es debido a los cambios biológicos, químicos y ambientales (Norma Técnica Peruana, 2014).

La presencia de microorganismos hace que cambie a color negro y tenga mancha oscuras, la humedad adecuada es de 10 a 12% para el secado de los granos, esto ayuda a prevenir la germinación de las semillas, el crecimiento de bacterias y hongos, también retarda el desarrollo de ácaros e insectos.



*Figura 19.* Grano inmaduro.

En la Figura 19 se presenta el grano inmaduro de forma circular imperfecto, el tamaño es menor a 1.6 mm , de color verde, se adquirió 275 imágenes. Este grano presenta una inmadurez fisiológica, se caracteriza por ser de tamaño pequeño y de bajo peso (Norma Técnica Peruana, 2014) .

A causa de la anticipación de la cosecha el grano no logra su completo desarrollo fisiológico, dando así esta coloración verdusca y de menor peso, afectando la productividad al realizar la compra para la obtención de quinua perlada (Meyhuay, 1997).



*Figura 20.* Grano aclarado inmaduro 2.

La Figura 20 presenta el grano aclarado inmaduro 2 de forma circular, es menor a 1.6 mm de diámetro y color beige, de esta impureza se adquirió 272 imágenes, este grano tiene la característica de una coloración muy clara, y falta la maduración fisiológica.



*Figura 21.* Grano germinado.

En la Figura 21 presenta el grano germinado de forma circular más una radícula, el diámetro que abarca es menor a 2 mm de diámetro y la radícula 3 mm de largo, presenta de color beige aclarado, el grano germinado presenta un desarrollo de la radícula (embrión) esto se da por presencia de humedad (Norma Técnica Peruana, 2014). Se adquirió 215 imágenes del grano germinado.

En el proceso de emparve se da con la finalidad de realizar el proceso de secado a las panojas del grano de quinua, estas panojas se cubren para proteger de los cambios climáticos como (granizada y lluvia) hasta que el grano obtenga 12% a 15% de humedad para su siguiente proceso, debido a la mala práctica del secado se da la geminación de los granos ocasionando pérdidas (Meyhuay, 1997), la presencia de humedad deteriora las semillas y envejecimiento de la quinua (FAO, 2013).



*Figura 22.* Grano quebrado.

El grano quebrado se muestra en la Figura 22, es de forma irregular tamaño, menor de las tres cuartas partes del grano entero de color beige, este se dio por la presencia de acción mecánica (Norma Técnica Peruana, 2014), se observa en la Figura 22 el perispermo de la quinua, según el grado de dulzor los insectos serán atraídos como *Capitarsia turbata*, *Eurysacca quinoa*, en consecuencia estos insectos perforan el grano de quinua (Tenorio, et al., 2010). De esta muestra se adquirió 308 imágenes.




*Figura 23.* Granos contrastantes –Negra, Roja y Amarilla.

En la Figura 23 se muestra los granos de quinua contrastantes de forma circular, de tamaño menores a 2.2 mm, de colores como: negro, rojo y amarillo, predominantes en el proceso de selección de los granos de quinua blanca (Norma Técnica Peruana, 2014). Se adquirió de la quinua negra 208 imágenes, de la quinua roja 255 imágenes y quinua amarilla 226 imágenes.

La demanda de la exportación de quinua blanca hace que tenga un enfoque mas selectivo del tipo de quinua que se va a cultivar, por consiguiente una mala selección para su cultivo este alterará el tipo de grano de quinua deseado y se obtendran quinuas contrastadas como se ve en la Figura 23 como la quinua negra, la quinua roja y quinua amarilla.

Otra de las razones es por la polinización cruzada por las parcelas cercanas de distintas variedades de la quinua y la existencia de polinizadores como insectos y aves., por ello es importante mantener el grado de uniformidad y la estabilidad de la variedad que se va adquirir (Gómez & Aguilar, 2016).



*Figura 24.* Impureza inorgánica – (A) Piedra, (B) Terron.

Se observa en la Figura 24 las impurezas inorgánicas de la quinua no procesada, de forma irregular de tamaño menor a 1.4 mm de diámetro, presenta de color entre café y plomo oscuro la muestra (A) y de color café la muestra (B).

La presencia de los terrones se presenta después de la pos cosecha de quinua, se debe a un mal manejo de siega, como el arranque de las plantas de quinua que traen tierra y piedrecilla al salir junto con la raíz, como consecuencia se mezcla con el grano

de quinua, disminuyendo la calidad y en el proceso del venteado no se retira toda la materia por el peso específico (Meyhuay, 1997).



Figura 25. Impureza orgánica- Larva seca(*Eurysacca quínoae*).

En la Figura 25 presenta la larva seca son cruciformes tienen cinco pares de patas en el abdomen, tiene la forma de un cuerpo alargado y cilíndrico, 10 a 12 mm de tamaño y de color marrón oscuro(DRA-Ancash, 2016). Estas larvas son masticadores y defoliadores de la quinua, cuando existe una gran población, genera pérdidas económicas (Carpio, 2007). La presencia de las larvas en la quinua debido al sabor dulce y mal manejo de secado (Meyhuay, 1997).

