



# FACULTAD DE INGENIERÍA

Carrera de Ingeniería de Sistemas Computacionales

“SISTEMA DE VISIÓN COMPUTACIONAL MÓVIL EN LA IDENTIFICACIÓN DE LA CALIDAD DE QUINUA BLANCA”

Tesis para optar el título profesional de:

Ingeniero de Sistemas Computacionales

Autores:

Lecca Pino Percimil

Tafur Vera Daniel Llonathan

Asesor:

Ing. Juan Orlando Salazar Campos

Trujillo - Perú

2018

## DEDICATORIA

Dedico este proyecto de tesis a mis padres por inculcar en mí el ejemplo de esfuerzo y valentía, quienes a lo largo de su vida han velado por mi bienestar y educación en cada momento; a mi familia por haber tenido paciencia en esta etapa de desarrollo y brindado su apoyo para llegar a cumplir esta meta.

Percimil Lecca.

Dedico este trabajo a mis padres Edgar y Milagros quienes me dieron la mejor educación posible inculcándome valores y principios para convertirme en lo que soy, sobre todo a mi madre por su cariño, y su apoyo incondicional a lo largo de mi vida; a mi familia por creer en mí siempre; a Fátima mi compañera por su amor, por vivir cada proyecto mío como el suyo y su constante motivación.

Daniel Tafur.

## AGRADECIMIENTO

A Dios por habernos guiado y acompañado en el transcurso de nuestras vidas, brindándonos paciencia y sabiduría; a nuestro asesor de tesis, quien con sus aportes brindados nos permitió culminar con éxito este trabajo de titulación; también a todas las personas que nos han apoyado y motivado, de alguna forma, son parte de su culminación.

## Tabla de contenidos

<b>DEDICATORIA</b> .....	<b>2</b>
<b>AGRADECIMIENTO</b> .....	<b>3</b>
<b>ÍNDICE DE TABLAS</b> .....	<b>5</b>
<b>ÍNDICE DE FIGURAS</b> .....	<b>6</b>
<b>ÍNDICE DE ECUACIONES</b> .....	<b>7</b>
<b>CAPÍTULO I. INTRODUCCIÓN</b> .....	<b>10</b>
1.1. Realidad problemática.....	10
1.2. Formulación del problema .....	43
1.3. Objetivos .....	43
1.4. Hipótesis.....	43
<b>CAPÍTULO II. METODOLOGÍA</b> .....	<b>44</b>
2.1. Tipo de investigación .....	44
2.2. Población y muestra (Materiales, instrumentos y métodos).....	44
2.3. Procedimiento .....	46
2.3.1. Análisis.....	46
2.3.2. Diseño .....	48
2.3.3. Implementación.....	63
2.3.4. Pruebas .....	68
<b>CAPÍTULO III. RESULTADOS</b> .....	<b>72</b>
5.1. Indicador 1: Porcentaje de eficacia .....	74
5.2. Indicador 2: Porcentaje de sensibilidad .....	76
5.3. Indicador 3: Porcentaje de especificidad .....	78
<b>CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES</b> .....	<b>81</b>
<b>REFERENCIAS</b> .....	<b>84</b>
<b>ANEXOS</b> .....	<b>86</b>
<b>ANEXO n.º 01</b> .....	<b>86</b>
<b>ANEXO n.º 02</b> .....	<b>122</b>
<b>ANEXO n.º 03</b> .....	<b>126</b>
<b>ANEXO n.º 04</b> .....	<b>127</b>

## ÍNDICE DE TABLAS

Tabla 1 <i>Comparativa de cámaras en dispositivos móviles.</i> .....	20
Tabla 2 <i>Clasificación por tamaño del grano de quinua según NTP.</i> .....	42
Tabla 3 <i>Clasificación por categoría del grano de quinua según NTP.</i> .....	42
Tabla 4 <i>Criterios para la clasificación del grano de quinua según su tamaño.</i> .....	46
Tabla 5 <i>Criterios para la categorización de los granos de quinua según características físicas.</i> .....	47
Tabla 6 <i>Escala de pesos, para sección de técnicas en el procesamiento de imágenes.</i> .....	48
Tabla 7 <i>Comparativa para selección de dispositivos de captura.</i> .....	49
Tabla 8 <i>Comparativa de técnicas para suavizado de imagen.</i> .....	50
Tabla 9 <i>Comparativa de técnicas para el realce de características.</i> .....	51
Tabla 10. <i>Comparativa de técnicas para segmentación.</i> .....	54
Tabla 11. <i>Comparativa de técnicas de extracción de características.</i> .....	55
Tabla 12 <i>Resultado de análisis de sensibilidad para cada clase.</i> .....	76
Tabla 13 <i>Resultado de análisis de sensibilidad para cada categoría.</i> .....	77
Tabla 14 <i>Resultado de análisis de especificidad por cada clase.</i> .....	78
Tabla 15 <i>Resultado de análisis de especificidad por cada categoría.</i> .....	79

## ÍNDICE DE FIGURAS

<i>Figura 1.</i> Filtrado espaciales de imágenes. ....	25
<i>Figura 2.</i> Detección de contornos en imágenes.....	26
<i>Figura 3.</i> Representación de una red neuronal artificial.....	32
<i>Figura 4.</i> Arquitectura de una red neuronal convolucional.....	33
<i>Figura 5.</i> Ejemplo de convolución de imagen con un kernel de 3x3. ....	34
<i>Figura 6.</i> Ejemplo de Pooling. ....	35
<i>Figura 7.</i> Comparativa de modelos de redes CNN.....	37
<i>Figura 8.</i> Convolución de modelo MobileNet. ....	38
<i>Figura 9.</i> Arquitectura de modelo MobileNet. ....	38
<i>Figura 10.</i> Técnicas, instrumentos y procedimientos de recolección de datos.....	45
<i>Figura 11.</i> Métodos, instrumentos y procedimientos de análisis de datos. ....	45
<i>Figura 12.</i> Características físicas consideradas para el análisis basado en la NTP. ....	47
<i>Figura 13.</i> Captura de muestra en entorno controlado. ....	50
<i>Figura 14.</i> Diagrama de flujo de preprocesamiento. ....	52
<i>Figura 15.</i> Recuperación de perspectiva de la imagen original.....	53
<i>Figura 16.</i> Preprocesamiento de imagen. ....	54
<i>Figura 17.</i> Segmentación de imagen. ....	55
<i>Figura 18.</i> Diagrama de flujo de extracción de características.....	56
<i>Figura 19.</i> Extracción de características. ....	57
<i>Figura 20.</i> Diagrama de flujo para el reconocimiento de los elementos según su tipo y tamaño.....	57
<i>Figura 21.</i> Arquitectura del modelo MobileNet de red CNN para la clasificación de elementos. ....	58
<i>Figura 22.</i> Diagrama de flujo para la interpretación de clase según norma técnica. ....	60
<i>Figura 23.</i> Diagrama de flujo para la interpretación de categoría según norma técnica. ....	61
<i>Figura 24.</i> Arquitectura del SVC en la identificación de la calidad de quina blanca. ....	62
<i>Figura 25.</i> Función para la aplicación del preprocesamiento de imagen. ....	63
<i>Figura 26.</i> Método de segmentación de la imagen.....	63
<i>Figura 27.</i> Función que devuelve los contornos de la imagen binarizada.....	64
<i>Figura 28.</i> Función que genera la región de interés por cada elemento. ....	64
<i>Figura 29.</i> Función que clasifica los elementos por región de interés a través de la red CNN. ....	64
<i>Figura 30.</i> Función que determina el diámetro de los granos enteros de quinua. ....	65
<i>Figura 31.</i> Métodos de interpretación de calidad (clase y categoría). ....	65
<i>Figura 32.</i> Directorio de clases de entrada para el entrenamiento de la red CNN. ....	66
<i>Figura 33.</i> Imágenes de la clase quinua entera para entrenamiento de red CNN. ....	67
<i>Figura 34.</i> Archivos de salida del entrenamiento de la red CNN.....	67
<i>Figura 35.</i> Resultado de una prueba después del entrenamiento de la red CNN.....	68
<i>Figura 36.</i> Resultados obtenidos de prueba por tamaño. ....	69
<i>Figura 37.</i> Resultados obtenidos de prueba por tipos de elementos.....	70
<i>Figura 38.</i> Resultado esperado de una muestra basado en NTP.....	70
<i>Figura 39.</i> Resultados obtenidos de prueba de una muestra basada en la NTP.....	71
<i>Figura 40.</i> Matriz de confusión para múltiples clases. ....	73
<i>Figura 41.</i> Matriz de confusión múltiple del análisis por clase.....	73
<i>Figura 42.</i> Resultado de matriz de confusión múltiple por cada clase. ....	74
<i>Figura 43.</i> Matriz de confusión múltiple del análisis por categoría. ....	74
<i>Figura 44.</i> Resultado de matriz de confusión múltiple por cada categoría. ....	74
<i>Figura 45.</i> Análisis de eficacia.....	75
<i>Figura 46.</i> Resultados de sensibilidad por cada clase. ....	76
<i>Figura 47.</i> Resultados de sensibilidad por cada categoría.....	77
<i>Figura 48.</i> Análisis de sensibilidad. ....	78
<i>Figura 49.</i> Resultados de especificidad por cada clase. ....	79
<i>Figura 50.</i> Resultados de especificidad por cada categoría.....	80
<i>Figura 51.</i> Análisis de especificidad. ....	80

## ÍNDICE DE ECUACIONES

Ecuación ( 1 ) .....	44
Ecuación ( 2 ) .....	59
Ecuación ( 3 ) .....	73
Ecuación ( 4 ) .....	74
Ecuación ( 5 ) .....	75
Ecuación ( 6 ) .....	76
Ecuación ( 7 ) .....	77
Ecuación ( 8 ) .....	78
Ecuación ( 9 ) .....	80

## RESUMEN

La quinua en la actualidad posee gran demanda en el ámbito comercial debido a sus diversas propiedades nutritivas.

El proceso para determinar la calidad de este grano esta propenso a la presencia de errores, debido a que frecuentemente se realiza de forma manual dependiendo de un experto el cual está sujeto al cansancio y a criterios subjetivos.

Esta problemática nos conllevó evaluar el entorno internacional y nacional verificando que no existe tecnología relacionada para la identificación de la calidad de quinua basada en estándares, esto nos abrió la posibilidad de explorar alternativas basadas en visión computacional.

La investigación se enfocó en determinar la influencia de un sistema de visión computacional móvil en la identificación de la calidad de quinua blanca, basándonos en la norma técnica peruana NTP-205.062:2009, desarrollando un sistema de visión computacional a través de las fases de PDI, realizando comparativas entre los métodos y técnicas, para seleccionar la que mejor se adecuaba en la construcción de un sistema móvil.

Obteniendo como resultados una eficacia de 96.75%, sensibilidad de 82.05% y una especificidad de 99.11%. Logrando determinar la influencia de un sistema de visión computacional móvil en la identificación de la calidad de la quinua blanca.

**Palabras clave:** sistema de visión computacional, calidad de quinua, procesamiento digital de imágenes, norma técnica, redes neuronales convolucionales



## ABSTRACT

Quinoa is currently in great demand in the commercial field due to its diverse nutritional properties.

The process to determine the quality of this grain is prone to the presence of errors, because it is often done manually depending on an expert who is subject to fatigue and subjective criteria.

This problem led us to evaluate the international and national environment, verifying that there is no related technology for the identification of the quality of quinoa based on standards, this opened the possibility of exploring alternatives based on computational vision.

The research focused on determining the influence of a mobile computer vision system in the identification of the quality of white quinoa, based on the Peruvian technical standard NTP-205.062: 2009, developing a system of computational vision through the phases of digital image processing, making comparisons between the methods and techniques, to select the one that best suited the construction of a mobile system.

Obtaining as results an efficiency of 96.75%, sensitivity of 82.05% and a specificity of 99.11%. Achieving to determine the influence of a mobile computer vision system in the identification of the quality of white quinoa.

**Keywords:** computer vision system, quinoa quality, digital image processing, technical standard, convolutional neural networks

## CAPÍTULO I. INTRODUCCIÓN

### 1.1. Realidad problemática

La quinua es un grano andino que presenta una gran diversidad biológica. Es un producto de alto contenido de macronutrientes, aminoácidos y minerales, base de la dieta alimenticia de los pobladores de las zonas andinas, en especial del antiguo Perú, Bolivia, parte de Ecuador, Chile y Argentina. (MINAGRI, 2017)

Según la OMS y la FAO, la quinua es el alimento ideal para el ser humano, porque su proteína contiene el mejor balance de aminoácidos, incluyendo los ocho aminoácidos esenciales, que no pueden ser producidos por el organismo humano. Es un alimento de fácil digestión, recomendable para celíacos, diabéticos y para quienes tienen intolerancia a la lactosa; por sus características nutritivas es un sustituto de la carne o la leche. De acuerdo con los datos provistos por la FAO, los principales países productores son Perú y Bolivia. Siendo nuestro país el primer productor de quinua seguido de Bolivia, liderando la producción mundial de quinua con aproximadamente un 52% de la producción mundial y Bolivia el 45%. (Fairlie Reinoso, 2016)

Las exportaciones de la quinua en el Perú se reflejan, a partir del 2006 superando las mil toneladas, llegando en el 2010 hasta las 4,8 mil toneladas. Con la denominación del año 2013 como “Año Internacional de la Quinua” (AIQ) las exportaciones se elevan en un 75% llegando a 18,2 mil toneladas; en el 2014 se llega a exportar 36,2 mil toneladas logrando alcanzar el valor de exportación de (US\$ 196,4 millones), en el 2015 se eleva las exportaciones a 41,4 mil toneladas y en el 2016 se mantiene la tendencia aumentando a 44,3 mil toneladas. (MINAGRI, 2017)

Nuestro país se ha convertido en uno de los mayores exportadores alrededor del mundo. La puesta en vitrina mundial de la quinua y la elevada presión de su demanda permitió la mejora de sus precios y el incentivo para sembrar mayores áreas de quinua en especial en ciertas regiones de la costa donde antes no se había producido; tales como Arequipa (parte costa), Lambayeque, La Libertad, Tacna, Lima e Ica. Asimismo, se amplió y consolidó su producción en regiones de la serranía como Ayacucho, Junín y Huánuco. (MINAGRI, 2017)

La quinua para su comercialización y exportación tiene que pasar por distintos procesos de poscosecha siendo el último la etapa de clasificación y selección, en algunos lugares este proceso ha dejado de ser manual, dando lugar a la tecnificación, donde los granos son pasados por una máquina clasificadora con diferentes tamaños de malla, gracias a estos procesos, el producto adquiere una calidad para ser vendido en mercados o supermercados. (Fairlie Reinoso, 2016)

El proceso de selección consiste en clasificar el grano de acuerdo al tamaño peso y color a través de un método manual o mecanizado; el primero es apropiado para las pequeñas cantidades y el segundo para grandes volúmenes, en este proceso se pueden utilizar máquinas de aire y zaranda, mesa densimetría o depredadora y el selector óptico. (Apaza Quispe, 2015).

Uno de los factores que pueden afectar la calidad final del grano es la presencia de cierta cantidad de defectos que son llamados “valores porcentuales de sus

características” como son: granos quebrados, inmaduros, contraste e impurezas y también el diámetro promedio de los mismos. (NTP 205.062, 2009)

La identificación de la calidad del grano de quinua es uno de los criterios más importantes para la comercialización, ya que los costos de los mercados nacionales e internacionales varían según el nivel de calidad del producto. Para ello los productores de quinua procesada en nuestro país también hacen uso de diferentes tipos de máquinas que se encargan de la clasificación y selección del grano. Sin embargo, la importancia de la calidad no es solamente vista desde los productores sino también de los comerciantes y consumidores finales, quienes actualmente no cuentan con herramientas tecnológicas o medios para poder corroborar con certeza la calidad de la quinua, sólo se tiene que confiar en el juicio experto o en análisis manuales basados en la norma técnica peruana 205.062.

Se han considerado los siguientes trabajos como antecedentes internacionales sobre el procesamiento digital de imágenes en la clasificación y calidad de granos:

Los autores Redolfi, González, Pucheta, y Canali (2016) de la Universidad Tecnológica Nacional, en la investigación “Clasificación de variedades de semillas de trigo usando visión por computadora”. Abordaron el problema de identificación de variedades de semillas de trigo, a las cuales antes de su comercialización se le debe realizar un análisis de una pequeña muestra. Esta tarea es realizada por personal calificado usando inspección visual, pero en la mayoría de los casos los métodos usados son lentos, tediosos, tienen baja reproducibilidad y agregan un grado de subjetividad difícil de cuantificar. Para resolver este problema plantearon el uso de

técnicas actuales de clasificación de imágenes y visión por computadora como son los algoritmos eFV y CNN. Para comparar los diferentes métodos propuestos, se evaluaron la exactitud de cada uno de ellos en el conjunto de evaluación, el cual estuvo compuesta por 195 muestras. Logrando como resultado una exactitud del 95% en la clasificación de un dataset de semillas de 6 variedades de grano de trigo.

En otra investigación de Arias y Sierra (2016), desarrollaron en Colombia el proyecto de investigación titulado “procesamiento de imágenes para la clasificación de café verde”, donde afrontan el problema de la clasificación del grano que normalmente son a través de selección manual o a nivel industrial, los cuales presentan desventajas como el agotamiento del trabajador llevando a errores en la selección o el alto costo de la maquinaria industrial, lo que le dificulta al pequeño productor ofrecer un producto de alta calidad. Para esta necesidad desarrollaron un algoritmo para la detección de defectos en café verde mediante el procesamiento de imágenes. Donde evaluaron la eficiencia total del algoritmo, es decir la cantidad de granos buenos que pasan por malos (falso rechazo), como la cantidad de granos malos que pasan por buenos (falsa aceptación), obteniendo resultados como: falso rechazo 16.7% y falsa aceptación 7.3%.

En la universidad Autónoma del caribe, Colombia, autores como Beleño, Gualdrón, Medina, y Herrera (2016), en el artículo “diseño de un sistema automático de selección de frutos de café mediante técnicas de visión artificial” se enfrentaron a la problemática sobre la selección de frutos de café. Donde los caficultores tienen que analizar si los frutos están en un estado adecuado de maduración y además, tienen que buscar la

presencia de la broca. Algunos caficultores utilizan un método artesanal, llamado “método de flotes”, el cual consiste en llenar un tanque con agua y con frutos de café, de manera que los frutos de baja densidad que no son adecuados queden flotando y los de alta densidad que son adecuados caigan al fondo del tanque, lográndose una eficacia de separación de 88,9%. Sin embargo, este método exige un consumo elevado de agua (4,7 L/Kg). Ante este problema diseñaron un sistema de visión artificial, desarrollando dos algoritmos, uno basado en un clasificador de color usando la “regla del mínimo error de Bayes”, para la detección de los cafés maduros. Y para detectar la broca se realizó una binarización por umbral, para conocer el estado de los frutos de café empleados como muestras se realizó una validación mediante el “método tradicional de flotes”. Como resultado el clasificador de color obtuvo un 100% de efectividad. Mientras que, el algoritmo de detección de brocas obtuvo un resultado equivalente a un 76% de efectividad. Por último, evaluaron el rendimiento de ambos algoritmos en conjunto, obteniendo como resultados una efectividad del 87%.