En el secado de la quinua ya trillada, muchas de estas larvas quedan atrapadas y tienden a secarse junto con la quinua y quedan como se muestra en la Figura 25.



Figura 26. Impurezas orgánicas: (A) Perigonio. (B) Muni muni (*Bidens pilosa*), (C) Tallo de quinua y (D) Cebadilla falsa (*Hordeum murinum*).

En la Figura 26 se presenta del perigonio (A) del grano de quinua también llamado envoltura (Norma Técnica Peruana, 2014). Estos al momento de secar la quinua tienen una facilidad de salir del grano de quinua con suaves movimientos mecánicos; también se presenta el Muni muni (*Bidens pilosa*) (B) se caracteriza por tener una forma alargada y de color negro y en un extremo presenta como dos ganchos, la presencia de esta impureza, debido a la presencia de mala hierbas en la época de cosecha, de esta manera la mala hierba interfiere en su desarrollo de la quinua compitiendo por espacio, nutrientes, agua y luz (Carpio, 2007); el tallo (C) se caracteriza por tener un bajo peso específico, es parte de la panoja, que sujeta a cada grano de quinua y la cebadilla falsa (*Hordeum murinum*) (D), de color entre blanco y amarillo de forma alargada, esto se mezcla por las malezas que crecen a lado de la quinua siendo así un impedimento para su desarrollo de la quinua.

Al momento de poscosecha toda estas impurezas orgánicas de bajo peso específico se retiran con las corrientes de viento, puesto que por un mal manejo de venteado y secado, no separa el 100% de las impurezas orgánicas de la quinua (Johana & Ballén, 2018).

Se adquirió 286 imágenes del perigonio, 286 de muni muni (*Bidens pilosa*), 288 de tallos y 256 de cebadilla falsa (*Hordeum murinum*).



Figura 27. Heces de rata.

Se presenta en la Figura 27 la hece de rata, de forma alargado y cilíndrico, tamaño mayor a 1.70 mm de largo, color negro con puntos blancos.

A causa de un mal manejo de emparve y almacenamiento, los roedores ingresan en el proceso de emparve y por ello se encuentran heces de rata, también al finalizar todo

el proceso de poscosecha, ingresan los roedores al área de almacenamiento del grano de quinua.(Meyhuay, 1997).

#### 4.4. Reconocimiento y adquisición de imágenes mediante el dispositivo.

En la Figura 29 se muestra el reconocimiento y la segmentación de las muestras adquiridas en el dispositivo.




Figura 28. Reconocimiento y segmentación de quinua vestida con perigonio.

En Figura 28 se presenta 12 muestras de la impureza de quinua vestida con perigonio, el mayor número de reconocimiento es de diez, a excepción de dos que se confunde con tallos.



Figura 29. Reconocimiento y segmentación de muestras de quinua no procesada.

En la Figura 29 se muestra el reconocimiento y segmentación de las muestras de quinua no procesada, todas fueron segmentadas y solo reconoció a la muestra de quinua contrastadas de color rojo.




Figura 30. Segmentación y reconocimiento de muestras de quinua no procesada.

En la Figura 30 se presenta dos tipos de impurezas muni muni (*Bidens pilosa*) y el tallo, al cual reconoce a la muestra de muni muni (*Bidens pilosa*).

A parte de estos indicadores tenemos también los pertenecientes a la CURVA de ROC.

En la Figura 31 se presenta los Label's de las imágenes, donde se observa una diagonal de puntos en distintos valores acorde a las medidas de la regla de valores de la parte derecha, donde el máximo valor de color amarillo apunta al Label de *Bidens pilosa*, porque el patrón es definida esto quiere decir que la categoría que hace la predicción más exacta es en este tipo de imágenes.




Figura 31. Curva de ROC de los Label's de impurezas y granos defectuosos de quinua.

Así mismo la categoría que sigue es la quinua cubierta, quinua amarilla y la pajilla, el resto sigue en ponderación descendente. En este sentido la diagonal descrita, ilustra la predicción casi perfecta de cada uno de los Label's, al mismo tiempo permite retroalimentar Label's como la quinua aclarada donde las imágenes pueden presentar una confusión con alguna otra categoría.

En la Figura 31 se detalla la relación que existe entre las clases y predicción del modelo, siendo aquellas celdas pintadas con colores claros las que con mayor puntuación se han determinado; lo que describe el nivel de confusión del modelo.

Tabla 6.

Reporte de la clasificación (Verdaderos positivos/ falsos positivos).

Muestras	Precisión (%)	Recall (Reconocimiento)(%)	Support (und)
1 Quinoa buena	31	73	253
2 Quinoa cubierta	52	47	292
3 Quinoa dañada	51	16	292
4 Quinoa inmadura 1	46	66	275
5 Quinoa inmadura 2	39	90	272
6 Quinoa germinada	23	0.5	215
7 Quinoa quebrada	36	0.5	308
8 Quinoa negra	66	58	208
9 Quinoa roja	56	79	255
10 Quinoa amarilla	91	91	226
11 Piedra	64	51	282
12 Terrones	52	81	274
13 Larvas secas( <i>Eurysacca quínoae</i> )	90	55	302
14 Perigonio	52	11	286
15 Muni muni ( <i>Bidens pilosa</i> )	77	99	287
16 Tallos	20	20	288
17 Pajillas ( <i>Hordeum murinum</i> )	69	76	256
18 Heces de rata	76	49	285
<b>Total</b>	55	54	4856

En la Tabla 6, se analiza según indicadores como Precisión es la sensibilidad o exhaustividad del modelo de predicción, por tanto los Label's con mejor predicción fueron; en ese sentido la categoría de imágenes pertenecientes a muni muni (*Bidens pilosa*), tuvo la siguiente Performace: una precisión del 55%, una sensibilidad para acertar que realmente era la categoría correcta del 91%, y estos porque la cantidad de imágenes con excelente resolución se pudo hacer la correcta clasificación y distinción del resto de Label's, así mismo se observa que la pajilla, quinua roja han logrado buena eficiencia en las corridas (EPOCH), de manera opuesta está el Label de tallos que es una categoría confusa y esto se puede deber a que tiene un cruce para reconocer su categoría con alguna otra muy similar conforme a lo que describa las imágenes

En la Tabla 6 presenta de menor precisión los tallos con 20 % y la muestra con mayor precisión es la contrastada quinua amarilla con 91%. El recall de mayor reconocimiento es la impureza muni muni (*Bidens pilosa*) con 99% y el de menor 0.5% las muestras de quinua germinada y quinua quebrada.

El modelo de redes convolucionadas en cuanto a la predicción de quinua amarilla tiene una precisión del 91% , tiene una sensibilidad a la clase del 91%. Esto significa

que la red neuronal a clasificado al 0. 91% de exactitud ( performance del modelo) dicho label. hecho una clasificación casi exacta para la predicción del label.

Según los autores Delgado et al., (2017) encontraron errores en la adquisición de imagen, cuando estás muestras están muy cercanas no determina por completo la clasificacion, y cuando las imágenes tienen similitudes en los colores existe una confusión, por tanto falla en la especificidad.

Confusion Matrix

```

[[185  0  0  0  0  7  0  40  0  0  1  0  2  16  2  0  0  0]
 [  0 205  0  0  0  0  0  2  1  0  0  1  0  16  1  0  0  0]
 [  0  1 145 104  5  0  5  0  1 14  2  4  1  0  0  0  0  0]
 [  0  0  44 221  1  0  2  0  0  6  0  0  0  0  0  0  0  0]
 [  0  0  2  8 167  0 63  0  0 15  0  0  0  0  0  0  5 42]
 [123  0  3  0  0 31  0 42  4  0  6  5 43 14  5 10  0  0]
 [  0  0  0  0  1  0 285  0  1  0  0  0  0  0  0  0  0  0]
 [ 49  5  3  3  0  3  3 57 77  0  5  7 22 49  2  3  0  0]
 [  0  0  0  0  0  0  3 24 195  0  0  0 34  0  0  0  0  0]
 [  1  0 10 72 10  0  4  1  0 139  2  0  0  1  0  0 14 31]
 [ 33  2  2  6  0  0  0  7  1  0 136 18  1 78  6  2  0  0]
 [ 14  9  9  5  0  0  0  1  1  0  52 47 47 92 11  3  1  0]
 [ 21  3  0  0  0  1  0 22  2  0  4  3 182 29  5  3  0  0]
 [ 13  0  0  0  0  0  0  0  0  0  7  2  0 244  2  4  0  0]
 [ 41  1  8  6  0  2  0 50  0  0 32  5 23 32 11  4  0  0]
 [114  0  0  1  0 16  0 42  0  0 15  0 41 60  3 16  0  0]
 [  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0 120 87]
 [  0  0  0  1  1  0  2  0  0  9  0  0  0  0  0  0 41 201]]

```

Figura 32. Matriz de confusión numéricamente.

En la Figura 32 se muestra la matriz de confusión numérica, donde se forma la recta diagonal debe de tener una elevado número, donde en la parte inferior y superior debe de ser 0.

Entonces en la columna 1 y la fila 16 se muestra que la confusión es muy alta siendo la muestra de quinua entera con la quinua quebrada.

El dispositivo adquirió 108 imágenes de una cantidad de 5g de quinua no procesada, al cual dio como resultado de precisión 0.55% de reconocimiento de las impurezas mediante el dispositivo.

Según el autor Samame et al. (2018) realizó clasificación de quinua según los colores a las cuales la precisión llego a 66% a cual abarcando solo de 3 tipos variedades de quinua (sacaca o amarilla, pasankalla o roja y salcedo).