En Argentina la investigación titulada “control de la calidad de granos para dispositivos móviles empleando procesamiento de imágenes” de los autores Ventre, Sampallo y Cleva (2016), expresa que actualmente la valoración de la calidad de los granos, basada en cualidades tales como tamaño, forma, color y defectos son realizados por expertos, haciendo el control en forma manual grano por grano, siendo una tarea tediosa. La demanda en tiempo de la labor y la subjetividad de los resultados acentúan la necesidad de instrumentar sistemas objetivos y automáticos de control de la calidad. Para la clasificación de la calidad de los granos se emplean las definiciones de carácter morfológico y de aspecto que son establecidas, en el Código Alimentario

Argentino (C.A.A). Ante este problema desarrollaron un sistema portátil para clasificar la calidad de granos basado en sus descriptores morfológicos como son contorno, largo, ancho, área, factor de forma y un sistema experto que se basa en reglas para determinar su calidad. Permitiendo realizar objetivamente el análisis y la clasificación de acuerdo con las normativas de calidad vigentes. Para ello usaron una muestra de 5 gramos de arroz (alrededor de 150 granos) distribuyéndolo sobre una superficie plana negro mate, que contraste con el color claro del grano y con la condición de que los granos no estén en contacto entre sí. Se incorpora en una posición definida de la escena un objeto de dimensiones conocidas (por ejemplo, una moneda para definir la escala). La captura se tomó en un ambiente controlado de iluminación y distancia. Obteniendo resultados coherentes con el tipo de muestra analizada.

Y así mismo, se mencionan algunas investigaciones nacionales sobre el procesamiento digital de imágenes basados en la clasificación de granos:

El autor Tapia (2014) de Puno Perú, desarrolló la tesis titulada “análisis y diseño de un sistema computarizado para la interpretación colorimétrica y morfométrica del *Chenopodium*”, donde abarca el problema sobre la clasificación y control de calidad de las variedades de los granos de quinua. Nos menciona que actualmente existen sistemas muy complejos y costosos capaces de reconocer e interpretar patrones en imágenes aplicados a la selección y control de alimentos siendo estos accesibles solo para centros de investigación o laboratorios. Para solucionar el problema se propuso la implementación de sistemas automáticos de control de calidad y de selección en el proceso de producción de Quinua, a través del procesamiento de imágenes.

Concluyendo en sus resultados que el algoritmo es eficiente determinando el color valido de los granos en un 95% y la selección de granos a expulsar en un 90%.

En la universidad nacional José María Arguedas de Andahuaylas, el autor Palomino (2014), desarrolló la tesis titulada “software automático de reconocimiento de patrones para la discriminación de granos de arroz pulido basado en procesamiento digital de imágenes”, donde atendió la problemática sobre los granos de arroz, que presenta variaciones en sus características en relación al tamaño, consistencia al cocinar, cualidades aromáticas y color de grano. Además, la presencia de los granos tizosos “panza blanca” tienden a aumentar el porcentaje de granos quebrados afectando la calidad del producto. Siendo la etapa más importante en la producción de arroz el control de calidad, donde un operario con la capacitación adecuada hace un conteo total para determinar el número de granos, y mide cada grano para hallar el número total de largos, medianos y cortos. Del mismo modo identifica si los granos poseen algún defecto como tizoso total, tizoso parcial. Todo este proceso demanda demasiado tiempo y está sujeto a posibles errores. Debido a estos problemas el autor implementó una aplicación de software automático basado en procesamiento digital de imágenes desarrollado bajo la metodología de software OpenUp, haciendo uso de MatLab con el Toolbox Image Processing. A través de las siguientes fases: adquisición de la imagen, con color negro en el fondo del escáner, para eliminar la sombra del grano e incrementar el contraste, pre procesado de la imagen, eliminación del ruido y ciertas partes de la imagen que son irrelevantes, se utilizó binarización con umbral obtenido con el método de Otsu para segmentar la imagen, extracción de características, los atributos geométricos que consideraron para el proyecto fueron: longitud máxima y el



área. Y discriminación de objetos, se hizo con indicadores de la Norma Técnica Peruana NTP 205.011 .Obteniendo resultados de confiabilidad en: un 95 % para la discriminación en función a su clase, 96 % para la discriminación en función a su tipo de defecto y un 100 % para el conteo de granos.

Viera (2017), desarrolló la tesis “procesamiento de imágenes usando OpenCV aplicado en Raspberry PI para la clasificación del cacao” en la universidad de Piura, donde nos indica los métodos utilizados para la evaluación de la calidad de granos de cacao, como: cromatografía líquida de alto rendimiento (HPLC), cromatografía de gases, índice de fermentación, prueba sensorial, espectroscopia de masas, y la prueba de corte, generalmente son, tediosos, lentos, caros, o destructivos y requieren una preparación cuidadosa de la muestra. Para esta necesidad desarrolló un sistema prototipo que realice la selección automática de grano de cacao orgánico según sus características externas por medio de un sistema de visión artificial. Aplicando las fases: adquisición de imágenes, se construyó un pequeño prototipo compuesto por una caja de madera (paredes internas blancas), una bandeja blanca, dos cámaras digitales con conexión USB, una fuente de alimentación de 12V e iluminación LED. En el procesado y segmentación de imágenes, la imagen original se transforma a escala de grises y luego a binario con el método de Otsu. Extracción de características, se definen el largo, ancho, altura de los granos permitiendo una clasificación según el tamaño, en tres distintas clases. En el análisis aplicado en el modelo de color HSV se concluyó que el valor de color adecuado oscila entre los valores de 0.04 y 0.15 en el parámetro H (tono), entre 0.29 y 0.7 en el parámetro S (saturación), y entre 0.28 y 0.68 en el parámetro V (valor). Como resultado de la tesis se tiene: clasificación de granos de

cacao según su tamaño con porcentaje de acierto de 89% en un total de 300 imágenes evaluadas. Con respecto al tamaño de los granos se midió su largo, presentando en este caso un error máximo de 0.06 cm en un total de 300 fotos evaluadas.

Conjuntamente, en este trabajo de investigación recogemos conceptos como:

### **Sistemas de visión computacional**

La visión computacional puede ser definida como los procesos de obtención, caracterización e interpretación de información de imágenes tomadas de un mundo tridimensional. (García Santillán, 2008)

El objetivo de la visión por computadora es tomar decisiones útiles sobre objetos físicos reales y escenas basadas en imágenes capturadas.

Para tomar decisiones sobre objetos reales, casi siempre es necesario construir alguna descripción o modelo de ellos a partir de la imagen. Debido a esto, muchos expertos dicen que el objetivo de la visión por computadora es la construcción de descripciones de escenas a partir de imágenes. (Shapiro & Stockman, 2000)

### **Visión artificial en dispositivos móviles**

Tradicionalmente, la visión por computador es una disciplina científica que ha requerido equipos con gran poder de cómputo. Gracias a los espectaculares avances de la tecnología, los teléfonos móviles de última generación han adquirido capacidades que permiten la ejecución de programas de procesamiento de imagen. Los dispositivos móviles permiten crear aplicaciones de visión por computador muy diversas, algunos ejemplos son: (Interfaces gestuales, reconocimiento óptico de caracteres, búsqueda, visual, realidad aumentada, aplicaciones avanzadas de fotografía, vigilancia). (Déniz, 2007)

## **Imagen digital**

Se define como una función bidimensional  $f(x,y)$  donde  $x$  e  $y$  son coordenadas en el plano y la amplitud  $f$  es llamada intensidad o nivel de gris en ese punto. Cuando  $(x, y)$  y  $f$  son todos finitos (cantidades discretas) llamamos a la función como imagen digital. Es decir, una imagen digital estará compuesta por un número finito de elementos llamados píxeles, cada uno de los cuales con un valor y una posición particular. El valor es relativo a alguna propiedad del punto que representa, como por ejemplo su brillo o su matiz. (García Santillán, 2008)

## **Píxel**

Abreviación de Picture element o elemento de imagen, es la unidad mínima de información de una imagen, la cual aparece como un punto en la pantalla o en una impresora. (García Santillán, 2008)

## **Formatos de Imagen Digital**

Los formatos de imágenes más populares son: TIFF, BMP, GIF, JPEG y PNG.

## **Clasificación de las imágenes digitales**

Entre estos tenemos: Imágenes RGB, que utilizan tres canales para reproducir los colores en la pantalla, 8 bits por canal, es decir, 24 bits de color para cada píxel presentando hasta 16,7 millones de colores. Imágenes en escala de grises, utilizan distintos tonos de gris que van desde 0 a 255. Imágenes binarias, tienen una profundidad de color de 1 bit (blanco o negro) para representar una imagen. (García Santillán, 2008)

### Calidad de una imagen

La calidad de la imagen es determinada por tres factores: El tamaño del píxel, donde un intervalo de muestreo largo produce una imagen baja en resolución espacial. Un intervalo más corto produce una resolución espacial más alta. El brillo o valor de color de cada píxel es definido por un bit o un grupo de bits. Mientras más bits se usen, más alta es la resolución de brillo. El ruido se manifiesta generalmente como píxeles aislados que toman un nivel de gris diferente al de sus vecinos y aparece como pequeñas y aleatorias variaciones en el brillo y el color. (García Santillán, 2008)

### La resolución

El tamaño de una imagen se puede calcular multiplicando la cantidad de píxeles horizontales (ancho) por la cantidad de píxeles verticales (alto) y por la profundidad de brillo (en bits). (García Santillán, 2008)

Tabla 1  
*Comparativa de cámaras en dispositivos móviles.*

CARÁCTE- RÍSTICAS	Dispositivos				
	Samsung Galaxy s9 Plus	LG G5	HTC m9	Huawei P9 Lite	OnePlus One
Resolución	12mp	16mp	20.7mp	13mp	13mp
Apertura de diafragma	F1.5-2.4	f/1.8	f/2.2	f/2.0	f/2.0
Tamaño sensor / píxel	1.4 $\mu\text{m}$	1.12 $\mu\text{m}$	1.096 $\mu\text{m}$	1.127 $\mu\text{m}$	1.115 $\mu\text{m}$
Estabilización de imagen	Sí	Sí	NO	NO	Sí
Memoria Interna	64GB	32GB	32GB	16GB	64GB

Nota. Fuente: propia.

### **Modelo RGB**

En el modelo RGB, cada color aparece en sus componentes espectrales primarios de rojo, verde y azul. Las imágenes representadas en este modelo consisten en tres componentes de imágenes, una para cada color primario. El número de bits que se utiliza para representar cada píxel en el espacio RGB es llamado profundidad de píxel. Así, una imagen RGB en que cada imagen roja, verde y azul es una imagen de 8-bits tiene 24 bits de profundidad, puesto que cada píxel es una tripleta de valores (R, G, B) y tiene un número total de  $2^{24} = 16,777,216$  colores. (García Santillán, 2008)

Las máquinas pueden distinguir entre cualquier par de codificaciones de bits diferentes, pero las codificaciones pueden o no representar diferencias que son significativas en el mundo real. Cada píxel RGB de 3 bytes o 24 bits incluye un byte para cada uno de rojo, verde y azul. El orden en que cada uno aparece en la memoria puede variar; el orden es irrelevante para la teoría, pero importante para la programación. (Shapiro & Stockman, 2000)

### **Modelo HSV**

Los modelos RGB y CMY no son útiles para describir los colores en términos prácticos para la interpretación humana. Por ejemplo, una persona no se refiere al color de un auto dando porcentajes del contenido de cada uno de sus colores primarios, sino que lo describe en términos de su tono (H), saturación (S) y su brillo o intensidad (I). Existen algunas utilidades de este modelo como el diseño de sistemas automáticos para detectar el grado de maduración de frutas y vegetales, sistemas para comparar muestras de color o inspeccionar la calidad de productos coloreados. (García Santillán, 2008)

## **Fases para el procesamiento de imágenes**

El procesamiento digital de imágenes (PDI) está dividido en seis áreas principales:

- ✓ La captura o adquisición es el proceso a través del cual se obtiene una imagen digital utilizando un dispositivo de captura como una cámara digital, video cámara, escáner, satélite, etc.
- ✓ El preprocesamiento incluye técnicas tales como la reducción del ruido, realce del contraste, realce de ciertos detalles, o características de la imagen.
- ✓ La segmentación es el proceso que divide una imagen en objetos que sean de nuestro interés de estudio.
- ✓ La descripción es el proceso que obtiene características convenientes para diferenciar un tipo de objeto de otro, como: la forma, el tamaño, área, etc.
- ✓ Calificación o reconocimiento es el proceso que identifica los objetos, como, por ejemplo: una llave, un tornillo, moneda, coche, etc.
- ✓ La interpretación es el proceso que asocia un significado a un conjunto de objetos reconocidos (llaves, tornillos, herramientas, etc.) y trata de emular la cognición. Según (García Santillán, 2008)

## **Captura**

El proceso de captura se refiere a la adquisición de la imagen del mundo físico. La imagen puede ser capturada o generada de varias maneras: fotográficamente, con elementos químicos; o a través de dispositivos electrónicos como el computador, escáner, cámara digital o videocámara digital. (García Santillán, 2008)

✓ **Apertura diafragma**

El tamaño de la apertura se representa con una serie de números llamados números f, estos números son una sucesión logarítmica, los más comunes son:  $f/1 - f/1.2 - f/1.4 - f/2 - f/2.8 - f/4 - f/5.6 - f/8 - f/11 - f/16 - f/22 - f/32 - f/64$ , un diafragma abierto tiene un número menor y uno cerrado uno mayor, por tanto un  $f/1$  es un diafragma completamente abierto, por el que entraría bastante luz y un  $f/64$  es un diafragma muy cerrado, por el que pasaría poca luz. (Ochoa, 2015)

✓ **Tamaño de sensor**

Determina la calidad de la imagen, cuando el sensor es más grande, la captura se obtiene con menos ruido y mayor rango dinámico que los sensores más pequeños, es la pieza de una cámara digital que recibe la señal lumínica y la convierte en una señal eléctrica para que el procesador la convierta finalmente en una imagen digital. Existen diferentes tamaños de sensor encontrando los más pequeños en las cámaras compactas o en las cámaras de los smartphones, gracias a su tamaño estos dispositivos pueden ser mucho más pequeños. Algunos de los más comunes son de tamaño  $1/1,7''$  ( $7,6 \times 5,7$  mm),  $1/1,8''$  ( $7,18 \times 5,32$  mm) o  $1/2,5''$  ( $5,76 \times 4,29$  mm). (León, 2007)

## **Preprocesamiento**

✓ **Realce o mejora de imágenes**

Esta técnica comprende un conjunto de operaciones tendentes a mejorar la calidad visual de una imagen. Estas operaciones permiten realzar las

características de brillo y contraste de una imagen, reducir su contenido de ruido, o agudizar o intensificar detalles presentes en ella. (Santamaría, 2002)

### **Procesado de histograma**

Es un proceso por el que se normaliza la imagen de tal forma que el valor de gris más pequeño es llevado a 0 y el máximo valor a 255. El histograma es de gran utilidad en el tratamiento de imágenes ya que con él se puede variar el aspecto de las imágenes. El histograma es una función discreta que representa el número de píxeles en la imagen en función de los niveles de intensidad. (Gómez Trejos y Guerrero Guzmán, 2016)

#### ○ **Filtrado espacial de una Imagen**

El filtrado es una técnica para modificar o mejorar a una imagen, se calcula mediante algún algoritmo que toma en cuenta los valores de los píxeles de la vecindad de la imagen original.

#### **Filtros espaciales de paso bajo (Suavizantes)**


Tienen por objeto suavizar los contrastes espaciales presentes en una imagen. Un filtro espacial de paso bajo tiene por efecto dejar pasar o mantener intocables los componentes de baja frecuencia espacial de una imagen. (Santamaría, 2002).

- **Filtrado paso bajo**, se basa en el promediado de los píxeles adyacentes al píxel que se evalúa (vecindad 3x3, 5x5, etc.). (García Santillán, 2008)
- **Filtro de paso bajo mediana**, se basa en sustituir el valor de un píxel por el de la mediana del conjunto formado por el mismo y sus ocho vecinos. Es una operación no lineal que se suele



utilizar en el procesamiento de imágenes para reducir el ruido "sal y pimienta". La mediana de filtrado es más efectiva cuando el objetivo es reducir el ruido y al mismo tiempo preservar los bordes. (García Santillán, 2008)

- **Filtrado gaussiano**, se caracteriza por asignar un mayor peso al píxel central y a sus vecinos dando menor peso a los píxeles alejados, en este filtro el difuminado de los bordes no es tan pronunciado como en el paso del filtro de media simple. Es especialmente utilizado para eliminar el ruido gaussiano.



*Figura 1.* Filtrado espaciales de imágenes.

(a) Imagen original; (b) Imagen con ruido; (c) Imagen con filtro de promedio; (d) Imagen con filtro de mediana

Fuente: (García Santillán, 2008)

### **Filtros espaciales de paso alto**


Los filtros espaciales de paso alto se corresponden con las altas frecuencias, suelen corresponder a los bordes de los objetos presentes en las imágenes.

- **El realce de bordes**

Consiste en resaltar aquellos píxeles que tienen un valor de gris diferente al de sus vecinos. Si la imagen contiene ruido, su efecto se multiplicará, por lo que primero se debe eliminar el ruido. (García Santillán, 2008)

- **La detección de contornos**

En una imagen, los contornos corresponden a los límites de los objetos presentes en la imagen. Para hallar los contornos se buscan los lugares en la imagen en los que la intensidad del píxel cambia rápidamente. Los métodos para el realce de bordes más utilizados son: Sobel, Prewitt, Robert, Canny. (García Santillán, 2008)



*Figura 2.* Detección de contornos en imágenes.

(a) Imagen original; (b) Detección con filtro de Sobel;

(c) Detección con filtro de Canny

Fuente: (García Santillán, 2008)

### **Canny**

Es el operador más utilizado en la detección de bordes en imágenes donde existe la presencia de geometrías regulares, ya que mantiene tres criterios vitales para nuestros propósitos: Precisión en la localización del contorno. Fiabilidad en la detección de los puntos de contorno. Unicidad en la obtención de un único borde para el contorno; este filtro de detección de

bordes consiste en un proceso multifase, en el que el usuario deberá introducir tres parámetros básicos: una desviación estándar y dos valores umbral. El resultado será una imagen binaria, con píxeles de color negro y blanco; los píxeles negros son los que corresponden a los bordes. (Aguilera, 2011)

#### ✓ Operadores morfológicos

Una operación morfológica es una herramienta que permite extraer componentes de una imagen que son útiles en la representación y descripción de la forma de una región como los bordes. (Palomino Cáceres, 2014)

##### **Dilatación**

Hace crecer o engrosar los objetos en una imagen binaria. La forma específica y el alcance de este crecimiento son controlados por un elemento estructural. Si el origen o el centro de este último coincide con un píxel de valor 1 de la imagen, el elemento estructural solapa a la imagen original (Palomino Cáceres, 2014).

##### **Erosión**

Encoge o adelgaza los objetos en una imagen binaria. Del mismo modo que en la dilatación, la forma específica y el alcance de este encogimiento son controlados por un elemento estructural. Si todo el elemento estructural coincide con los valores 1 de la imagen, se obtiene en la salida solo la posición del origen del elemento estructural. (Palomino Cáceres, 2014)

##### **Apertura**

De forma parecida a la erosión, pretende eliminar algunas zonas de los píxeles del frente, siendo en general menos destructiva que la erosión. Se utiliza para

eliminar ruido de las imágenes. Es una combinación de las dos operaciones morfológicas básicas (apertura = erosión + dilatación). La apertura es el dual del cerramiento; abrir los píxeles del frente con un determinado kernel es lo mismo que cerrar los píxeles del fondo con el mismo kernel. (Gutiérrez y Antolín, 2003)

### **Cierre**

Es parecido a la dilatación ya que ambas tienden a agrandar los bordes de regiones del frente, pero más constructiva que esta operación. El cerramiento dilata suavemente, cerrando un poco los huecos. Es también una combinación de las operaciones morfológicas básicas (cerramiento = dilatación + erosión). Realizar el cerramiento de los píxeles del frente con un kernel particular equivale a abrir el fondo con el mismo kernel. (Gutiérrez y Antolín, 2003)

### **Segmentación**

Consiste en dividir una imagen digital en regiones homogéneas o similares con respecto a una o más características (como por ejemplo el brillo, el color, tamaño, longitud, forma). Se basan en dos propiedades básicas de los niveles de gris de la imagen: Discontinuidad y Similitud. Dentro de la primera categoría se intenta dividir la imagen basándonos en los cambios bruscos en el nivel de gris. Las áreas de interés en esta categoría son la detección de puntos, líneas y bordes en la imagen. Las áreas dentro de la segunda categoría están basadas en las técnicas de umbrales, crecimiento de regiones, y técnicas de división y fusión. Algunos ejemplos de problemas de segmentación son: localizar los ojos de una persona dentro de la imagen de una fotografía, separar los caracteres dentro de una imagen de un texto, localizar los

vehículos en una calle dentro de una imagen, detectar ciertos tipos de células en imágenes médicas, o en general, cuando se trata de separar ciertos objetos de un fondo en una imagen cualquiera. (García Santillán, 2008)

✓ **Segmentación basada en detección de bordes**

La imagen está compuesta por objetos de diversas características y en la detección de bordes se localiza la intersección de estos objetos para poder determinar sus regiones e información. Los bordes pueden clasificarse por su anchura, ángulo de su pendiente de variación, y las coordenadas de su punto medio. Los diferentes modelos de bordes son: línea, tipo escalón, tipo rampa y tipo tejado. (Gómez Trejos y Guerrero Guzmán, 2016)

✓ **Segmentación basada en umbralización**

La umbralización es un proceso que permite convertir una imagen de niveles de gris o en color en una imagen binaria, de tal forma que los objetos de interés se etiqueten con un valor distinto de los píxeles del fondo. Es una técnica de segmentación rápida, que tiene un coste computacional bajo y que incluso puede ser realizada en tiempo real durante la captura de la imagen usando un computador personal. (García Santillán, 2008)

Si bien hay diferentes métodos para hallar un umbral, la mayoría de ellos no dan buenos resultados cuando se trabaja con imágenes del mundo real, debido a la presencia de ruido, histogramas planos o una iluminación inadecuada. Por el contrario, el método de Otsu es uno de los mejores métodos de selección de umbral para imágenes del mundo real, sin embargo, necesita mucho más tiempo para seleccionar el umbral óptimo. La importancia del método de Otsu radica en que es automático, es decir, no necesita supervisión humana ni

información previa de la imagen antes de su procesamiento. (García Santillán, 2008)

✓ **Segmentación basada en regiones**

Es utilizada para separar los objetos de interés. En este caso, la imagen es particionada en diferentes regiones, quedándose cada una relacionada en ciertas características y conjuntos de píxeles conectados. Así, a partir de la segmentación de la imagen en regiones, pueden ser realizadas las medidas sobre cada región y las relaciones entre las regiones adyacentes pueden ser establecidas. (García Santillán, 2008)

### **Descripción**

Como su nombre lo indica, esta técnica consiste en extraer las características de la imagen tales como tamaño, colores, área, forma, perímetro; entre otras. También permite conocer las características topográficas como la representación de objetos geográficos y el tamaño de la superficie. (Gómez Trejos y Guerrero Guzmán, 2016)

✓ **Descriptores de contorno**

Aquí encontramos dos descriptores sencillos: Longitud, se obtiene contando el número de píxeles a lo largo del contorno. Curvatura, se define como el ritmo de variación de la pendiente. Se puede emplear la diferencia entre las pendientes de segmentos adyacentes del contorno (que han sido representados por líneas rectas) como un descriptor de la curvatura en el punto de intersección de los segmentos. De esta forma, se obtiene la curvatura de puntos significativos, como, por ejemplo, los vértices de un polígono. Se puede querer

indicar si un segmento es cóncavo/convexo o bien si un segmento es recto o corresponde con una esquina. (Gutiérrez y Antolín, 2003).

✓ **Descriptores de regiones**

Permite extraer las características a partir de la información de todos los píxeles del objeto segmentado, además del contorno. Se puede calcular métricas como: Área, número de píxeles contenidos dentro de su frontera. Perímetro, longitud de la frontera de la región. Compatibilidad, se define como la relación entre el cuadrado del perímetro entre el área de la región. Centro de gravedad (x, y), es un punto representativo de la región. Redondez, razón entre el área y el eje mayor al cuadrado. Enlongación, también denominada razón de aspecto es la relación entre la longitud y la anchura de una región. Excentricidad, cociente entre la longitud de los ejes mayor y menor. Compacidad, cociente entre la raíz cuadrada del área y el eje mayor. (Gutiérrez y Antolín, 2003)

## **Reconocimiento**

✓ **Redes neuronales.**

Las redes neuronales utilizan muchos elementos de cálculo elementales y generalmente no lineales llamados neuronas, los cuales reciben un conjunto de señales de entrada  $x_1, x_2, \dots, x_n$  (el vector  $X$ ). Cada señal de entrada se multiplica por un peso asociado a la conexión y después se calcula una suma ponderada para determinar el nivel de excitación de la neurona. La salida de la neurona se obtiene calculando el nivel de excitación mediante una función de activación. (Gutiérrez y Antolín, 2003)




Figura 3. Representación de una red neuronal artificial.

Fuente: (Rosano, 1996)

Una red neuronal se compone de los siguientes elementos: El elemento receptor, a donde llegan una o varias señales de entrada  $X_i$ , que generalmente provienen de otras neuronas y que son atenuadas o amplificadas cada una de ellas con arreglo a un factor de peso  $W_i$  que constituye la conectividad entre la neurona fuente de donde provienen y la neurona de destino en cuestión. El elemento sumador, que efectúa la suma algebraica ponderada de las señales de entrada, ponderándolas de acuerdo con su peso. El elemento de función activadora, que aplica una función no lineal de umbral (que frecuentemente es una función escalón o una curva logística) a la salida del sumador para decidir si la neurona se activa, disparando una salida o no. El elemento de salida que es el que produce la señal, de acuerdo con el elemento. (Rosano, 1996)

Las ventajas de las redes neuronales son las siguientes: Aprendizaje adaptativo, tienen la capacidad de aprender a realizar tareas basadas en entrenamiento en experiencia. Auto organización, la red puede crear su propia organización o su propia representación de la información después de una etapa de aprendizaje. Tolerancia a fallos, una destrucción parcial de la red conduce a una degradación de los resultados, pero puede seguir funcionando, Operación en tiempo real, pueden ser realizadas en paralelo. Fácil inserción dentro de la



tecnología existente, una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a hardware con bajo coste. (García, 2013)

### Entrenamiento

Las redes neuronales usan algoritmos para ajustar sus parámetros (pesos) para obtener la salida deseada de la red. El algoritmo más común es backpropagation, el cual calcula el gradiente de una función de costo para determinar cómo ajustar los parámetros para minimizar el error que afecta el desempeño. (Zaragoza, 2018).

### ✓ Redes Neuronales convolucionales

Las CNNs son especialmente útiles para localizar patrones en imágenes con el objetivo de reconocer objetos, caras y escenas. Aprenden directamente a partir de los datos de imágenes, utilizando patrones para clasificar las imágenes y eliminar la necesidad de una extracción manual de características. Puede tener decenas o cientos de capas que aprenden a detectar diferentes características de una imagen. Se aplican filtros a cada imagen estos pueden pasar de características muy simples, tales como el brillo y los bordes, a características más complejas que definen inequívocamente el objeto. Entre las ventajas del uso de las CNNs están que: Eliminan la necesidad de una extracción manual de características, la propia CNN aprende directamente las características. Generan unos magníficos resultados de reconocimiento. Se pueden volver a entrenar para nuevas tareas de reconocimiento a partir de redes ya existentes. (Matlab, s.f.)

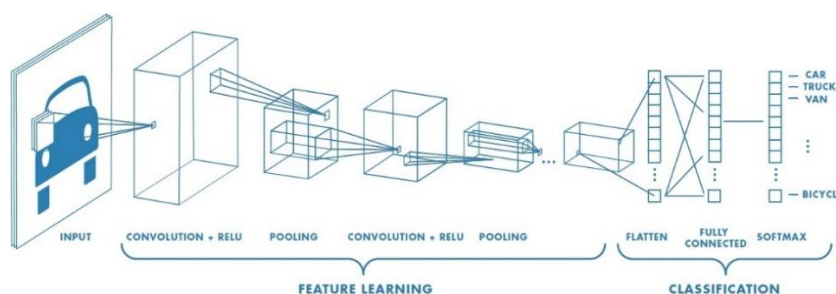


Figura 4. Arquitectura de una red neuronal convolucional.

Fuente: (Matlab, s.f.)

○ **Capas de una red CNN**

**Capa de entrada**

Es la entrada a la red, normalmente para el tipo de redes convolucionales es una imagen sin procesar.

**Capa convolucional**

Permite extraer las características útiles en una imagen a través de un conjunto de filtros convolucionales. En las aplicaciones de deep learning, la entrada es normalmente un vector de varias dimensiones (tensor), y el kernel es frecuentemente un vector multidimensional de parámetros que son modificados por el algoritmo de aprendizaje. Por ejemplo, si se usa como datos de entrada, una imagen  $I$ , lo más frecuente es que se utilice un kernel de dos dimensiones, que en este caso denotaremos como  $K$ . (Alesanco, 2018)




Figura 5. Ejemplo de convolución de imagen con un kernel de 3x3.

Fuente: (Alesanco, 2018)

**Rectificador Lineal de Unidad**

Es una función de activación utilizado después de cada convolución. Esta operación reemplaza los valores negativos por cero y su propósito es agregar no linealidad al modelo, eliminando la relación proporcional entre la entrada y salida. (Carlos Quintero, 2018)

**Normalizador por Lotes (Batchnorm)**

Es una técnica que se encarga de normalizar la capa de entrada ajustando y escalando las activaciones; centrándose especialmente en optimizar y acelerar el entrenamiento de una red. Se basa en reducir la covarianza interna de los datos, o más simplificado, reducir la frecuente

variabilidad que hay entre los datos de un mismo conjunto (por ejemplo, en imágenes cambios en la normalización de luz). Para la transformación que se aplica se requieren 4 parámetros, por un lado, la media y varianza, con los que se normaliza, y por otro lado dos parámetros que se aprenden (de la misma forma que los pesos y sesgos), que sirven para escalar y centrar respectivamente de forma correcta los datos. (Estruch, 2016)

### Pooling

Algoritmo utilizado para reducir las dimensiones, con el objetivo de disminuir los tiempos de procesamiento reteniendo la información más importante. (Carlos Quintero, 2018)

Se calcula a través de la media o se busca el valor máximo dentro del mapa de características.

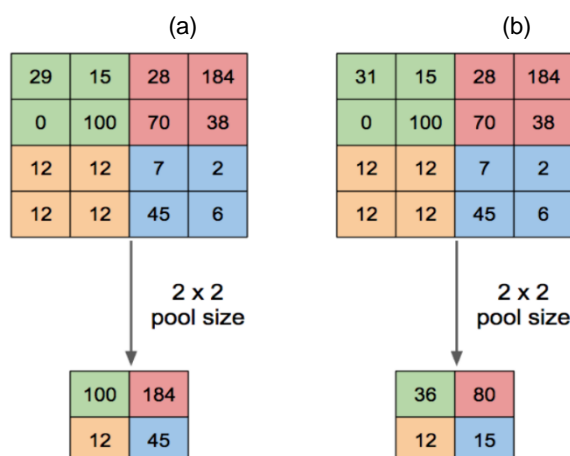


Figura 6. Ejemplo de Pooling.

(a) Max-Pooling; (b) Average-Pooling

Fuente: (Alesanco, 2018)

### Capa totalmente conectada (Dense Layer)

Realiza la clasificación basado en las características extraídas por las capas de convolución y las reducidas por pooling. En esta capa todos los nodos están conectados con la capa precedente. (Carlos Quintero, 2018)

- **Transferencia de conocimiento entre redes convolucionales**

Los modelos modernos de reconocimiento de imágenes tienen millones de parámetros. Entrenarlos desde cero requiere una gran cantidad de datos de entrenamiento etiquetados y mucha potencia de cómputo. El aprendizaje por transferencia es una técnica que facilita este proceso tomando una parte de un modelo que ya ha sido entrenado en una tarea relacionada y reutilizándolo en un nuevo modelo. Para hacer esto, necesita generar un conjunto de datos personalizados etiquetados con las clases relevantes. (Tensorflow, 2018)

En las primeras capas de las redes neuronales convolucionales obtenemos características de bajo nivel como los bordes para luego, en las capas posteriores, capturar las de alto nivel. Al utilizar modelos previamente entrenados, aprovechamos las características de bajo nivel y resolvemos el problema del sobreajuste. Además, reducimos la carga de entrenamiento que tiene un alto costo computacional para los modelos más complejos. (Carlos Quintero, 2018)

- ✓ **Modelo MobileNet**

Es una familia de modelos de visión por computadora de Google, principalmente para móvil, diseñada para maximizar efectivamente la precisión, mientras toma en consideración los recursos restringidos para aplicaciones integradas o en dispositivos móviles. Se pueden usar para clasificación, detección, incrustaciones y segmentación, de forma similar a otros modelos populares a gran escala, como Inception . Fue entrenado con la base de datos de imágenes de ImageNet que contiene 1000 clases predefinidas. Si estas clases no son suficientes para un caso específico, el modelo deberá ser re-entrenado. (Wang, 2017)




Figura 7. Comparativa de modelos de redes CNN.

(eje X) número de operaciones requeridas (eje Y) frente a la exactitud para modelos disponibles

Fuente: (Tensorflow, 2017)

### Arquitectura de MobileNet

La estructura de MobileNet se basa en convoluciones separables en profundidad, a excepción de la primera capa que es una convolución completa. Todas las capas van seguidas de normalizador por lotes y ReLU no lineal, con la excepción de la capa final totalmente conectada que no tiene linealidad y se alimenta en una capa de softmax para la clasificación. Finalmente se aplica un Average Pooling para reducir la resolución espacial a uno antes de la capa completamente conectada. Considerando las capas de convolución profunda y las puntuales, en total la red tiene 28 capas. (Andrew G. Howard, Menglong Zhu, Bo Chen, & Dmitry Kalenichenko, 2017)

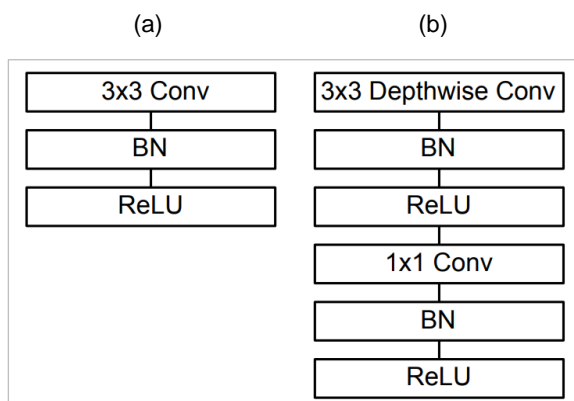


Figura 8. Convolución de modelo MobileNet.

(a) capa convolucional estándar; (b) capa convolucional profunda y puntual)

Fuente: (Andrew G. Howard, Menglong Zhu, Bo Chen, & Dmitry Kalenichenko, 2017)

Type / Stride	Filter Shape	Input Size	
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$	
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$	
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$	
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$	
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$	
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$	
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$	
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$	
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$	
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$	
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$	
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$	
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$	
5×	Conv dw / s1	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
	Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$	
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$	
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$	
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$	
Avg Pool / s1	Pool $7 \times 7$	$7 \times 7 \times 1024$	
FC / s1	$1024 \times 1000$	$1 \times 1 \times 1024$	
Softmax / s1	Classifier	$1 \times 1 \times 1000$	

Figura 9. Arquitectura de modelo MobileNet.

Fuente: (Andrew G. Howard, Menglong Zhu, Bo Chen, & Dmitry Kalenichenko, 2017)

## **Quinua**

La quinua (*Chenopodium quinoa* Willd.) es un cultivo de alto valor nutritivo que contiene más proteínas que la mayoría de los demás alimentos vegetales. La quinua es considerada una semilla (vegetal), pero se come como un cereal. Es un recurso alimentario natural de alto valor nutritivo cuya importancia es cada vez más reconocida en la seguridad alimentaria, para las generaciones presentes y futuras. La quinua se cultiva principalmente en los países andinos Perú, Argentina, Bolivia, Chile, Colombia y Ecuador, y también en los Estados Unidos. Bolivia es el primer productor mundial, seguido de Perú y a menudo se le denomina “el grano de oro de los Andes”. (FAO, 2013)

Es un grano pequeño de forma redonda semi-aplanado de color blanco amarillento, rico en proteínas, carbohidratos y un excelente balance de aminoácidos esenciales para el desarrollo de tejidos en el ser humano. (Control Union Perú (Agente Certificador), 2014)

### ✓ **Distribución y producción de la quinua**

Según FAOSTAT, en el periodo 1992 - 2010 el área cosechada y la producción total de quinua en los principales países productores Bolivia, Perú y Ecuador casi ha duplicado y triplicado sus cifras respectivamente. El cultivo de la quinua está en expansión, encontrándose en la actualidad en más de 70 países. En 2002 fueron registradas 80.000 hectáreas de quinua en el mundo, las cuales se producen principalmente en la región andina. Los principales productores del mundo son Bolivia, Perú y los Estados Unidos. Sin duda, los mayores países productores de quinua en la región andina y en el mundo son Perú y Bolivia. El año 2008 la producción de ambos países representó el 92% de la quinua producida en el mundo. Más atrás se encuentran: Estados Unidos, Ecuador, Argentina y Canadá, totalizando cerca del 8% de los volúmenes globales de producción. En los últimos años la producción en la región andina fue de aproximadamente 70.000 toneladas. (FAO, 2013)

### ✓ **Proceso productivo de la quinua perlada**

Durante este proceso se pretende conseguir un grano de alta calidad, para esto se realizan varias etapas una vez obtenida la materia prima como despedrado,

limpieza y purificación del grano, desaponificado, tamizado, lavado del grano, centrifugado, secado, despedrado, clasificado, envasado, embalado, almacenado.