Según Redolfi, et al. (2016) en el trabajo que realizaron en muestras de granos de trigo de clasificación muestra que existe una confusión al tener parecidos en cuando a las características.

En el caso de la muestra de muni muni (*Bidens pilosa*) fue el mejor en reconocimiento la superficie el tamaño que abarca y la calidad de la imagen son mejores que el resto de las muestras, ya que el resto son pequeñas e influye al momento de hacer el reconocimiento.

Apaza et al. (2014) mencionaron que el canal de color la intensidad de color es proporcional al producto de reflectancia y la iluminación dado que el color de las muestras es mas resaltante para el reconocimiento de imágenes por ello las muestras de color fueron mas fácil de ser reconocidas.

La cantidad de imágenes adquiridas para la alimentación del entrenamiento influye para obtener la precisión mientras más imágenes mejor sera la exactitud para el reconocimiento y clasificación (Bagnato, 2018).

Se logró desarrollar el dispositivo para la adquisición de imágenes al cual se muestra en la Figura 33.



Figura 33. Dispositivo para la adquisición de imágenes.

Una vez obtenido las imágenes (4856 imágenes) se paso al entrenamiento para ejecutar en 10 EPOCH de la Red Neuronal, se pudo mejorar la precisión en la identificación de las imágenes a través de las 16 capas convolucionadas.

Las partes del dispositivo del dispositivo mecanico son:

- Cámara de microscopio USB de 1600x1200(pixel de los 2M), 1280x960, 800x600, 640x480, sujeta a un “cabezal” móvil con toma de imagen controlada.
- Tornillo sin fin se encarga del desplazamiento de la cámara a lo largo del porta muestras.
- Motor de paso se encarga del movimiento sincronizado del tornillo sin fin.
- Microcontrolador, la tarjeta Arduino UNO es el encargado del funcionamiento y control del dispositivo programable con lenguaje C++.
- Driver para motor de paso DRV 8825, provee de ordenes exactas al motor de paso.

- Fuente de energía se encarga de suministrar energía eléctrica bajo las tensiones de trabajo requerido.
- Armazon o estructura hecho de material melanina.

Este dispositivo se encarga para la adquisición de imágenes a partir de 12 unidades que se colocan al porta muestras para realizar el reconocimiento de imágenes.

#### Funcionamiento

- Inicialmente se “resetea” la posición del cabezal llevándolo al inicio del recorrido, posición cuadrante 1.
- Se espera la pulsación del botón “siguiente” (botón verde) para tomar fotografía del cuadrante actual para despues pasar al siguiente cuadrante.
- El botón “anterior” (botón blanco) regresa al cuadrante previo.
- El botón “ Reset ” (botón amarillo), resetea el microcontrolador.
- El botón “ siguiente” realiza la función asignada para los 108 cuadrantes, es decir al llegar al cuadrante 54, se debe posicionar el porta muestras para continuar con la siguiente hilera de 54 cuadrante.

## CAPÍTULO V

### CONCLUSIONES Y RECOMENDACIONES

#### 5.1. Conclusiones

Se seleccionó y clasificó las impurezas y granos defectuosos de la quinua según la NTP 205.062 de la quinua no procesada obteniendo de quinua buena 67.18%, quinua cubierta 8.06%, quinua dañada 11.42 %, quinua inmadura 1 0.001 %, quinua inmadura 2 7.79% , quinua germinada 0.24%, quinua quebrada 2.18%, quinua negra 0.13%, quinua roja 0.10%, quinua amarilla 0.07%, piedra 0.05 %, terrones 0.05%, larvas secas 0.03, perigonio 0.80%, muni muni 1.09%, tallos 0.11%, pajillas 0.66 % y heces de rata 0.04%, se determinó las propiedades físicas a las impurezas y granos de quinua defectuosos, humedad esta en un rango de 12.86% la quinua inmadura 2 a 1.96% la impureza de piedra, densidad aparente esta en un rango de 1592.40 Kg/m<sup>3</sup> a 171.09 Kg/m<sup>3</sup> y la densidad real esta en un rango de 2062.18 Kg/m<sup>3</sup> piedra a 501.37 Kg/m<sup>3</sup> , se adquirió imágenes de las impurezas y los granos defectuosos de quinua siendo: 253 de quinua entera, 292 quinua con perigonio, 292 de quinua dañada, 275 de quinua inmadura 1, 272 de quinua inmadura 2, 215 de quinua germinada, 308 de quinua quebrada, 208 quinua contrastada negra, 255 de quinua contrastada roja, 226 de quinua contrastada amarilla, 282 de piedra, 274 de terrones, 302 de larva seca, 286 de perigonio, 287 de muni muni (*Bidens pilosa*), 288 de tallos, 256 de pajillas, 285 de heces de rata con un total de 4856 imágenes. Se desarrolló el sistema aplicativo con los patrones y las imágenes adquiridas utilizando redes neuronales convolucionadas, reconoció las imágenes con los patrones entrenados, el mejor en precisión fue la quinua conrastada amarilla con 91% de exactitud, el mejor en recall fue la muestra de muni muni (*Bidens pilosa*) 99% , se desarrolló el dispositivo para la adquisición de imágenes para 5g de muestra de quinua no procesada.

#### 5.2. Recomendaciones

- Utilizar otros algoritmos para comparar la optimización de la exactitud.
- Mejorar el dispositivo.
- Aumentar mas imágenes de las impurezas y granos defectuosos de la quinua para disminuir el grado de confusión.
- Desarrollar un aplicativo Web para realizar trabajo en campo.

## REFERENCIAS

- Abugoch, L., Augustin, M., Chen, F., Falcone, P., Giudici, P., Gullo, M., ... Yin, J. (2009). *Quinoa (Chenopodium quinoa Willd.): composition, chemistry, nutritional, and functional properties. Adv Food Nutr Res.* (First Edit, Vol. 58). London: Elsevier. Retrieved from [http://dx.doi.org/10.1016/B978-0-88415-882-2\(058\)9001-0](http://dx.doi.org/10.1016/B978-0-88415-882-2(058)9001-0)
- Apaza, R. G., Portugal, C. E., Gutiérrez, J. C., & Beltrán, C. A. (2014). An approach for improve the recognition of defects in coffee beans using retinex algorithms. *Proceedings of the 2014 Latin American Computing Conference, CLEI 2014.* <https://doi.org/10.1109/CLEI.2014.6965102>
- Aranibar, G. (2011). "Efecto inhibitorio de la Saponina de Quinoa (*Chenopodium quinoa Willd.*) en la flora fúngica natural e inducida de *Penicillium digitatum* en naranjas (*Citrus sinensis*)." Universidad Nacional del Altiplano.
- Arévalo, V. M., González, J., & Ambrosio, G. (2004). La librería de visión artificial OpenCV aplicación a la docencia e investigación. Retrieved from [www.sourceforge.net](http://www.sourceforge.net)
- Bagnato, J. (2018). Aprende Machine Learning | Crea tu propia Inteligencia Artificial - antes que sea demasiado tarde-. Retrieved June 10, 2019, from <http://www.aprendemachinlearning.com/>
- Carpio, B. (2007). *EVALUACION DE CARACTERISTICAS , AGRONOMICAS DE DIEZ CULTIVARES DE QUINUA (Chenopodium quinoa Willd.) TOLERANTES A SEQUIA.* Universidad Nacional del Altiplano Puno.
- Casas, Á. (2017). Reconocimiento de imágenes con Redes Convolucionales en C, 1–70.
- Castro, W., Oblitas, J., Chuquizuta, T., & Avila-George, H. (2017). Application of image analysis to optimization of the bread-making process based on the acceptability of the crust color. *Journal of Cereal Science*, 74, 194–199. <https://doi.org/10.1016/j.jcs.2017.02.002>
- Cogliatti, M., & Heter, D. (2017). *Estatuto de la Universidad Nacional del Centro de la Provincia de Buenos Aires en.*
- Coila, J., Quispe, P., & Mujica, A. (1993). Cultivos Andinos FAO - INTRODUCCION. Retrieved April 22, 2019, from

[http://www.fao.org/tempref/GI/Reserved/FTP\\_FaoRlc/old/prior/segalim/prodalim/pr odveg/cdrom/contenido/libro03/cap10.htm](http://www.fao.org/tempref/GI/Reserved/FTP_FaoRlc/old/prior/segalim/prodalim/pr odveg/cdrom/contenido/libro03/cap10.htm)

- Da Wen, S. (2017). *Computer vision technology for food quality evaluation*.
- Delgado, M., Herrera, D., Medina, L., & Corredor, J. (2017). Implementación de un sistema de procesamiento de imágenes integrado con Raspberry PI 2B para reconocimiento y recolección de fresas maduras. *Revista Politécnica*, 13(25), 75–85. <https://doi.org/10.33571/rpolitec.v13n25a6>
- Deng, L., & Yu, D. (2014). Deep Learning: Methods and Applications. *Foundations and Trends® in Signal Processing*, 7(3–4), 197–387. <https://doi.org/10.1561/20000000039>
- DRA-Ancash. (2016). Cultivo de la Quinua en Ancash, 48.
- Elbatawi, I., & Arafa, G. (2008). Application of machine vision for detection of foreign matter in wheat grains. *Agricultural Engineering Research Institute*, 16(2), 275–284.
- FAO. (2013). *Estado del arte de la quinua en el mundo en 2013*. Retrieved from [www.fao.org/publications](http://www.fao.org/publications)
- Garcia, P. P. (2013). Reconocimiento de imagenes usando redes neuronales artificiales. Retrieved from <http://eprints.ucm.es/23444/1/ProyectoFinMasterPedroPablo.pdf>
- Gómez, L., & Aguilar, E. (2016). *Guía de cultivo de la quinua*. Retrieved from [www.fao.org/publications/es](http://www.fao.org/publications/es)
- Haros, C., & Schoenlechner, R. (2017). *Pseudocereals chemistry and technology*. (C. M. Haros & R. Schoenlechner, Eds.) (John Wiley).
- Hayqui, H. (2016). *Extracción y caracterización de aceite de semillas de zapallo de la variedad Macre (Cucurbita maxima)*. *Haydeé Hayqui Betancurt Juliaca, diciembre de 2016*.
- Holger, O., Tufiño, R., & Estévez, J. (2017). Hacia la construcción de un dispositivo de asistencia para personas no videntes en el juego de cuarenta. *Enfoque UTE*, 8(4), 27. <https://doi.org/10.29019/enfoqueute.v8n4.170>
- Jacobsen, S., & Mujica, A. (2002). Genetic resources and breeding of the Andean grain crop quinua (*Chenopodium quinoa* Willd.). *Biodiversity International*, (130), 54–61. Retrieved from [https://www.biodiversityinternational.org/fileadmin/PGR/article-issue\\_130-art\\_61-lang\\_en.html](https://www.biodiversityinternational.org/fileadmin/PGR/article-issue_130-art_61-lang_en.html)
- Johana, L., & Ballén, L. (2018). *EVALUACIÓN DE LAS CONDICIONES POSCOSECHA DE LA QUINUA (Chenopodium quinoa willd) EN DOS CULTIVOS DE*