Estos procesos pueden efectuarse de forma manual o mecanizada de acuerdo a la cantidad de producción; por lo general se utilizan maquinarias, como limpiadoras, secadores, seleccionadoras o clasificadoras, transportadores, desaponificadores, tostadoras, molinos, laminadoras, equipos de expandidos, extracción aceite en frío y envasadoras. En la etapa de selección, se clasifica el grano de acuerdo con el tamaño, peso y color. El objetivo de este procedimiento es clasificarlo por categorías según las especificaciones de calidad. Para este proceso se suelen usar máquinas de aire y zaranda, mesa de disimétrica o despedradora y selector óptico. (Marca Vilca, Chaucha Jove, Quispe Quispe, y Mamani Centón, 2011)

#### ✓ **Calidad de la Quinua Procesada**

Según las especificaciones de la NTP 205.062:2009 para la quinua procesada se considera las siguientes características:

- **Color del grano de quinua no procesada:** es el color del pericaripo y del episperma, presentes en los granos de quinua antes del procesado; se clasifica en: granos blancos, granos oscuros, granos de color.
- **Granos contraste:** Son granos de quinua que, por su aspecto y color, difieren de las características predominantes del proceso de selección.
- **Granos enteros (no defectuosos):** Son aquellos granos de quinua procesada que no presentan ningún tipo de alteración en su forma física.
- **Granos quebrados:** Son pedazos de granos cuyos tamaños son menores a las tres cuartas partes del grano entero ocurridos por acción mecánica.
- **Granos dañados:** Son granos enteros o quebrados que en forma o estructura difieren de los demás, debido a que han sido alterados por agentes físicos, químicos o biológicos.
- **Granos infectados:** Son granos dañados por la presencia de microorganismos.



- **Granos infestados:** Son granos dañados por roedores o insectos que además pueden contener insectos vivos y/o muertos, como también sus larvas y/o excrementos.
- **Granos manchados:** Son granos enteros o quebrados que presentan una coloración diferente a la norma, debido a los fenómenos biológicos, químicos, atmosféricos, etc.
- **Granos inmaduros:** Son granos que no han alcanzado su madurez fisiológica, caracterizándose por su pequeño tamaño y coloración verdusca.
- **Granos germinados:** Son granos que presentan desarrollo inicial de la radícula (embrión).
- **Quinua:** Es el grano procedente de la especie *Chenopodium quinoa*, de la familia *Chenopodiaceae*.
- **Quinua procesada:** Son los granos de quinua que han sido sometidos a operaciones de limpieza y selección (clasificado), escarificado, lavado, secado y despedrado, resultando un producto apto para el consumo.
- **Granos recubiertos:** Son granos que conservan la envoltura (perigonio) o parte de la flor adherida al grano, antes o después de procesarlo.
- **Impurezas:** Son materias extrañas a los granos de quinua como: Las cascarillas, partes de tallos, granos de otras especies, partes de hojas, piedrecillas, arenilla, tierra, etc.
- **Saponina:** Moléculas que están constituidas por un elemento soluble en lípidos y un elemento soluble en agua, y forman una espuma cuando son agitados en agua. Las saponinas son tóxicas, podrían interferir en la asimilación de esteroides por el sistema digestivo o romper membranas de las células luego de ser absorbidas.

### Clasificación por el tamaño del grano

Tabla 2

*Clasificación por tamaño del grano de quinua según NTP.*

Tamaño de los granos	Diámetro promedio (mm)	Malla
<b>Extra grande</b>	mayor a 2,0	85 % retenido en la malla ASTM 10
<b>Grandes</b>	mayor a 1,70 hasta a 2,0	85 % retenido en la malla ASTM 12
<b>Medianos</b>	mayor a 1,40 hasta 1,69	85 % retenido en la malla ASTM 14
<b>Pequeños</b>	menor a 1,40	85 % que pasa por la malla ASTM 14

Nota. Fuente: NTP 205.062

### Clasificación por su categoría

Tabla 3

*Clasificación por categoría del grano de quinua según NTP.*

Parámetros Sensoriales	Unidad	Categoría 1		Categoría 2		Categoría 3	
		Min	Max	Min	Max	Min	Max
Granos enteros	%	96		90		86	
Granos quebrados	%		1,5		2,0		3,0
Granos dañados	%		1,0		2,5		3,0
Granos germinados	%		0,15		0,25		0,3
Granos recubiertos	%		0,25		0,30		0,35
Granos inmaduros	%		0,5		0,7		0,9
Impurezas totales	%		0,25		0,30		0,35
Piedrecillas en 100g de muestra	U/100g		0		0		0
Granos contrastantes	%		1,0		2,0		2,5
Insectos (enteros, partes o larvas)	%		0		0		0

Nota. Fuente: NTP 205.062.

## 1.2. Formulación del problema

¿Cómo influye un sistema de visión computacional móvil en la identificación de la calidad de quinua blanca?

## 1.3. Objetivos

### 1.3.1. Objetivo general

Determinar la influencia de un sistema de visión computacional móvil en la identificación de la calidad de quinua blanca.

### 1.3.2. Objetivos específicos

- ✓ Desarrollar un sistema de visión computacional móvil que permita identificar la calidad de quinua blanca a un nivel de eficacia mayor o igual a 95%.
- ✓ Desarrollar un sistema de visión computacional móvil que permita identificar la calidad de quinua blanca a un nivel de sensibilidad mayor o igual 93.45%.
- ✓ Desarrollar un sistema de visión computacional móvil que permita identificar la calidad de quinua blanca a un nivel de especificidad mayor o igual a 90.91%.

## 1.4. Hipótesis

### 1.4.1. Hipótesis general

H<sub>0</sub>: Un sistema de visión computacional móvil influye positivamente en la identificación de la calidad de quinua blanca.

H<sub>1</sub>: Un sistema de visión computacional móvil no influye positivamente en la identificación de la calidad de quinua blanca.

## CAPÍTULO II. METODOLOGÍA

### 2.1. Tipo de investigación

Experimental, pre experimental

Diseño de un solo grupo con una sola medición:

$$G: \longrightarrow X \quad - - O_1$$

Donde:

**G** : Grupo de investigación

**X** : Aplicación del sistema de visión computacional Móvil

**O<sub>1</sub>**: Observación de la Medición de Indicadores en el grupo de investigación.

### 2.2. Población y muestra (Materiales, instrumentos y métodos)

#### Población

Imágenes de porciones de quinua blanca de 5gr. Perú – La Libertad (basado en el antecedente Control de la calidad de granos para dispositivos móviles empleando procesamiento de imágenes)

#### Muestra

Para poblaciones infinitas obtenemos el tamaño de la muestra a través de la siguiente fórmula:

$$n = \frac{Z^2 * p * q}{e^2} \quad \text{Ecuación ( 1 )}$$

Donde:

Z: nivel de confianza (95% o 1.96)

p: porcentaje de la población que tiene el atributo deseado.

q: porcentaje de la población que no tiene el atributo deseado (1-p)

e: error de estimación máximo estimado (5%).

n: Tamaño de la muestra.

Nota: cuando no hay indicación de la población que posee o no el atributo se asume 50% para p y 50% para q 50%

Reemplazando tenemos  $n = 384.16$

### Materiales, instrumentos y métodos

Indicadores	Técnica	Instrumentos
Porcentaje de eficacia.	Observación	Guía de observación
Porcentaje de sensibilidad	Observación	Guía de observación
Porcentaje de especificidad	Observación	Guía de observación

Figura 10. Técnicas, instrumentos y procedimientos de recolección de datos.  
Fuente: propia.

Variable	Indicadores	Método de Procesamiento de análisis de datos
Variable Dependiente	Porcentaje eficacia.	$\text{Eficacia} = \frac{T}{N} \times 100$ <p>Donde: N: total de muestras T: Resultado correctos de la evaluación de una muestra.</p>
	Porcentaje Sensibilidad	$\text{Sensibilidad} = \frac{VP}{VP + FN}$ <p>Donde: VP: Verdaderos Positivos FN: Falsos Negativos</p>
Variable Independiente	Porcentaje Especificidad	$\text{Especificidad} = \frac{VN}{VN + FP}$ <p>Donde: VN: Verdaderos Negativos FP: Falsos Positivos</p>

Figura 11. Métodos, instrumentos y procedimientos de análisis de datos.  
Fuente: propia.

## 2.3. Procedimiento

Acá se describe las fases para desarrollar un sistema de visión de computacional móvil con el objetivo de identificar la calidad de quinua blanca, bajo la plataforma Android en lenguaje Java, haciendo uso de algoritmos y funciones de la biblioteca de OpenCV y TensorFlow. Este proyecto de investigación se desarrolla bajo el ciclo de vida en cascada según indica el autor: “Ian Sommerville”, a través las siguientes fases:

### 2.3.1. Análisis

Para identificar la calidad de la quinua blanca procesada nos basamos en sus características físicas como forma, color y tamaño, tal como lo indica en las especificaciones de la Norma Técnica Peruana 205.062:2009.

Tabla 4  
*Criterios para la clasificación del grano de quinua según su tamaño.*


<b>Tamaño de los granos</b>	<b>Diámetro promedio de los granos, expresado en mm</b>	<b>Malla</b>
Extra grande	mayor a 2,0	85 % retenido en la malla ASTM 10
Grandes	mayor a 1,70 hasta a 2,0	85 % retenido en la malla ASTM 12
Medianos	mayor a 1,40 hasta 1,69	85 % retenido en la malla ASTM 14
Pequeños	menor a 1,40	85 % que pasa por la malla ASTM 14

Nota. Fuente: NTP 205.062.

Tabla 5  
*Criterios para la categorización de los granos de quinua según características físicas.*

Parámetros Sensoriales	Unidad	Categoría 1		Categoría 2		Categoría 3	
		Min	Max	Min	Max	Min	Max
Granos enteros	%	96		90		86	
Granos quebrados	%		1,5		2,0		3,0
Granos inmaduros	%		0,5		0,7		0,9
Impurezas totales	%		0,25		0,30		0,35
Granos contrastantes	%		1,0		2,0		2,5

Nota. Fuente: NTP 205.062.



*Figura 12.* Características físicas consideradas para el análisis basado en la NTP. Donde; a) porcentaje de granos enteros; b) porcentaje de granos quebrados; c) porcentaje de granos inmaduros; d) porcentaje de granos contraste; e) porcentaje de impurezas; f) diámetro promedio de granos enteros.

Fuente: propia.

## Definición de requerimientos

### ✓ Funcionales

- Cargar muestra
- Procesar muestra
- Guardar resultado al procesar muestra
- Mostrar resultado
- Mostrar resultado por fases
- Mostrar historial de resultados
- Buscar Resultados
- Eliminar Resultados

### ✓ No funcionales

- Las interfaces deben ser amigables y sencillas de usar
- No debe depender de una PC
- Debe ser compatible con versiones superiores a Android 4.0.3

### 2.3.2. Diseño

Para determinar los métodos y técnicas en las distintas fases del procesamiento de imagen, se asignó pesos en una escala de 1 al 5, en función a sus características:

Tabla 6  
*Escala de pesos, para sección de técnicas en el procesamiento de imágenes.*

Malo	Regular	Medio	Bueno	Excelente
1	2	3	4	5

Nota. Fuente: propia.



a) Captura

Tabla 7  
*Comparativa para selección de dispositivos de captura.*

Criterios	Dispositivos				
	Samsung Galaxy s9 Plus	LG G5	HTC m9	Huawei P9 Lite	OnePlus One
Resolución	3	4	5	3	3
Apertura de diafragma	5	3	1	2	2
Tamaño sensor / píxel	5	4	2	3	3
Estabilización de imagen	5	3	0	0	2
Memoria Interna	5	4	4	2	5
<b>TOTAL</b>	<b>23</b>	<b>18</b>	<b>12</b>	<b>10</b>	<b>15</b>

Nota. Fuente: propia.

Todos los dispositivos evaluados estuvieron a nuestro alcance, pero el que mejor puntaje obtuvo fue el Samsung Galaxy S9 Plus. Que en la práctica mostró una calidad superior al momento de las capturas en luz natural.

Una vez seleccionado el dispositivo, se tuvieron en cuenta las siguientes características para la captura en un entorno controlado:

- ✓ Para obtener la muestra se adecuó un lienzo con un cuadrado de color rosado con un tamaño establecido en 20cm x 20cm sobre un fondo blanco, distribuyendo los granos de quinua dentro del cuadro sin mantener contacto entre ellos.
- ✓ Iluminación: Luz natural
- ✓ Posición de cámara: Fija, frontal a una altura aproximada de 25cm del objetivo

- ✓ Resolución: 3024x3024
- ✓ Formato de imagen: JPG
- ✓ Modelo de color de la imagen: RGB



Figura 13. Captura de muestra en entorno controlado.  
Fuente: propia

## b) Preprocesamiento

### Técnica de suavizado de imagen

Tabla 8  
*Comparativa de técnicas para suavizado de imagen.*

Características	Promedio	Gaussiano	Mediana
Reducción de ruido	3	3	4
Suavizado	3	4	2
Costo computacional	3	3	3
<b>TOTAL</b>	<b>9</b>	<b>10</b>	<b>9</b>

Nota. Fuente: propia.

La técnica más adecuada para suavizar la imagen es el filtro de paso bajo gaussiano, debido a que es el más eficiente computacionalmente y suaviza mejor la imagen para la segmentación.

### Técnicas de realce de características

Tabla 9  
*Comparativa de técnicas para el realce de características.*

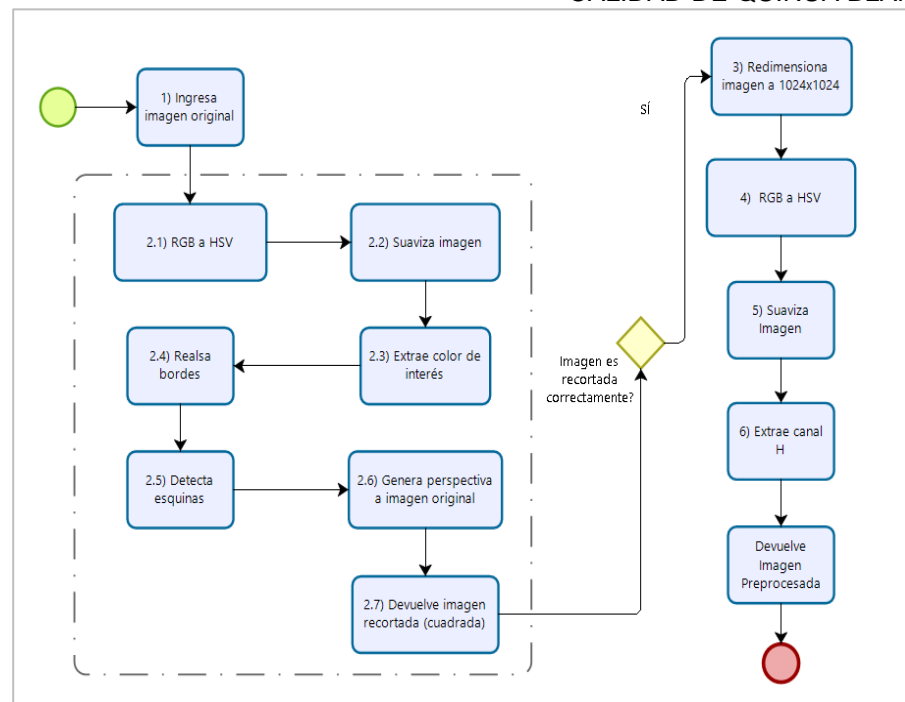
Características	Procesado de Histograma	Acentuado de Bordes	Detección de contornos
Mejor distribución de los niveles de gris	4	3	3
Resalta detalles con precisión	2	3	4
Costo computacional	3	3	4
Óptimo para detectar formas y objetos	2	3	5
Genera menor ruido	4	2	3
<b>TOTAL</b>	<b>15</b>	<b>14</b>	<b>19</b>

Nota. Fuente: propia.

La técnica para el realce de las características que se utiliza es la detección de contornos, el cual nos permite resaltar mejor los detalles externos de los elementos analizados, para lograr esto se aplicó el algoritmo de Canny.

### Técnicas operadores morfológicos

Para la eliminación de ruido interno se utiliza la técnica de operación morfológica “cierre” y para resaltar detalles se utiliza el operador morfológico dilatación.



*Figura 14.* Diagrama de flujo de preprocesamiento.  
Fuente: propia

1. Ingresamos la imagen capturada.
2. Recuperación de perspectiva deseada:
  - 2.1. Se cambia la imagen original de RGB a HSV
  - 2.2. Se aplica el filtro de suavizado de imagen de paso bajo Gaussiano.
  - 2.3. Se extrae los colores de interés distintos al fondo en base al rango de tonos del 0 al 300 en HSV, Seguidamente se elimina el ruido interno con el operador morfológico cierre.
  - 2.4. Se resalta los bordes aplicando el método de Canny más una dilatación.
  - 2.5. Se detecta los contornos y se identifica el contorno cuadrado que nos sirve para encontrar las esquinas.

- 2.6. Se genera la perspectiva recortando la imagen original en RGB en base a sus esquinas.
- 2.7. Devuelve la imagen recortada con el área conocida.
3. Se redimensiona el tamaño de la imagen resultante a 1024x1024, convirtiéndose a partir de este momento en la nueva imagen de análisis.
4. Se cambia el modelo de color de la imagen de RGB a HSV.
5. Se aplica el filtro Gaussiano para suavizar la imagen.
6. Extraemos el canal H (tono), que en un fondo rosa nos permite disminuir la sombra y ruido. Resaltando mejor los elementos para analizarlo en la siguiente fase.



*Figura 15.* Recuperación de perspectiva de la imagen original.  
(a) Imagen original; (b) Imagen recortada

Fuente: propia




Figura 16. Preprocesamiento de imagen.  
(a) Imagen en HSV; (b) Imagen en canal H (tono)

Fuente: propia

### c) Segmentación

#### Técnicas de segmentación

Tabla 10.

*Comparativa de técnicas para segmentación.*

Características	Detección de Bordes	Umbralización	Basado en Regiones
Distingue los cambios en niveles de gris	5	4	4
Costo computacional	3	4	2
Segmentación automática	3	5	2
Sensible al ruido	4	2	3
Adecuado para segmentar objetos de un fondo	3	5	2
<b>TOTAL</b>	<b>18</b>	<b>20</b>	<b>13</b>

Nota. Fuente: propia.

El método de segmentación que mejor se adecúa a nuestro proyecto, es el de “umbralización”, porque nos permite separar los elementos del fondo con mayor facilidad, y además porque tiene un costo computacional menor en comparación a las demás técnicas.

Para separar los elementos del fondo de la imagen resultante de la fase de preprocesamiento, se aplica la técnica “Otsu” de binarización invertida el cual permite calcular el umbral de forma automática. Al resultado se aplica el operador morfológico “Cierre” para la eliminación de los ruidos internos. Teniendo como resultado una imagen como el gráfico 15.




Figura 17. Segmentación de imagen.

(a) Imagen de entrada en canal H; (b) Imagen binarizada con el método Otsu.

Fuente: propia

#### d) Descripción

##### Técnicas de extracción de características

Tabla 11.

Comparativa de técnicas de extracción de características.

Características	Descriptores de contorno	Descriptores de Regiones
Permite calcular métricas en el objeto segmentado	4	4
Permite extraer características externas e internas	3	4
Facilita encontrar las formas de una figura	3	3
<b>TOTAL</b>	<b>10</b>	<b>11</b>

Nota. Fuente: propia.

La técnica que se utiliza en esta fase es los descriptores de regiones el cual nos permite en una imagen binarizada libre de ruido detectar los contornos de todos los elementos para posteriormente extraer características como el área a través de sus píxeles:

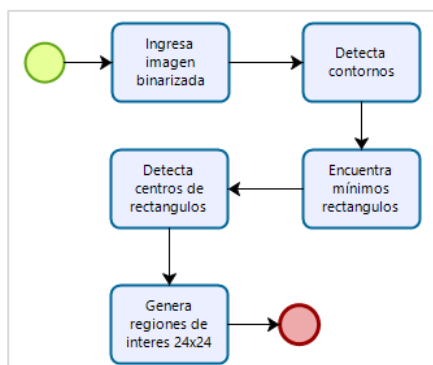


Figura 18. Diagrama de flujo de extracción de características.

Fuente: propia

### Región de interés

Se genera el mínimo rectángulo basado en el contorno de cada elemento, a continuación, se encuentra su centro, y a partir de este se crea una relación de 12 píxeles para los cuatro lados. Asegurando la región de interés de 24x24 píxeles para cada elemento.

Según lo evaluado, un grano de quinua de clase extra grande no supera los 3mm de diámetro promedio, por lo tanto, basándonos en el área de nuestro entorno controlado de 20x20 cm y la dimensión de nuestra imagen 1024x1024 px, determinamos el diámetro equivalente en píxeles:

$$\begin{array}{cc} 3\text{mm} & 200\text{mm} \\ \text{¿?px} & 1024\text{px} \end{array}$$

Con el resultado sabemos que un grano de quinua de clase extragrande no supera los 15.36 píxeles, y siempre estará dentro de la región de interés de



24x24 píxeles. Esta región será necesaria en la fase de reconocimiento para clasificar cada elemento.




Figura 19. Extracción de características.

Donde: (a) Detección de contornos; (b) Mínimo rectángulo basado en el contorno; (c) Región de interés 24x24

Fuente: propia

### e) Reconocimiento

En base a los contornos y la región de interés encontrados en la fase anterior, en esta etapa se clasifica los diferentes tipos de elementos.

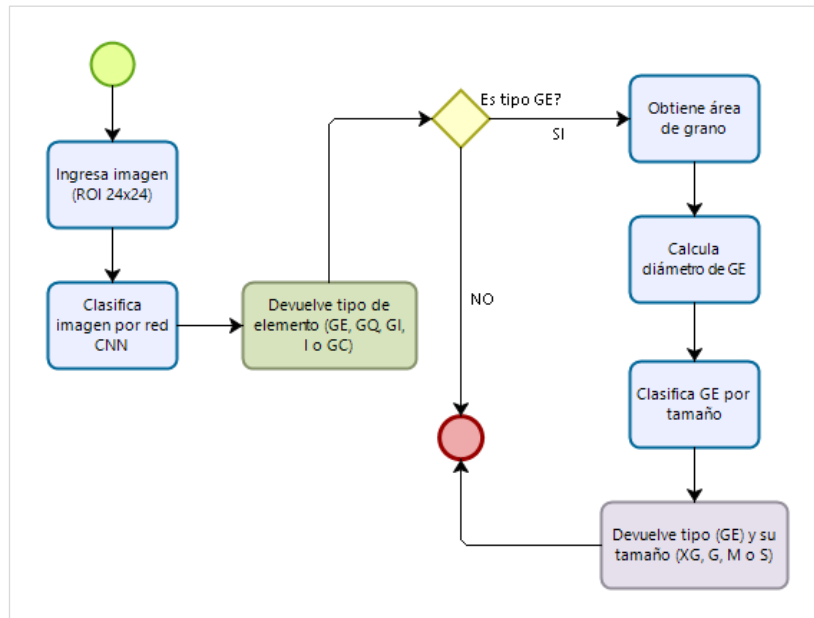


Figura 20. Diagrama de flujo para el reconocimiento de los elementos según su tipo y tamaño.

Dónde: GE (granos enteros); GQ (granos quebrados); GI (granos inmaduros); I (impurezas); GC (granos contraste); XG (granos extragrandes); G (granos grandes); M (granos medianos); S (granos pequeños)

Fuente: propia

### Clasificación de elementos a través de red neural convolucional

Para identificar los diferentes tipos de elementos de una muestra de quinua, se utiliza la técnica de redes neuronales. Específicamente una red neuronal convolucional (CNN). Para su implementación usamos el modelo de CNN pre-entrenado “MobileNet”, haciendo uso de Transfer Learning. Aprovechamos el conocimiento previo para aplicarlo en la clasificación de nuestros elementos (granos de quinua entera, quebrada, contraste, inmaduras y malezas), para lograrlo creamos un dataset con 3000 imágenes con las 5 clases de elementos y reentrenamos la capa de clasificación de la red convolucional.

### Arquitectura de la red convolucional propuesta

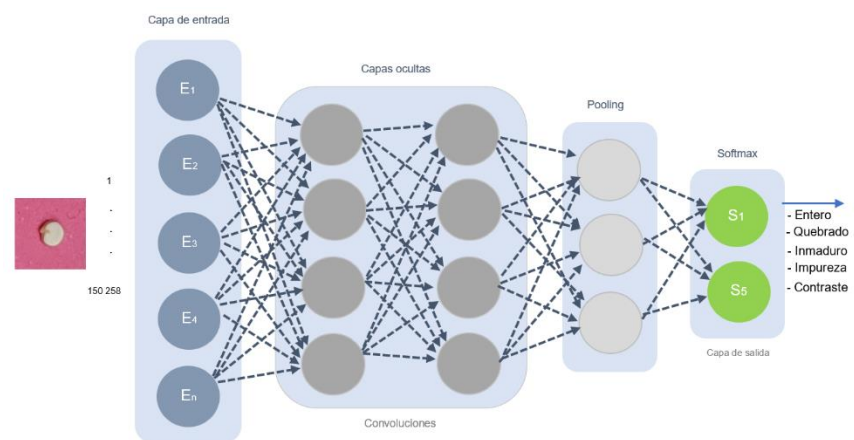


Figura 21. Arquitectura del modelo MobileNet de red CNN para la clasificación de elementos.

Fuente: propia

- ✓ Definimos la entrada con una imagen con un tamaño de 224x224 y una profundidad de 3 (RGB).
- ✓ La capa de entrada recibe la imagen haciendo coincidir cada píxel con una neurona alcanzando 150,528 neuronas.

- ✓ En la primera capa oculta se especifica la convolución regular, a partir de la segunda capa oculta se turnan una convolución profunda y una convolución puntual, reduciendo la resolución y aumentando los canales. Este proceso se repite hasta que la imagen original se reduce a 7x7 con 1024 canales.
- ✓ A continuación, se ejecuta el Pooling promedio para reducir la imagen. quedando 1x1x1024.
- ✓ Finalmente, en la capa de salida se ejecuta la función de activación Softmax que devuelve la probabilidad del tipo de elemento al que pertenece la imagen ingresada.

### **Identificación del tamaño de granos de quinua entera**

Si el elemento clasificado por la red CNN es del tipo de grano entero, se extrae el área en base a su contorno y se calcula su diámetro, usando la fórmula del diámetro de un círculo:

$$D = \sqrt{\frac{4(\text{Area})}{\pi}} \quad \text{Ecuación ( 2 )}$$

Este proceso de clasificación se repite por cada elemento a través de su contorno y región de interés.

### f) Interpretación

Con la información que se obtiene en la fase de reconocimiento: cantidad de elementos identificados según su tipo (granos enteros, granos quebrados, granos inmaduros, impurezas y granos contrastes) y la cantidad de granos en función a su tamaño (extragrandes, grandes, medianos y pequeños). Se interpreta lo siguiente:

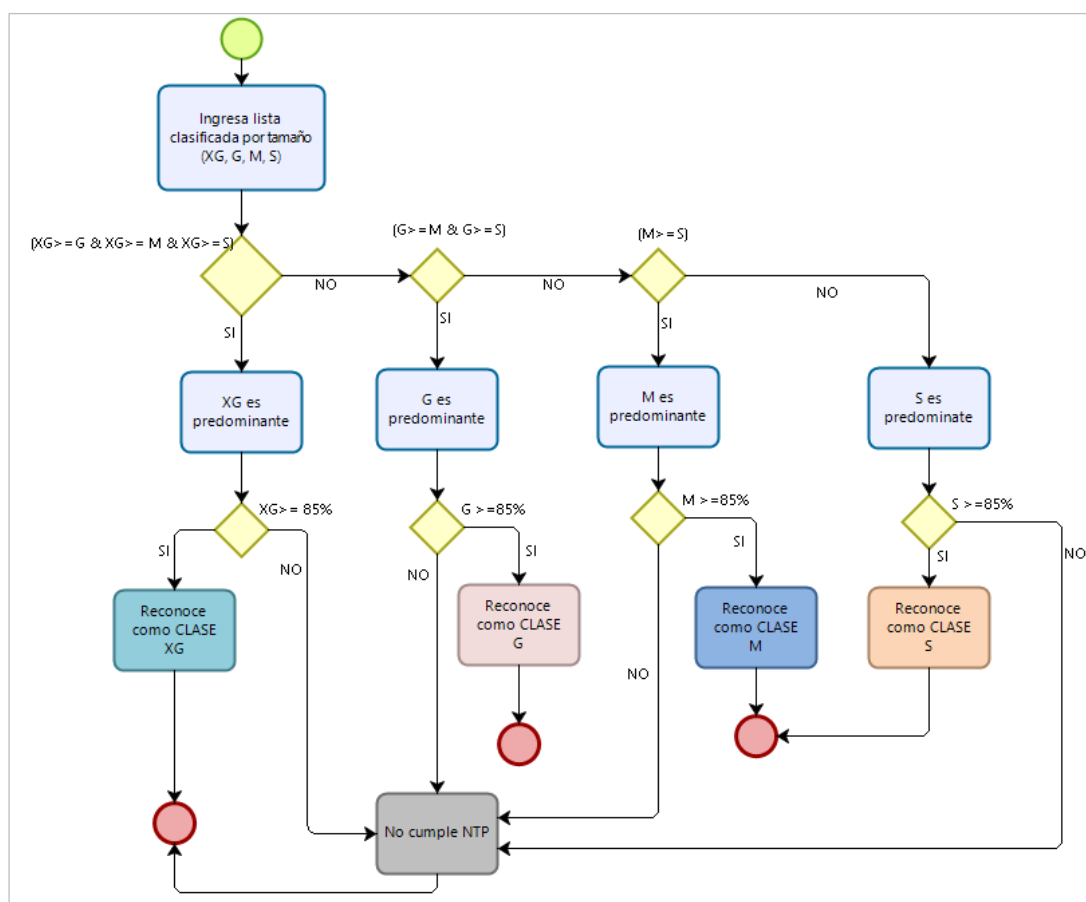
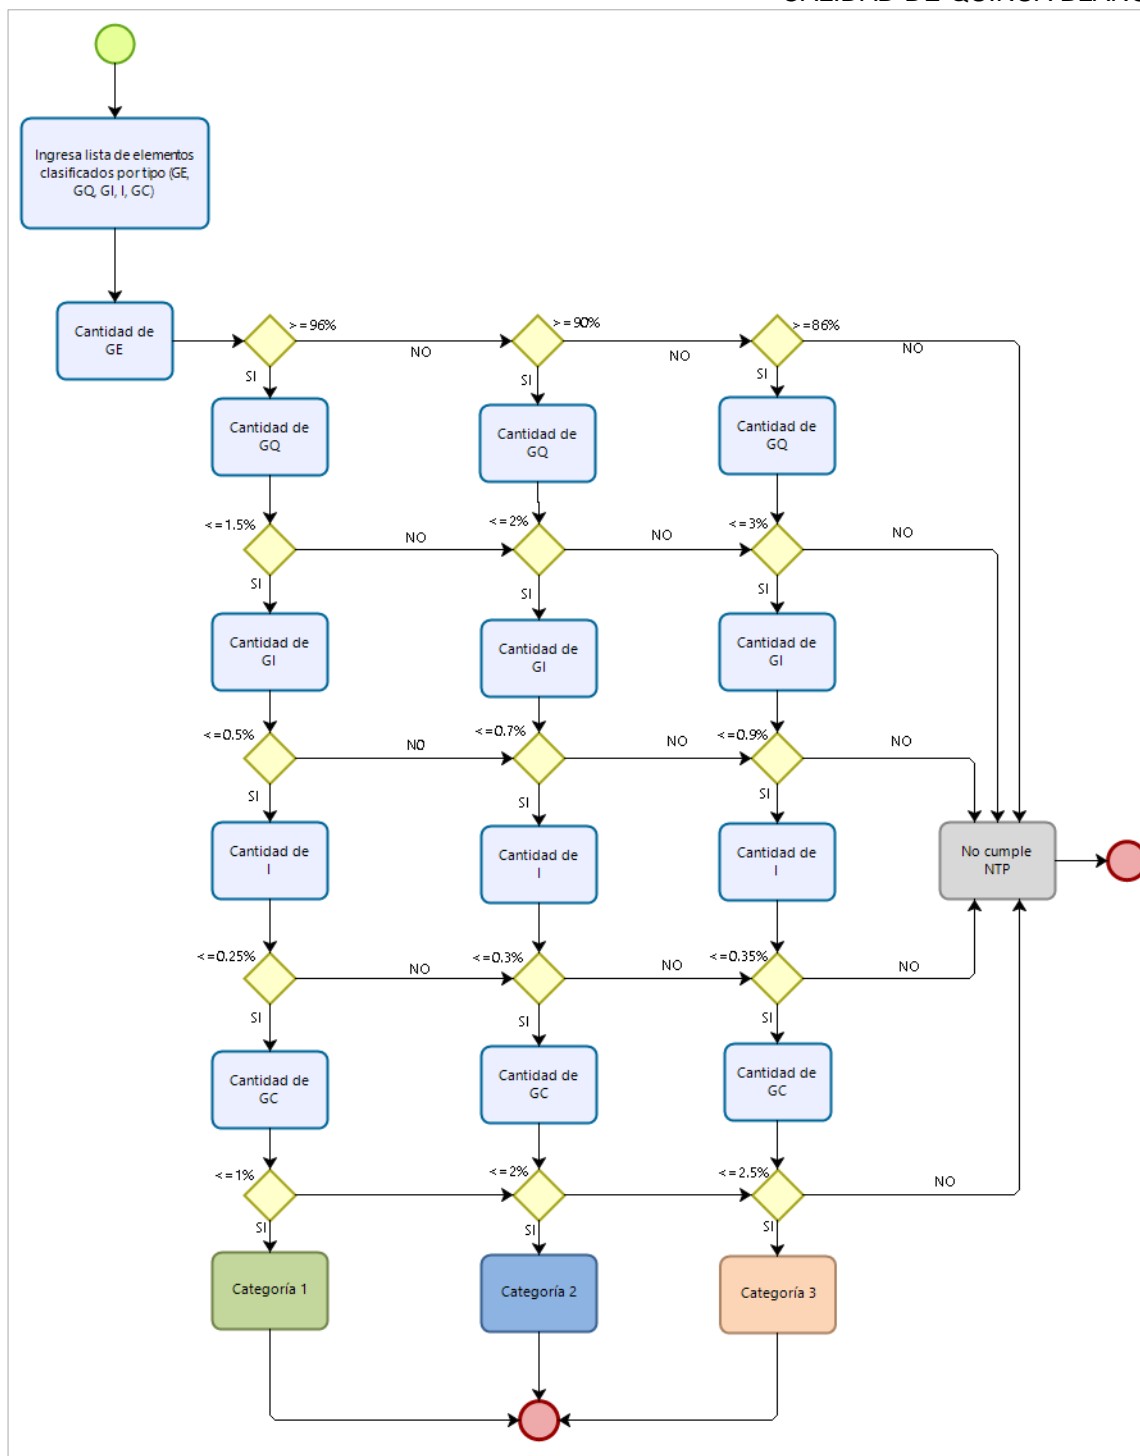


Figura 22. Diagrama de flujo para la interpretación de clase según norma técnica.

Dónde: XG (granos extra grandes); G (granos grandes); M (granos medianos); S (granos pequeños); NO cumple NTP (no alcanza el mínimo porcentaje de la norma técnica peruana “85%”).


Fuente: propia



**Figura 23.** Diagrama de flujo para la interpretación de categoría según norma técnica.

Dónde: cantidad está referido en porcentaje; GE (% de granos enteros); GQ (% de granos quebrados); GI (% de granos inmaduros); I (% de impurezas); GC (% de granos contraste)

Fuente: propia



*Figura 24.* Arquitectura del SVCVM en la identificación de la calidad de quina blanca.

Fuente: propia

### 2.3.3. Implementación

Para la implementación del sistema de visión computacional móvil, se consideró lo siguiente:

#### a) Tecnologías empleadas:

- ✓ IDE: Android Studio 3.1.3
- ✓ Biblioteca: OpenCV 3.4.0
- ✓ Biblioteca: TensorFlow 1.11.0
- ✓ Python 3.7.0

#### b) Funciones principales

##### ✓ Preprocesamiento

```
public Mat preprocesamiento(Mat rgba){
    Mat img = rgba.clone();
    Mat normalQuina = new Mat();

    Imgproc.cvtColor(img, normalQuina, Imgproc.COLOR_RGB2HSV);

    org.opencv.core.Size s = new Size( width: 5, height: 5);
    Imgproc.GaussianBlur(normalQuina, normalQuina, s, sigmaX: 0);

    List<Mat> canal = new ArrayList<>();
    Core.split(normalQuina, canal);

    return canal.get(0);
}
```

*Figura 25.* Función para la aplicación del preprocesamiento de imagen.  
(Se aplica filtro Gaussiano y retorna imagen con el primer canal de HSV).