*CUNDINAMARCA COMO ALTERNATIVA DE MEJORA EN LA PRODUCCION PRIMARIA.* Universidad Nacional Abierta y a Distancia.

- Lu, H., Li, Y., Chen, M., Kim, H., & Serikawa, S. (2018). Brain Intelligence: Go beyond Artificial Intelligence. *Mobile Networks and Applications*, 23(2), 368–375. <https://doi.org/10.1007/s11036-017-0932-8>
- Lutz, M., & Bascuñán-Godoy, L. (2017). The Revival of Quinoa: A Crop for Health. *Superfood and Functional Food*, 37–54. <https://doi.org/10.5772/65451>
- Macuga, T. (2017). What is Deep Learning and How Does It Work? – Robotic Vision Resources Hub. Retrieved April 25, 2019, from <https://resources.rvhub.org/what-is-deep-learning-and-how-does-it-work/>
- Medina, W., Skurtys, O., & Aguilera, J. M. (2010). Study on image analysis application for identification Quinoa seeds (*Chenopodium quinoa* Willd) geographical provenance. *LWT - Food Science and Technology*. <https://doi.org/10.1016/j.lwt.2009.07.010>
- Meyhuay, M. (1997). QUINUA, Operaciones de Poscosecha. In *FAO* (p. 35). Retrieved from <http://www.fao.org/3/a-ar364s.pdf>
- Montes, R. H., Chuctaya, J. H., Portugal-Zambrano, C. E., Gutiérrez-Cáceres, J. C., & Beltrán-Castañón, C. A. (2014). Automatic classification of physical defects in green coffee beans using CGLCM and SVM. *Proceedings of the 2014 Latin American Computing Conference, CLEI 2014*. <https://doi.org/10.1109/CLEI.2014.6965169>
- Moreno, A., & Sanchez, L. (2013). Catalogo de maquinaria para procesamiento de quinua, 1–46. Retrieved from [https://energypedia.info/images/0/08/Maquinaria\\_para\\_Cacao.pdf](https://energypedia.info/images/0/08/Maquinaria_para_Cacao.pdf)
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2(1), 1. <https://doi.org/10.1186/s40537-014-0007-7>
- Navruz-Varli, S., & Sanlier, N. (2016). Nutritional and health benefits of quinoa (*Chenopodium quinoa* Willd.). *Journal of Cereal Science*, 69, 371–376. <https://doi.org/10.1016/j.jcs.2016.05.004>
- Nieto, C., & Vimos, C. (1992). *La Quinoa, Cosecha Y Poscosecha Algunas Experiencias En Ecuador* - Carlos Nieto C, Carlos Vimos - Google Libros. Retrieved April 14, 2019, from <https://books.google.com.pe/books?hl=es&lr=&id=plAzaQAAMAAJ&oi=fnd&pg=PA2&dq=humedad+de+la+quinua+&ots=QviDmPK-0B&sig=->