Fuente: propia

##### ✓ Segmentación

```
Imgproc.threshold(canalH, normalQuina, thresh: 0, maxval: 255, type: Imgproc.THRESH_OTSU + Imgproc.THRESH_BINARY_INV);
Imgproc.morphologyEx(normalQuina, normalQuina, Imgproc.MORPH_CLOSE, new Mat(new Size( width: 3, height: 3), type: 0));
```

*Figura 26.* Método de segmentación de la imagen.  
(Se aplica el método de OpenCV con la técnica de Otsu + el operador morfológico Cierre para eliminar ruido)

Fuente: propia

### ✓ Descripción

```
public List<MatOfPoint> deteccionContornos(Mat rgb, Mat binary){
    mContours = new ArrayList<>();

    Imgproc.findContours(binary, mContours, new Mat(), Imgproc.RETR_TREE, Imgproc.CHAIN_APPROX_SIMPLE);

    for (int i= 0; i< mContours.size(); i++){
        i-= filter(rgb, i);
    }
    return mContours;
}
```

Figura 27. Función que devuelve los contornos de la imagen binarizada.

Fuente: propia

```
public static Rect getROIScaled(MatOfPoint contour, Size size){
    Rect roi = Imgproc.boundingRect(contour);
    double ratio = (roi.width <= 24 && roi.height <= 24)? 12 : 24;
    Point center = new Point( (int) roi.tl().x + roi.width / 2d, (int) roi.tl().y + roi.height / 2d);

    Point tl = new Point( (int) center.x - ratio, (int) center.y - ratio);
    Point br = new Point( (int) center.x + ratio, (int) center.y + ratio);

    if (tl.x < 0){
        br.x += tl.x;
        tl.x = 0; }

    if (tl.y < 0){
        br.y += tl.y;
        tl.y = 0; }

    if (br.x >= size.width){
        tl.x -= (br.x - size.width - 1);
        br.x = size.width - 1; }

    if (br.y >= size.height){
        tl.y -= (br.y - size.height - 1);
        br.y = size.height - 1; }

    return new Rect(tl, br);
}
```

Figura 28. Función que genera la región de interés por cada elemento.

Fuente: propia

### ✓ Reconocimiento

```
public int classidyUsingDNN(Mat rgb){
    Imgproc.resize(rgb, rgb, new Size( width: 224, height: 224));

    Bitmap bmp = Bitmap.createBitmap(rgb.cols(), rgb.rows(),Bitmap.Config.ARGB_8888);
    Utils.matToBitmap(rgb, bmp);

    List<Classifier.Recognition> recognitions = tf.recognizeImage(bmp);

    int label = 4;
    if (recognitions.size() > 0){
        String id = recognitions.get(0).getId().trim();
        if (id == "0")
            label = 0;
        else if (id == "1")
            label = 1;
        else if (id == "2")
            label = 2;
        else if (id == "3")
            label = 3;
        else
            label = 4;
    }

    return label;
}
```

Figura 29. Función que clasifica los elementos por región de interés a través de la red CNN.

Fuente: propia



```
public QuinoaCategory findCategory(List<MatOfPoint> contours, int pos){
    double diameter = 0;
    double area = Imgproc.contourArea(contours[pos]);

    diameter = Math.sqrt(4*area/Math.PI) * 20d / 1024d;

    QuinoaCategory cat = QuinoaCategory.EXTRABIG;
    if (diameter < 0.14d)
        cat = QuinoaCategory.SMALL;
    else if (diameter < 0.17)
        cat = QuinoaCategory.MEDIUM;
    else if (diameter <= 0.20)
        cat = QuinoaCategory.BIG;
    else
        cat = QuinoaCategory.EXTRABIG;
    return cat;
}
```

Figura 30. Función que determina el diámetro de los granos enteros de quinua.  
Fuente: propia

### ✓ Interpretación

(a)	(b)
<pre>if (xg &gt;= g &amp;&amp; xg &gt;= m &amp;&amp; xg &gt;= p){     category = "BLANCA XG";     if(xgf&gt;=85){         clase = "Extra Grande";     } }  else if (g &gt;= m &amp;&amp; g &gt;= p){     category = "BLANCA G";     if(gf&gt;=85){         clase = "Grandes";     } }  else if (m &gt;= p){     category = "BLANCA M";     if(mf&gt;=85){         clase = "Medianos";     } }  else{     category = "BLANCA P";     if(ssf&gt;=85){         clase = "Pequeños";     } }</pre>	<pre>int c1=0,c2=0,c3=0,c4=0; for(int k=0;k&lt;categoria.size();k++) {     if(categoria[k] == "cat1"){         c1+=1;     }else if(categoria[k] == "cat2"){         c2+=1;     }else if(categoria[k] == "cat3"){         c3+=1;     }else if(categoria[k] == "cat4"){         c4+=1;     } }  if(c1==5){     cate="Categoria 1"; }else if(c4&gt;=1){     cate="No cumple NTP"; }else if(c3&gt;=1 &amp; c4&lt;1){     cate="Categoria 3"; }else if(c2&gt;=1 &amp; c4&lt;1 &amp; c3&lt;1){     cate="Categoria 2"; }</pre>

Figura 31. Métodos de interpretación de calidad (clase y categoría).  
(a) Parte del método que determina la clase en función a la NTP; (b)  
Parte del método que determina la categoría en función a la NTP.  
Fuente: propia

### c) Entrenamiento de la Red Neuronal

#### ✓ Selección del modelo

Se utilizó el modelo de red convolucional pre-entrenado “MobileNet\_v1\_0.50\_224”.


#### ✓ Dataset para entrenamiento

Para el entrenamiento de la red, se prepara un conjunto de imágenes con las distintas clases de elementos a identificar (granos de quinua entera, granos de quinua quebrada, granos de quinua contraste, granos inmaduros e impurezas (malezas)).

Se recolecto 3000 imágenes de los 5 tipos de elementos repartidas de la siguiente forma:


- 800 imágenes de clase entera
- 700 imágenes de clase quebrada
- 600 imágenes de clase contraste
- 500 imágenes de clase inmadura
- 400 imágenes de clase malezas

Las imágenes fueron capturadas con una cámara de celular y recortadas a una resolución de 48x48, elemento por elemento.



*Figura 32.* Directorio de clases de entrada para el entrenamiento de la red CNN.

Fuente: propia




*Figura 33.* Imágenes de la clase quinoa entera para entrenamiento de red CNN.

Fuente: propia

### ✓ Entrenamiento de la red

Para entrenar la red, se hizo uso de la biblioteca TensorFlow bajo Python, donde se indica:

- Modelo de red CNN
- Ruta de dataset con imágenes de las clases a entrenar
- Ruta de salida para archivos de entrenamiento



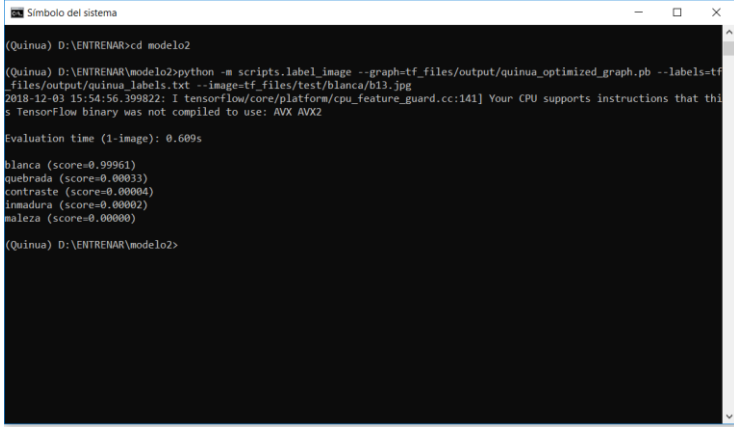
*Figura 34.* Archivos de salida del entrenamiento de la red CNN.

Fuente: propia

- Número de interacciones para el entrenamiento, en nuestro caso se utilizó 1000

### ✓ Prueba de la red

Después de haber entrenado la red se hace las pruebas para evaluar los resultados de la clasificación de los elementos.



```

(Quinoa) D:\ENTRENAR>cd modelo2
(Quinoa) D:\ENTRENAR\modelo2>python -m scripts.label_image --graph=tf_files/output/quinoa_optimized_graph.pb --labels=tf_files/output/quinoa_labels.txt --image=tf_files/test/blanca/bl13.jpg
2018-12-03 15:54:56.399022: I tensorflow/core/platform/cpu_feature_guard.cc:141] Your CPU supports instructions that this TensorFlow binary was not compiled to use: AVX AVX2
Evaluation time (1-image): 0.609s
blanca (score=0.99951)
quebrada (score=0.00033)
contraste (score=0.00004)
inmadura (score=0.00002)
maleza (score=0.00000)
(Quinoa) D:\ENTRENAR\modelo2>

```

Figura 35. Resultado de una prueba después del entrenamiento de la red CNN.

Fuente: propia

### 2.3.4. Pruebas

En esta fase se realizaron pruebas de caja negra, para medir los resultados de nuestra aplicación. A continuación, se detalla algunos ejemplos de pruebas:

#### a) Caso 1

##### ✓ Entrada

Cargamos en el sistema de visión computacional móvil una muestra con el siguiente resultado esperado:

- 10 granos de quinuas extra grandes
- 6 granos de quinua grande
- 5 granos de quinua mediana
- 4 granos de quinua pequeña



✓ **Salida**



MUESTRA	
tamaños 2	
<b>TOTAL ANALIZADOS</b>	<b>25(100%)</b>
<b>GRANOS ENTEROS</b>	<b>25(100.00%)</b>
- EXTRA GRANDES	10(40.00%)
- GRANDES	6(24.00%)
- MEDIANAS	5(20.00%)
- PEQUEÑAS	4(16.00%)
<b>QUEBRADOS</b>	<b>0(0.00%)</b>
<b>INMADUROS</b>	<b>0(0.00%)</b>
<b>TOTAL IMPUREZAS</b>	<b>0(0.00%)</b>
<b>CONTRASTANTES</b>	<b>0(0.00%)</b>

VER DETALLE POR FASES

Figura 36. Resultados obtenidos de prueba por tamaño.


Fuente: propia

b) **Caso 2**

✓ **Entrada**

Cargamos en el sistema de visión computacional móvil una muestra con el siguiente resultado esperado:

- 17 granos enteros
- 3 granos de quinua quebrada
- 2 granos de quinua inmadura
- 2 granos de quinua contraste



✓ **Salida**



Figura 37. Resultados obtenidos de prueba por tipos de elementos.

Fuente: propia

c) **Caso 3**

✓ **Entrada**

Cargamos en el sistema de visión computacional móvil una muestra completa con el siguiente resultado esperado:

Criterios Analizados	Manual según NTP		
	Cantidad	Resultados	
Total de granos analizados	1191.00		
Granos pequeños	1	0.08%	71.43%
Granos medianos	36	3.04%	
Granos grandes	301	25.44%	
Granos extra grandes	845	71.43%	
Granos enteros	1183	99.33%	Categoría 1
Granos quebrados	2	0.17%	Categoría 1
Granos contraste	2	0.17%	Categoría 1
Granos inmaduros	2	0.17%	Categoría 1
Total, impurezas	2	0.17%	Categoría 1
<b>CLASE</b>	<b>No clase</b>		<b>71.43%</b>
<b>CATEGORÍA</b>	<b>Categoría 1</b>		

Figura 38. Resultado esperado de una muestra basado en NTP.

Fuente: propia



✓ Salida



**Resultado**

MUESTRA  
prueba 11

CLASE No cumple NTP

CATEGORÍA Categoría 1

**DETALLE**

TOTAL ANALIZADOS	1191(100%)
<b>GRANOS ENTEROS</b>	<b>1183(99,33%)</b>
- EXTRA GRANDES	820(69,32%)
- GRANDES	316(26,71%)
- MEDIANAS	46(3,89%)
- PEQUEÑAS	1(0,08%)
<b>QUEBRADOS</b>	<b>2(0,17%)</b>
<b>INMADUROS</b>	<b>2(0,17%)</b>
<b>TOTAL IMPUREZAS</b>	<b>2(0,17%)</b>
<b>CONTRASTANTES</b>	<b>2(0,17%)</b>

VER DETALLE POR FASES

Figura 39. Resultados obtenidos de prueba de una muestra basada en la NTP.

Fuente: propia

### CAPÍTULO III. RESULTADOS

La presente investigación tiene como finalidad identificar la calidad de la quinua blanca a través de un sistema de visión computacional móvil (en adelante SVCM) para el análisis de resultados se utilizaron 385 muestras, las cuales se obtuvieron de diferentes tipos de quinua comercial en forma aleatoria, las mismas que fueron evaluadas a través del método manual basado en la norma técnica peruana para esto se hizo uso de una balanza digital y un vernier digital (**Ver Anexo N° 3**).

Para el procesamiento de nuestros resultados utilizamos un análisis basado en cuadros de confusión de múltiples clases, para lo cual tenemos las siguientes consideraciones:

- ✓ **Verdadero Positivo (VP)**. Cuando la clase real es clasificada correctamente por el SVCM.
- ✓ **Falso Negativo (FN)**. Cuando una clase real es clasificada por el SVCM como otra clase.
- ✓ **Falso Positivo (FP)**. Cuando a las clases reales el SVCM las clasifica erróneamente como una clase evaluada.
- ✓ **Verdadero Negativo (VN)**. Cuando las clases distintas a una clase evaluada el SVCM las clasifica como clases distintas a la evaluada.

Leyenda:

**XG** es grano extragrande.

**G** es grano grande.

**M** es grano mediano.

**S** es grano pequeño.

**NN** es no cumple la norma.



		Valor PREDICHO				
		Clase 1	Clase 2	Clase 3	...	Clase n
Valor REAL	Clase 1	<b>X<sub>11</sub></b>	X <sub>12</sub>	X <sub>13</sub>	...	X <sub>1n</sub>
	Clase 2	X <sub>21</sub>	<b>X<sub>22</sub></b>	X <sub>23</sub>	...	X <sub>2n</sub>
	Clase 3	X <sub>31</sub>	X <sub>32</sub>	<b>X<sub>33</sub></b>	...	X <sub>3n</sub>
	.	.	.	.	.	.
	.	.	.	.	.	.
Clase n	X <sub>n1</sub>	X <sub>n2</sub>	X <sub>n3</sub>	...	<b>X<sub>nn</sub></b>	

Figura 40. Matriz de confusión para múltiples clases.

Fuente: propia

$$VP_i = X_{ii}$$

donde  $i$  es la misma fila  
y misma columna

$$FN_i = \sum_{j=1}^n X_{ij} - VP_i$$

donde  $i$  es la fila y  
 $j$  la columna

$$FP_i = \sum_{j=1}^n X_{ji} - VP_i$$

donde  $i$  es la columna  
y  $j$  es la fila

Ecuación ( 3 )

$$VN_i = \sum_{j=1}^n \sum_{k=1}^n X_{jk} - VP_i - FN_i - FP_i$$

donde  $i$  es cualquier fila  
y columna,  $j$  es fila y  
 $k$  es columna

### Resultados de la predicción de las clases de quinua:

		Sistema de visión computacional móvil				
		XG	G	M	S	NN
Norma Técnica	XG	<b>201</b>	0	0	0	0
	G	0	<b>4</b>	0	0	3
	M	0	0	<b>2</b>	0	0
	S	0	0	0	<b>5</b>	5
	NN	0	2	0	5	<b>158</b>

Figura 41. Matriz de confusión múltiple del análisis por clase.

Fuente: propia.

Clases	Resultados			
	VP	FN	FP	VN
<b>XG</b>	201	0	0	184
<b>G</b>	4	3	2	376
<b>M</b>	2	0	0	383
<b>S</b>	5	5	5	370
<b>NN</b>	158	7	8	212

Figura 42. Resultado de matriz de confusión múltiple por cada clase.

Fuente: propia.

### Resultados de la predicción de las categorías de quinua:

		Sistema de visión computacional móvil			
		1	2	3	NN
Norma Técnica	1	334	4	1	0
	2	0	4	0	1
	3	0	0	5	4
	NN	0	0	0	32

Figura 43. Matriz de confusión múltiple del análisis por categoría.

Fuente: propia.

Categorías	Resultados			
	VP	FN	FP	VN
<b>1</b>	334	5	0	46
<b>2</b>	4	1	4	376
<b>3</b>	5	4	1	375
<b>NN</b>	32	0	5	348

Figura 44. Resultado de matriz de confusión múltiple por cada categoría.

Fuente: propia.

#### 5.1. Indicador 1: Porcentaje de eficacia

Consiste en la cantidad de muestras que fueron reconocidos correctamente por el SVCM.

$$\text{Eficacia} = \frac{T}{N} \times 100$$

Ecuación ( 4 )

Para nuestra investigación se evalúan dos aspectos:

- ✓ De un total de 385 muestras evaluadas por el SVCM se ha obtenido 370 resultados correctos (VP) en la predicción de clases, alcanzando una eficacia de:

$$\text{Eficacia SVCM (clase)} = \frac{370}{385} \times 100 = 96.10\%$$

- ✓ Por otro lado, de un total de 385 muestras al usar el SVCM para determinar la categoría obtuvimos 373 resultados correctos (VP) en predicción de categorías, alcanzando una eficacia:

$$\text{Eficacia SVCM (categoría)} = \frac{373}{385} \times 100 = 96.88\%$$

Obtenemos la eficacia total del SVCM aplicando la media aritmética a ambas eficacias:

$$\text{Eficacia Total} = \frac{\text{Eficacia (clase)} + \text{Eficacia (categoría)}}{2} \quad \text{Ecuación ( 5 )}$$

$$\text{Eficacia SVCM Total} = \frac{96.10 + 96.88}{2} = 96.49\%$$

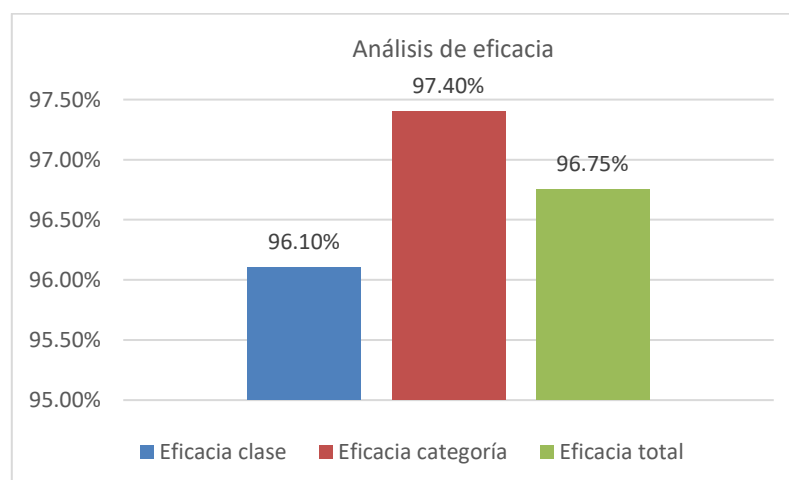


Figura 45. Análisis de eficacia.