- GA0WGrBljAvtknO\_T6RgfZdcdw#v=onepage&q=humedad de la quinua&f=false
- Norma Técnica Peruana. (2014). NTP 205.062 GRANOS ANDINOS Quinua APROBADO.
- Quiroga, C., & Escalera, R. (2010). Evaluación de la calidad nutricional y morfología del grano de variedades amargas de quinua beneficiadas en seco, mediante el novedoso empleo de un reactor de lecho fluidizado de tipo surtidor. *Investigacion & Desarrollo*, 10(1), 49–62. <https://doi.org/10.23881/idupbo.010.1-4i>
- Redolfi, J., Gonz, D., Pucheta, J., & Canali, L. (2016). Clasificación de variedades de semillas de trigo usando visión por computadora. *8° Congreso de AgroInformática*, 29.
- Repo-Carrasco, R., Espinoza, C., & Jacobsen, E. (1993). Cultivos Andinos FAO. Retrieved September 14, 2018, from [http://www.fao.org/tempref/GI/Reserved/FTP\\_FaoRlc/old/prior/segalim/prodalim/pr odveg/cdrom/contenido/libro14/cap5.1.htm](http://www.fao.org/tempref/GI/Reserved/FTP_FaoRlc/old/prior/segalim/prodalim/pr odveg/cdrom/contenido/libro14/cap5.1.htm)
- Russel, S., & Norvig, P. (2014). *Inteligencia artificial. Elsevier Brasil*. (Vol. 1). <https://doi.org/M-26913-2004>
- Samame, J. C. M., Monteza, V. A. T., Diaz, J. C. A., & Cabrera, H. I. M. (2018). Clasificación automática de tipos de semilla de quinua a través de descriptores de color. *Revista Científica INGENIERÍA: Ciencia, Tecnología e Innovación*, 4(2). Retrieved from <http://revistas.uss.edu.pe/index.php/ING/article/view/718/655>
- Sandoval, Z., & Prieto, F. (2007). Caracterización de café cereza empleando técnicas de visión artificial. *Rev.Fac.Nal.Agr.Medellín*, 60(2), 4105–4127.
- Tated, K., & Morade, S. (2012). Application of Image Processing for Automatic Cleaning of Rice. *1st International Conference on Recent Trends in Engineering and Technology*, 215–217.
- Tenorio, R., Terrazas, E., Alvarez, M. T., Vila, J. L., & Mollinedo, P. (2010). Revista boliviana de química. *Revista Boliviana de Química*, 27(1), 33–40. Retrieved from [http://www.scielo.org.bo/scielo.php?pid=S0250-54602010000100006&script=sci\\_arttext](http://www.scielo.org.bo/scielo.php?pid=S0250-54602010000100006&script=sci_arttext)
- Valcárcel, B., & Lannes, S. (2012). Applications of Quinoa ( *Chenopodium Quinoa Willd* .) and Amaranth ( *Amaranthus Spp* .) and Their Influence in the Nutritional Value of Cereal Based Foods. *Food and Public Health*, 2(6), 265–275. <https://doi.org/10.5923/j.fph.20120206.12>


- Valencia, P. (2017). *Evaluación tecnológica de la germinación y clarificación de las bebidas tradicionales fermentadas y pasteurizadas de maíz morado (Zea Mays) y Quinoa (Chenopodium Quinoa) Variedad INIA 420 Negra Collana*. Universidad Nacional de San Agustín.
- Vilcacundo, R., & Hernández-Ledesma, B. (2017). Nutritional and biological value of quinoa (*Chenopodium quinoa* Willd.). *Current Opinion in Food Science*, 14, 1–6. <https://doi.org/10.1016/j.cofs.2016.11.007>
- Vilche, C., Gely, M., & Santalla, E. (2003). Physical properties of quinoa seeds. *Biosystems Engineering*, 86(1), 59–65. [https://doi.org/10.1016/S1537-5110\(03\)00114-4](https://doi.org/10.1016/S1537-5110(03)00114-4)
- Vithu, P., & Moses, J. A. (2016). Machine vision system for food grain quality evaluation: A review. *Trends in Food Science and Technology*. <https://doi.org/10.1016/j.tifs.2016.07.011>
- Wang, J., Ma, Y., Zhang, L., & Gao, R. X. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, 48, 144–156. <https://doi.org/10.1016/J.JMSY.2018.01.003>
- Yupanqui, M. A. (2012). *Evaluación de las propiedades físicas y químicas en dos variedades de quinua expandida (Chenopodium quinoa Willd.)*.
- Zapana, F. (2017). "Estudio comparativo de isotermas de adsorción, propiedades físicas y microestructurales de tres variedades de quinua (*Chenopodium quinoa* Willd.), cultivadas a diferentes altitudes." Universidad Nacional del Altiplano. Retrieved from [http://repositorio.unap.edu.pe/bitstream/handle/UNAP/3370/Velasquez\\_Velasquez\\_Lucas\\_Raul.pdf?sequence=1&isAllowed=y](http://repositorio.unap.edu.pe/bitstream/handle/UNAP/3370/Velasquez_Velasquez_Lucas_Raul.pdf?sequence=1&isAllowed=y)

## ANEXOS

*Anexo A. Lote de muestras de quinua no procesada*



*Anexo B. Masado de muestra de quinua no procesada con impurezas.*



*Anexo C. Tamizado de muestra de quinua no procesada.*



Anexo D. Muestra de 100 g para selección y clasificación de impurezas de la quinua.



Anexo E. Selección y clasificación de quinua con impurezas.



Anexo F. Selección y clasificación de impurezas.





Anexo J. Dispositivo para adquisición de imágenes.