Fuente: propia.

## 5.2. Indicador 2: Porcentaje de sensibilidad

La sensibilidad consiste en la probabilidad de que el SVCM determine correctamente la clase y la categoría de los granos de quinua.

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad \text{Ecuación ( 6 )}$$

Para nuestra investigación se evalúan dos aspectos:

- ✓ La sensibilidad obtenida para la predicción en cada clase por el SVCM

es:

Tabla 12

*Resultado de análisis de sensibilidad para cada clase.*

Clases	VP	FN	Sensibilidad
<b>XG</b>	201	0	100.00%
<b>G</b>	4	3	57.14%
<b>M</b>	2	0	100.00%
<b>S</b>	5	5	50.00%
<b>NN</b>	158	7	95.76%

Nota. Fuente: propia.

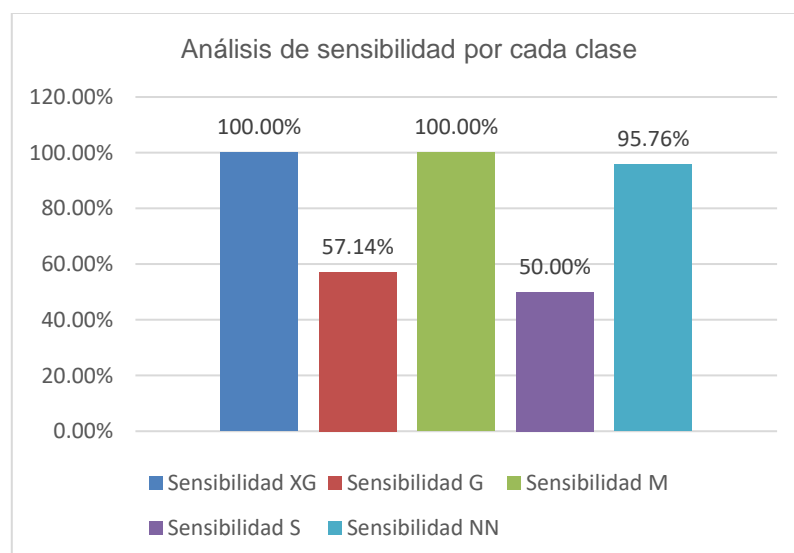


Figura 46. Resultados de sensibilidad por cada clase.

Fuente: propia

$$\text{Sensibilidad SVCM (clase)} = \frac{100 + 57.14 + 100 + 50 + 95.76}{5} = 80.58\%$$

- ✓ La sensibilidad obtenida para la predicción en cada categoría por el SVCM es:

Tabla 13  
*Resultado de análisis de sensibilidad para cada categoría.*

Categorías	VP	FN	Sensibilidad
1	334	5	98.53%
2	4	1	80.00%
3	5	4	55.56%
NN	32	0	100.00%

Nota. Fuente: propia.




Figura 47. Resultados de sensibilidad por cada categoría.

Fuente: propia.

$$\text{Sensibilidad SVCM (categoría)} = \frac{98.53 + 80 + 55.56 + 100}{4} = 83.52\%$$

Obtenemos la sensibilidad total del SVCM aplicando la media aritmética a ambas sensibilidades:

$$\text{Sens Total} = \frac{\text{Sens (clase)} + \text{Sens (categoría)}}{2} \quad \text{Ecuación ( 7 )}$$

$$\text{Sensibilidad SVCM Total} = \frac{80.58 + 83.52}{2} = 82.05\%$$




Figura 48. Análisis de sensibilidad.

Fuente: propia.

### 5.3. Indicador 3: Porcentaje de especificidad

La especificidad es el porcentaje que el SVCM prediga un elemento distinto al evaluado como tal.

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad \text{Ecuación ( 8 )}$$

Para nuestra investigación se evalúan dos aspectos:

- ✓ La especificidad obtenida para la predicción en cada clase por el SVCM es:

Tabla 14

Resultado de análisis de especificidad por cada clase.

Clases	VN	FP	Especificidad
XG	184	0	100.00%
G	376	2	99.47%
M	383	0	100.00%
S	370	5	98.67%
NN	212	8	96.36%

Nota. Fuente: propia.




Figura 49. Resultados de especificidad por cada clase.

Fuente: propia.

$$\text{Especificidad SVCM (clase)} = \frac{100 + 99.47 + 100 + 98.67 + 96.36}{5} = 98.90\%$$

- ✓ La especificidad obtenida para la predicción en cada categoría por el SVCM es:

Tabla 15

Resultado de análisis de especificidad por cada categoría.

Categorías	VN	FP	Especificidad
1	46	0	100.00%
2	376	4	98.95%
3	375	1	99.73%
NN	348	5	98.58%

Nota. Fuente: propia.




Figura 50. Resultados de especificidad por cada categoría.

Fuente: propia.

$$\text{Especificidad SVCM (categoría)} = \frac{100 + 98.95 + 99.73 + 98.58}{4} = 99.32\%$$

Obtenemos la especificidad total del SVCM aplicando la media aritmética a ambas especificidades:

$$\text{Espec Total} = \frac{\text{Espec (clase)} + \text{Espec (categoría)}}{2} \quad \text{Ecuación ( 9 )}$$

$$\text{Especificidad SVCM Total} = \frac{98.90 + 99.32}{2} = 99.11\%$$




Figura 51. Análisis de especificidad.

Fuente: propia



## CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES

### 4.1 Discusión

En la presente investigación podemos afirmar que nuestro sistema de visión computacional móvil ha alcanzado un nivel de eficacia del 96.75%, una sensibilidad de 82.05% y una especificidad de 99.11%. No obstante, los resultados que se alcanzaron con muestras de quinua blanca procesada fueron obtenidos bajo un entorno controlado. Para el análisis se consideró solo las características físicas de los granos como forma, color y tamaño especificados en la norma técnica peruana.

El hallazgo en el indicador de eficacia es ligeramente superior en más de 1% respecto al antecedente sobre la “clasificación de variedades de semilla de trigo usando visión por computadora” de los autores (Redolfi, *et al.*, 2016), esto se pudo deber a que en dicha investigación utilizaron una red neuronal convolucional basada en “AlexNet” que tiene menor exactitud en la clasificación a diferencia del modelo “MobileNet”, además dicho antecedente utilizó solo 315 imágenes para el entrenamiento de su red CNN.

El resultado del SVCM desarrollado alcanza una sensibilidad de 82.05%, el cual es inferior en 11.40% respecto al antecedente sobre “Software automático de reconocimiento de patrones para la discriminación de granos de arroz pulido basado en procesamiento de imágenes” del autor Palomino (2014), esto se pudo deber a que dicho antecedente evaluó como experimento solo una muestra de 215 granos de arroz para la discriminación en función a su clase y tipo, siendo este grano aproximadamente 4 veces más grande que una quinua, además para la captura usaron

como entorno controlado un escáner el cual brinda una iluminación constante. Por lo que se sugiere para futuros trabajos hacer la adquisición de la muestra en un entorno con iluminación constante.

Respecto al análisis de especificidad, logramos alcanzar 99.11%, superando en 8.20% al antecedente sobre “procesamiento de imágenes para la clasificación de granos de café verde”, de los autores Arias y Sierra (2016) donde obtuvieron una especificidad de 90.91% esto se pudo deber a que dicha investigación tuvo que clasificar entre 10 variedades de granos basados en distintas características de color, forma y broca. Por lo que tuvieron que implementar algoritmos de clasificación para cada escenario con resultados dispersos.

En los resultados para la clase extra grande se tiene una sensibilidad de 100%, mientras que para la clase pequeña 50%, esto debido a que los granos pequeños en la clasificación por la red CNN son en algunos casos confundidos por granos del tipo inmaduro ya que comparten características similares como el tamaño, además estos granos en el espacio muestral tienden a estar más pegados lo que dificulta su segmentación para el análisis de tamaño. Esta variación ocurre además por el tipo de muestra, ya que en algunas muestras las clases o categorías tienen tendencia a pertenecer a otra, es decir están cercanas al rango límite, por ejemplo en las muestras de categoría 3 que alcanzó solo una sensibilidad de 55.56%, que con mínimas variaciones toma otra clase o categoría como se puede observar en la (tabla 12 y 13). Para futuros trabajos se sugiere investigar técnicas que permitan mejorar la segmentación en granos pegados y/o sobrepuestos.

## 4.2 Conclusiones

Se logró determinar la influencia que tiene un sistema de visión computacional móvil en la identificación de la calidad de quinua blanca, mediante las técnicas y algoritmos de procesamiento de imagen.

Se logró desarrollar un sistema de visión computacional móvil que permite identificar la calidad de quinua blanca con un nivel de eficacia de 96.75%.

Se logró desarrollar un sistema de visión computacional móvil que permite identificar la calidad de quinua blanca con un nivel de sensibilidad de 82.05% este objetivo no pudo ser alcanzado, debido a que la red CNN confunde en algunos casos los granos pequeños con inmaduros, además en el espacio muestral por la cantidad de granos son difícil de separar, lo que complica su medición.

Se logró desarrollar un sistema de visión computacional móvil que permite identificar la calidad de quinua blanca a un nivel de especificidad de 99.11%.

Gracias a los avances tecnológicos para los dispositivos móviles, en la actualidad se puede asegurar que es posible implementar sistemas robustos que permitan solucionar problemas aplicando visión computacional en esta plataforma.

Para problemas de clasificación múltiple en base a normas o estándares de calidad, es necesario utilizar muestras proporcionales de los distintos tipos o clases.

## REFERENCIAS

- Aguilera, G. (2011). Procesamiento de Imágenes (Tema 2). *Investigación*, 8.
- Alesanco, R. S. (2018). *Aplicación de redes neuronales convolucionales y recurrentes al diagnóstico de autismo a partir de resonancias magnéticas funcionales*. Madrid: Tesis.
- Andrew G. Howard, W. W., Menglong Zhu, T. W., Bo Chen, M. A., & Dmitry Kalenichenko, H. A. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision*. EE.UU: Paper, Pag.19.
- Apaza Quispe, Z. P. (2015). *Propuesta de diseño del sistema de costos por proceso para el sector agro industrial*. Juliaca.
- Arias Marta, M. A., & Sierra Ruiz, J. A. (2016). *Procesamiento de Imágenes para la Clasificación de Café Verde*. Bogotá: Pontificia Universidad Javeriana.
- Beleño, K., Gualdrón, O. E., Medina, S. M., & Herrera, J. C. (2016). *Diseño de un sistema automático de selección de frutos de café mediante técnicas de visión artificial*. Bucaramanga - Colombia: Universidad Industrial de Santander.
- Carlos Quintero, F. M. (2018). *Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo*. ESTEC, Panama.
- Control Union Perú (Agente Certificador). (2014). *Especificación Técnicas - Quinua Orgánica. ET-QUINUA(ESP)*, 9.
- Déniz, Ó. (2007). *Programación de apps de visión artificial*. España: Editorial Bubok Publishing S.L.
- Estruch, C. P. (2016). *Emotions Recognition using Deep Learning*. España: Tesis.
- Fairlie Reinoso, A. (2016). *La quinua en el Perú cadena exportadora y políticas de gestión ambiental*. INTE-PUCP.
- FAO. (2013). *Catálogo de variedades comerciales de quinua en el Perú. FAO en el Perú*.
- García Santillán, I. D. (2008). *Visión Artificial y Procesamiento Digital de Imágenes usando Matlab*. Ibarra - Ecuador.
- García, P. P. (2013). *Reconocimiento de imágenes utilizando redes neuronales artificiales*. España: Tesis.
- Gómez Trejos, D., & Guerrero Guzmán, A. (2016). *Estudio y análisis de técnicas para procesamiento digital de imágenes*. Colombia: Trabajo de Investigación.
- Gutiérrez, E. A., & Antolín, J. C. (2003). *Procesamiento digital de imagen: fundamentos y prácticas con Matlab*. (Vol. 10). España: Libro Grande.
- León, N. (2007). *Descubre por qué el Tamaño (del Sensor) sí Importa*. Obtenido de <https://www.dzoom.org.es/descubre-por-que-en-fotografia-el-tamano-del-sensor-si-importa/>
- Marca Vilca, S., Chaucha Jove, W., Quispe Quispe, J. C., & Mamani Centón, V. (2011). *Comportamiento actual de los agentes de la cadena productiva de quinua en la región Puno. Proyecto, Desarrollo de capacidades de la cadena productiva de quinua en la Región Puno*.
- Matlab. (s.f.). *Deep Learning Redes Neuronales Convolucionales*. Obtenido de <https://es.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>

- MINAGRI. (2017). *Boletín Perfil técnico N° 2 La quinua producción y comercio del Perú*. MINAGRI.
- Ochoa, C. (2015). *Elementos de la cámara*. Argentina: Trabajo de Investigación.
- Palomino Cáceres, J. (2014). software automático de reconocimiento de patrones para la discriminación de granos de arroz pulido basado en procesamiento digital de imágenes. *Trabajo de Investigación*, 9.
- Redolfi, J., González, D., Pucheta, J., & Canali, L. (2016). *Clasificación de Variedades de Semillas de Trigo Usando Visión por Computadora*. Córdoba - Argentina.
- Rosano, F. L. (1996). *Fundamentos de redes neuronales artificiales*. México, Facultad de Ingeniería, UNAM: Trabajo de Investigación.
- Santamaría, B. A. (2002). *Realce de Imágenes: Filtrado espacial*. Argentina: revista de Teledetección.
- Shapiro, L., & Stockman, G. (2000). *Computer Vision*. New Jersey: Prentice-Hall.
- Tapia Pinto, J. W. (2014). *Análisis y Diseño de Un Sistema Computarizado para la Interpretación Colorimétrica y Morfométrica del Chenopodium*. Puno: Universidad Nacional del Altiplano.
- Tensorflow. (2017). *GitHub*. Obtenido de GitHub:  
[https://github.com/tensorflow/models/blob/master/research/slim/nets/mobilenet\\_v1.md](https://github.com/tensorflow/models/blob/master/research/slim/nets/mobilenet_v1.md)
- Tensorflow. (2018). *www.tensorflow.org*. Obtenido de  
[https://www.tensorflow.org/hub/tutorials/image\\_retraining](https://www.tensorflow.org/hub/tutorials/image_retraining)
- Ventre, F. R., Sampallo, G. M., & Cleva, M. S. (2016). Control de la calidad de granos para dispositivos móviles empleando. 8.
- Viera Maza, G. (2017). *Procesamiento de Imágenes Usando OpenCV Aplicado en Raspberry Pi para la Clasificación del Cacao*. Piura: Universidad de Piura.
- Wang, A. G. (2017). *Tensorflow*. Obtenido de <https://www.tensorflow.org/lite/overview>
- Zaragoza, O. E. (2018). *Desarrollo de una red neuronal convolucional para el procesamiento de imágenes placentaria*. México: Tesis.

**ANEXOS**

**ANEXO n.º 01**  
**Tablas de resultados**

**A. Tabla 1: comparativa de resultados para el análisis de clase**

Leyenda:

**XG:** cantidad predominante granos extra grandes

**G:** cantidad predominante granos grandes

**M:** cantidad predominante granos medianos

**S:** cantidad predominante granos pequeños

# Muestra	NORMA TÉCNICA				APLICACIÓN SVCM			
	Elementos Analizados	Tamaño predominant e %		Clase	Elementos Analizados	Tamaño predominant e %		Clase
1	1058	XG	92.05	Extra grande	1058	XG	97.73	Extra grande
2	1188	XG	75.46	No tiene clase	1186	XG	78.9	No tiene clase
3	1218	XG	75.97	No tiene clase	1211	XG	66.42	No tiene clase
4	1062	XG	92.05	Extra grande	1062	XG	98.58	Extra grande
5	1059	XG	92.05	Extra grande	1059	XG	93.86	Extra grande
6	1099	XG	91.53	Extra grande	1099	XG	93.62	Extra grande
7	1067	XG	94.28	Extra grande	1065	XG	95.68	Extra grande
8	1121	XG	91.23	Extra grande	1121	XG	92.66	Extra grande
9	1103	XG	91.55	Extra grande	1102	XG	94.64	Extra grande
10	1354	S	84.05	No tiene clase	1354	S	85.53	Pequeños

11	1189	XG	75.46	No tiene clase	1186	XG	69	No tiene clase
12	1186	XG	75.46	No tiene clase	1182	XG	74.01	No tiene clase
13	1218	XG	75.97	No tiene clase	1213	XG	69.82	No tiene clase
14	1067	XG	92.05	Extra grande	1067	XG	98.58	Extra grande
15	1061	XG	92.05	Extra grande	1061	XG	93.66	Extra grande
16	1248	XG	66.8	No tiene clase	1243	XG	67.1	No tiene clase
17	1069	XG	94.1	Extra grande	1068	XG	98.12	Extra grande
18	1182	G	85.21	Grande	1182	G	86.92	Grande
19	1399	S	85.96	Pequeños	1399	S	84.1	No tiene clase
20	1395	S	85.91	Pequeños	1395	S	83.86	No tiene clase
21	1088	XG	76.31	No tiene clase	1086	XG	70.69	No tiene clase
22	1344	S	85.25	Pequeños	1184	S	80.08	No tiene clase
23	1188	XG	75.46	No tiene clase	1186	XG	68.63	No tiene clase
24	1058	XG	92.05	Extra grande	1058	XG	98.11	Extra grande
25	1063	XG	92.05	Extra grande	1063	XG	92.82	Extra grande
26	1249	XG	66.8	No tiene clase	1240	XG	65.99	No tiene clase
27	1081	XG	93.06	Extra grande	1079	XG	98.42	Extra grande
28	1121	XG	91.23	Extra grande	1121	XG	90.86	Extra grande

29	1103	XG	91.55	Extra grande	1103	XG	91.92	Extra grande
30	1063	XG	92.05	Extra grande	1063	XG	92.53	Extra grande
31	1191	XG	75.46	No tiene clase	1189	XG	78.97	No tiene clase
32	1186	XG	75.46	No tiene clase	1183	XG	75.06	No tiene clase
33	1218	XG	75.97	No tiene clase	1210	XG	72.21	No tiene clase
34	1072	XG	92.05	Extra grande	1072	XG	93.85	Extra grande
35	1065	XG	92.05	Extra grande	1065	XG	93.29	Extra grande
36	1249	XG	66.8	No tiene clase	1242	XG	69.44	No tiene clase
37	1069	XG	94.11	Extra grande	1067	XG	99.53	Extra grande
38	1185	G	85.21	Grande	1185	G	76.6	No tiene clase
39	1394	S	85.56	Pequeños	1394	S	85.16	Pequeños
40	1065	XG	92.05	Extra grande	1065	XG	93.57	Extra grande
41	1188	XG	75.46	No tiene clase	1185	XG	68.33	No tiene clase
42	1202	XG	74.35	No tiene clase	1197	XG	70.38	No tiene clase
43	1218	XG	75.97	No tiene clase	1210	XG	72.33	No tiene clase
44	1148	XG	55.4	No tiene clase	1147	XG	51.62	No tiene clase
45	1058	XG	92.05	Extra grande	1058	XG	98.2	Extra grande
46	1060	XG	92.31	Extra grande	1060	XG	94.4	Extra grande