Anexo K. Segmentación de las impureza muni muni (*Bidens pilosa*) y tallo del grano de quinua no procesada.




Anexo L1. Reconocimiento y segmentación de muestras clasificadas (Quinoa contrastada amarilla, quinoa inmadura 2 y pajilla).




Anexo M.2 Reconocimiento y segmentación de quinoa de inmadura 2, quinoa amarilla y negra.



Anexo N. Reconocimiento y segmentacion de quinua contrastada, quebrada y larva seca.



Anexo Ñ. Reconocimiento y segmentacion de quinua quebrada, contrastada negra y larva seca.



### Anexo P3. Implementación del dispositivo.



## Descripción

El dispositivo fue diseñado y elaborado conforme a los parámetros proporcionados o características que debiera cumplir. Para su elaboración se utilizó materiales disponibles en el ámbito local principalmente. La realización consta de dos partes fundamentales: implementación física (hardware) y la implementación lógica (software).

## Parámetros y características








El dispositivo debe tomar imágenes con una cámara-microscopio USB, de muestras colocadas en una superficie horizontal (porta muestras), situada a 7cm de la lente de la cámara, dividida en "cuadrantes", 108 en total, distribuidos en 2 hileras de 54 cuadrantes cada una. Requiriendo, entonces, que la cámara se "movilice" a lo largo de los 54 cuadrantes de ida y 54 cuadrantes de vuelta. El número de imágenes a tomar por cada cuadrante es de 3 imágenes, que ayudado del software propietario (cámara-microscopio USB) son almacenadas en la PC a la cual se encuentra conectada la cámara.

## 1ra Parte: Implementación Física

### Diseño del porta muestras

Cada cuadrante es de 15mm (13+2) x 20mm (17+3), con lo que se obtiene un largo mínimo de 810mm para el porta muestras, considerando 30mm de distancia para posicionamiento de la cámara en cada extremo, se tiene como largo del porta muestras 870mm. Para el ancho se considera 20mm x 2 (hileras), obteniendo un ancho mínimo de 40mm, estableciéndose en 80mm de ancho. Finalmente, el porta muestras es de 870mm x 80mm (87cm x 8cm).

### Principales componentes

<p><b>Cámara-microscopio USB:</b> Sujetada a un "cabezal" móvil con toma de imagen controlada.</p>	
<p><b>Tornillo sin fin:</b> Encargado del desplazamiento de la cámara a lo largo del porta muestras.</p>	
<p><b>Motor de paso:</b></p>	
<p>Encargado del movimiento sincronizado del tornillo sin fin.</p>	
<p><b>Microcontrolador:</b> Tarjeta Arduino® UNO, encargado del funcionamiento y control del dispositivo. Programable con lenguaje C++.</p>	
<p><b>Driver para motor de paso:</b> DRV8825, provee de "órdenes" exactas al motor de paso.</p>	
<p><b>Fuente de energía:</b> Suministra energía eléctrica bajo las tensiones de trabajo requeridas.</p>	
<p><b>Armazón o estructura:</b> De material "melamina", en base al dimensionamiento obtenido.</p>	

## 2da Parte: Implementación Lógica

La programación del microcontrolador se realizó con el software Arduino® IDE versión 1.6.5, con lenguaje de programación C++.



### Funcionamiento:

- Inicialmente se "resetea" la posición del cabezal llevándolo al inicio del recorrido, posicionándose en el cuadrante 1.

```
void setup() {  
    pinMode(nnext, INPUT);  
    pinMode(nante, INPUT);  
  
    pinMode(dirPin, OUTPUT);  
    pinMode(stepPin, OUTPUT);  
  
    pinMode(2, INPUT);  
  
    attachInterrupt(digitalPinToInterrupt(2), inix, RISING);  
    delay(200);  
    reset0();  
}
```

- Se espera la pulsación del botón "Siguiente" (botón verde) para tomar 3 fotografías del cuadrante actual para seguidamente pasar al siguiente cuadrante.
- El botón "Anterior" (botón blanco) regresa al cuadrante previo.

```
void loop() {  
    if(digitalRead(nnext)==HIGH) {  
        cuadrant();  
    }  
    delay(100);  
    if(digitalRead(nante)==HIGH) {  
        if(qq>0) {  
            anterior();  
        }  
    }  
    delay(100);  
}
```

- El botón "Reset" (botón amarillo), resetea el microcontrolador.
- El botón "Siguiente" realiza la función asignada para los 108 cuadrantes, es decir al llegar al cuadrante 54, se debe posicionar el porta muestras para continuar con la segunda hilera.

```
void cuadrant() {  
  if(fin==0) {  
    return;  
  }  
  if(qq<54) {  
    digitalWrite(dirPin, HIGH); // horario  
  } else {  
    digitalWrite(dirPin, LOW); // antihorario  
  }  
  qq++;  
  pasosX(1500);  
}
```

Anexo Q. Dispositivo para la adquisición de imágenes (frontal ).



Anexo R. Dispositivo para la adquisición de imagen (lateral).