47	1069	XG	94.28	Extra grande	1067	XG	99.91	Extra grande
48	1121	XG	91.23	Extra grande	1121	XG	93.29	Extra grande
49	1101	XG	91.55	Extra grande	1101	XG	93.55	Extra grande
50	1391	S	85.76	Pequeños	1391	S	78.02	No tiene clase
51	1193	XG	75.46	No tiene clase	1191	XG	78.97	No tiene clase
52	1202	XG	74.35	No tiene clase	1199	XG	71.56	No tiene clase
53	1211	XG	75.97	No tiene clase	1201	XG	67.25	No tiene clase
54	1057	XG	92.05	Extra grande	1057	XG	98.11	Extra grande
55	1060	XG	92.31	Extra grande	1059	XG	96.44	Extra grande
56	1249	XG	66.8	No tiene clase	1247	XG	66.96	No tiene clase
57	1069	XG	94.28	Extra grande	1068	XG	99.81	Extra grande
58	1195	G	85.34	Grande	1195	G	86.19	Grande
59	1101	XG	91.55	Extra grande	1101	XG	94.28	Extra grande
60	1096	XG	91.69	Extra grande	1096	XG	94.43	Extra grande
61	1188	XG	75.46	No tiene clase	1186	XG	74.83	No tiene clase
62	1202	XG	74.35	No tiene clase	1197	XG	71.91	No tiene clase
63	1215	XG	75.97	No tiene clase	1213	XG	67.58	No tiene clase
64	1057	XG	92.05	Extra grande	1057	XG	98.3	Extra grande

65	1069	XG	92.31	Extra grande	1069	XG	94.8	Extra grande
66	1249	XG	66.8	No tiene clase	1247	XG	65.75	No tiene clase
67	1069	XG	94.28	Extra grande	1066	XG	100	Extra grande
68	1121	XG	91.23	Extra grande	1121	XG	92.93	Extra grande
69	1103	XG	91.55	Extra grande	1103	XG	92.65	Extra grande
70	1099	XG	91.53	Extra grande	1099	XG	92.71	Extra grande
71	1196	XG	75.46	No tiene clase	1194	XG	78.97	No tiene clase
72	1203	XG	74.35	No tiene clase	1201	XG	72.6	No tiene clase
73	1215	XG	75.97	No tiene clase	1214	XG	70.66	No tiene clase
74	1057	XG	92.05	Extra grande	1057	XG	98.58	Extra grande
75	1056	XG	92.31	Extra grande	1056	XG	98.39	Extra grande
76	1249	XG	66.8	No tiene clase	1247	XG	66.18	No tiene clase
77	1069	XG	94.28	Extra grande	1068	XG	99.81	Extra grande
78	1165	G	84.66	No tiene clase	1165	G	87.18	Grande
79	1390	S	85.14	Pequeños	1103	S	84.9	No tiene clase
80	1349	S	84.99	No tiene clase	1349	S	85.47	Pequeños
81	1187	XG	75.46	No tiene clase	1187	XG	73.27	No tiene clase
82	1203	XG	74.35	No tiene clase	1200	XG	73.16	No tiene clase

83	1215	XG	75.9	No tiene clase	1214	XG	69.46	No tiene clase
84	1057	XG	92.05	Extra grande	1057	XG	98.68	Extra grande
85	1054	XG	92.31	Extra grande	1054	XG	97.53	Extra grande
86	1249	XG	66.8	No tiene clase	1246	XG	66.16	No tiene clase
87	1069	XG	94.28	Extra grande	1068	XG	99.91	Extra grande
88	1121	XG	91.23	Extra grande	1121	XG	92.48	Extra grande
89	1103	XG	91.55	Extra grande	1103	XG	96	Extra grande
90	1361	S	84.17	No tiene clase	1361	S	85.25	Pequeños
91	1195	XG	75.46	No tiene clase	1192	XG	69.34	No tiene clase
92	1203	XG	74.35	No tiene clase	1201	XG	70.87	No tiene clase
93	1215	XG	75.97	No tiene clase	1214	XG	75.37	No tiene clase
94	1057	XG	92.05	Extra grande	1057	XG	98.58	Extra grande
95	1054	XG	92.31	Extra grande	1054	XG	95.92	Extra grande
96	1248	XG	66.8	No tiene clase	1247	XG	67.42	No tiene clase
97	1069	XG	94.28	Extra grande	1067	XG	99.91	Extra grande
98	1162	G	84.45	No tiene clase	1162	G	87.14	Grande
99	1103	XG	91.55	Extra grande	1103	XG	96	Extra grande
100	1189	XG	75.46	No tiene clase	1188	XG	76.46	No tiene clase

101	1194	XG	75.46	No tiene clase	1193	XG	70.1	No tiene clase
102	1203	XG	74.35	No tiene clase	1203	XG	70.53	No tiene clase
103	1215	XG	75.97	No tiene clase	1213	XG	70.2	No tiene clase
104	1057	XG	92.05	Extra grande	1057	XG	97.82	Extra grande
105	1198	XG	75.46	No tiene clase	1196	XG	78.97	No tiene clase
106	1248	XG	66.8	No tiene clase	1245	XG	66.8	No tiene clase
107	1069	XG	94.28	Extra grande	1068	XG	99.91	Extra grande
108	1123	XG	91.23	Extra grande	1123	XG	95.26	Extra grande
109	1115	XG	91.64	Extra grande	1115	XG	93.71	Extra grande
110	1189	XG	75.46	No tiene clase	1188	XG	69.68	No tiene clase
111	1194	XG	75.46	No tiene clase	1193	XG	70.04	No tiene clase
112	1203	XG	74.35	No tiene clase	1201	XG	70.53	No tiene clase
113	1215	XG	75.97	No tiene clase	1213	XG	66.25	No tiene clase
114	1058	XG	92.05	Extra grande	1058	XG	98.58	Extra grande
115	1201	XG	75.46	No tiene clase	1199	XG	78.97	No tiene clase
116	1248	XG	66.8	No tiene clase	1247	XG	67.47	No tiene clase
117	1069	XG	94.28	Extra grande	1068	XG	99.91	Extra grande
118	1123	XG	91.23	Extra grande	1123	XG	94.99	Extra grande

119	1115	XG	91.64	Extra grande	1115	XG	94.15	Extra grande
120	1189	XG	75.46	No tiene clase	1187	XG	68.58	No tiene clase
121	1194	XG	75.46	No tiene clase	1192	XG	70.9	No tiene clase
122	1203	XG	74.35	No tiene clase	1202	XG	70.98	No tiene clase
123	1216	XG	75.97	No tiene clase	1213	XG	66.72	No tiene clase
124	1065	XG	92.05	Extra grande	1065	XG	93.38	Extra grande
125	1197	XG	75.46	No tiene clase	1196	XG	78.97	No tiene clase
126	1248	XG	66.8	No tiene clase	1245	XG	66.91	No tiene clase
127	1069	XG	94.28	Extra grande	1067	XG	99.91	Extra grande
128	1124	XG	91.23	Extra grande	1124	XG	95.61	Extra grande
129	1115	XG	91.64	Extra grande	1115	XG	93.79	Extra grande
130	1198	XG	75.46	No tiene clase	1196	XG	78.97	No tiene clase
131	1194	XG	75.46	No tiene clase	1194	XG	70.74	No tiene clase
132	1203	XG	74.35	No tiene clase	1202	XG	71.27	No tiene clase
133	1216	XG	75.97	No tiene clase	1215	XG	72.54	No tiene clase
134	1058	XG	92.05	Extra grande	1058	XG	99.05	Extra grande
135	1054	XG	92.31	Extra grande	1054	XG	98.58	Extra grande
136	1248	XG	66.8	No tiene clase	1245	XG	69.01	No tiene clase

137	1069	XG	94.28	Extra grande	1068	XG	99.91	Extra grande
138	1125	XG	91.23	Extra grande	1125	XG	95.79	Extra grande
139	1112	XG	91.64	Extra grande	1112	XG	93.17	Extra grande
140	1201	XG	75.46	No tiene clase	1199	XG	78.13	No tiene clase
141	1194	XG	75.46	No tiene clase	1192	XG	75.06	No tiene clase
142	1203	XG	74.35	No tiene clase	1200	XG	70.7	No tiene clase
143	1216	XG	75.97	No tiene clase	1215	XG	69.89	No tiene clase
144	1070	XG	92.05	Extra grande	1070	XG	95.27	Extra grande
145	1121	XG	91.17	Extra grande	1121	XG	92.95	Extra grande
146	1248	XG	66.8	No tiene clase	1247	XG	71.23	No tiene clase
147	1069	XG	94.28	No tiene clase	1068	XG	97.65	No tiene clase
148	1125	XG	91.23	Extra grande	1125	XG	95.79	Extra grande
149	1112	XG	91.64	Extra grande	1112	XG	94.06	Extra grande
150	1189	XG	75.46	No tiene clase	1187	XG	70.86	No tiene clase
151	1195	XG	75.46	No tiene clase	1193	XG	75.17	No tiene clase
152	1203	XG	74.35	No tiene clase	1201	XG	70.53	No tiene clase
153	1216	XG	75.97	No tiene clase	1214	XG	72.33	No tiene clase
154	1058	XG	92.05	Extra grande	1058	XG	92.50	Extra grande

155	1293	M	85.02	Medianos	1293	M	87.16	Medianos
156	1248	XG	66.8	No tiene clase	1247	XG	70.75	No tiene clase
157	1069	XG	94.28	Extra grande	1068	XG	98.22	Extra grande
158	1122	XG	91.23	Extra grande	1122	XG	95.52	Extra grande
159	1115	XG	91.64	Extra grande	1115	XG	94.07	Extra grande
160	1099	XG	91.53	Extra grande	1099	XG	93.62	Extra grande
161	1194	XG	75.46	No tiene clase	1192	XG	79.7	No tiene clase
162	1203	XG	74.35	No tiene clase	1202	XG	69.71	No tiene clase
163	1216	XG	75.97	No tiene clase	1213	XG	71.89	No tiene clase
164	1080	XG	92.05	Extra grande	1080	XG	89.79	Extra grande
165	1120	XG	91.16	Extra grande	1120	XG	94.11	Extra grande
166	1248	XG	66.8	No tiene clase	1247	XG	70.1	No tiene clase
167	1069	XG	94.11	Extra grande	1067	XG	98.87	Extra grande
168	1122	XG	91.23	Extra grande	1122	XG	95.52	Extra grande
169	1115	XG	91.64	Extra grande	1115	XG	94.07	Extra grande
170	1098	XG	91.53	Extra grande	1098	XG	92.62	Extra grande
171	1194	XG	75.46	No tiene clase	1193	XG	80	No tiene clase
172	1201	XG	74.35	No tiene clase	1200	XG	70.73	No tiene clase

173	1216	XG	75.97	No tiene clase	1214	XG	66.64	No tiene clase
174	1058	XG	92.05	Extra grande	1058	XG	95.74	Extra grande
175	1120	XG	91.16	Extra grande	1120	XG	93.21	Extra grande
176	1244	XG	66.8	No tiene clase	1243	XG	66.75	No tiene clase
177	1069	XG	94.11	Extra grande	1068	XG	99.16	Extra grande
178	1114	XG	91.2	Extra grande	1114	XG	97.4	Extra grande
179	1115	XG	91.64	Extra grande	1115	XG	94.07	Extra grande
180	1098	XG	91.53	Extra grande	1098	XG	92.9	Extra grande
181	1194	XG	75.46	No tiene clase	1192	XG	75.59	No tiene clase
182	1201	XG	74.35	No tiene clase	1199	XG	72.2	No tiene clase
183	1216	XG	75.97	No tiene clase	1215	XG	69.15	No tiene clase
184	1085	XG	92.05	Extra grande	1084	XG	89.21	Extra grande
185	1119	XG	91.15	Extra grande	1119	XG	94.01	Extra grande
186	1244	XG	66.8	No tiene clase	1242	XG	68.52	No tiene clase
187	1069	XG	94.28	Extra grande	1067	XG	98.78	Extra grande
188	1114	XG	91.2	Extra grande	1114	XG	96.68	Extra grande
189	1115	XG	91.64	Extra grande	1115	XG	94.07	Extra grande
190	1367	S	83.92	No tiene clase	1367	S	85.22	Pequeños



191	1188	XG	75.46	No tiene clase	1186	XG	68.24	No tiene clase
192	1201	XG	74.35	No tiene clase	1200	XG	70.58	No tiene clase
193	1211	XG	75.97	No tiene clase	1209	XG	70.86	No tiene clase
194	1058	XG	92.05	Extra grande	1058	XG	94.98	Extra grande
195	1119	XG	91.15	Extra grande	1119	XG	92.67	Extra grande
196	1244	XG	66.8	No tiene clase	1243	XG	70.45	No tiene clase
197	1069	XG	94.28	Extra grande	1067	XG	98.69	Extra grande
198	1114	XG	91.2	Extra grande	1114	XG	96.32	Extra grande
199	1116	XG	91.64	Extra grande	1116	XG	94.96	Extra grande
200	1218	XG	77.62	No tiene clase	1210	XG	73.88	No tiene clase
201	1188	XG	75.46	No tiene clase	1184	XG	67.85	No tiene clase
202	1201	XG	74.35	No tiene clase	1195	XG	72.30	No tiene clase
203	1211	XG	73.49	No tiene clase	1207	XG	68.13	No tiene clase
204	1072	XG	92.05	Extra grande	1072	XG	87.46	Extra grande
205	1118	XG	91.23	Extra grande	1118	XG	92.93	Extra grande
206	1244	XG	66.80	No tiene clase	1238	XG	69.36	No tiene clase
207	1069	XG	94.28	Extra grande	1067	XG	98.31	Extra grande
208	1114	XG	91.20	Extra grande	1114	XG	91.20	Extra grande

209	1116	XG	91.64	Extra grande	1116	XG	95.59	Extra grande
210	1058	XG	92.05	Extra grande	1058	XG	96.59	Extra grande
211	1206	XG	75.46	No tiene clase	1206	XG	75.59	No tiene clase
212	1201	XG	74.35	No tiene clase	1194	XG	70.64	No tiene clase
213	1211	XG	72.01	No tiene clase	1207	XG	67.50	No tiene clase
214	1117	XG	91.23	Extra grande	1114	XG	93.26	Extra grande
215	1118	XG	91.23	Extra grande	1118	XG	92.31	Extra grande
216	1244	XG	66.80	No tiene clase	1238	XG	66.83	No tiene clase
217	1069	XG	94.28	Extra grande	1067	XG	97.28	Extra grande
218	1114	XG	91.20	Extra grande	1114	XG	96.59	Extra grande
219	1116	XG	91.64	Extra grande	1116	XG	95.41	Extra grande
220	1099	XG	91.53	Extra grande	1099	XG	94.26	Extra grande
221	1211	XG	75.46	No tiene clase	1211	XG	75.66	No tiene clase
222	1201	XG	74.35	No tiene clase	1195	XG	69.47	No tiene clase
223	1216	XG	75.46	No tiene clase	1216	XG	75.59	No tiene clase
224	1067	XG	92.05	Extra grande	1066	XG	87.49	Extra grande
225	1063	XG	92.05	Extra grande	1063	XG	92.82	Extra grande
226	1249	XG	66.80	No tiene clase	1240	XG	65.99	No tiene clase

227	1081	XG	93.06	Extra grande	1079	XG	98.42	Extra grande
228	1121	XG	91.23	Extra grande	1121	XG	90.86	Extra grande
229	1103	XG	91.55	Extra grande	1103	XG	91.92	Extra grande
230	1063	XG	92.05	Extra grande	1063	XG	92.53	Extra grande
231	1189	XG	75.46	No tiene clase	1184	XG	67.06	No tiene clase
232	1201	XG	74.35	No tiene clase	1196	XG	69.04	No tiene clase
233	1211	XG	68.70	No tiene clase	1209	XG	64.79	No tiene clase
234	1067	XG	91.19	Extra grande	1065	XG	95.11	Extra grande
235	1117	XG	91.23	Extra grande	1117	XG	93.19	Extra grande
236	1213	XG	68.89	No tiene clase	1200	XG	74.71	No tiene clase
237	1069	XG	94.28	Extra grande	1065	XG	98.97	Extra grande
238	1114	XG	91.20	Extra grande	1114	XG	96.50	Extra grande
239	1116	XG	91.64	Extra grande	1116	XG	94.33	Extra grande
240	1160	G	85.96	Grande	1160	G	87.63	Grande
241	1221	XG	75.46	No tiene clase	1221	XG	75.51	No tiene clase
242	1213	XG	75.97	No tiene clase	1204	XG	69.13	No tiene clase
243	1211	XG	73.58	No tiene clase	1208	XG	61.00	No tiene clase
244	1067	XG	91.19	Extra grande	1066	XG	93.99	Extra grande

245	1091	XG	91.65	Extra grande	1091	XG	93.12	Extra grande
246	1213	XG	68.89	No tiene clase	1200	XG	73.12	No tiene clase
247	1069	XG	94.28	Extra grande	1056	XG	94.50	Extra grande
248	1114	XG	91.20	Extra grande	1114	XG	96.86	Extra grande
249	1116	XG	91.64	Extra grande	1116	XG	94.69	Extra grande
250	1098	XG	91.52	Extra grande	1098	XG	93.53	Extra grande
251	1226	XG	75.46	No tiene clase	1226	XG	75.44	No tiene clase
252	1214	XG	75.97	No tiene clase	1206	XG	73.04	No tiene clase
253	1211	XG	75.97	No tiene clase	1209	XG	71.91	No tiene clase
254	1067	XG	91.19	Extra grande	1065	XG	95.11	Extra grande
255	1091	XG	91.65	Extra grande	1091	XG	92.75	Extra grande
256	1213	XG	68.89	No tiene clase	1206	XG	74.34	No tiene clase
257	1069	XG	94.28	Extra grande	1066	XG	99.25	Extra grande
258	1114	XG	91.20	Extra grande	1114	XG	96.77	Extra grande
259	1116	XG	91.64	Extra grande	1116	XG	94.78	Extra grande
260	1099	XG	91.52	Extra grande	1099	XG	92.98	Extra grande
261	1188	XG	75.46	No tiene clase	1185	XG	73.27	No tiene clase
262	1214	XG	75.97	No tiene clase	1207	XG	71.52	No tiene clase

263	1211	XG	75.97	No tiene clase	1210	XG	72.48	No tiene clase
264	1069	XG	91.19	Extra grande	1069	XG	94.93	Extra grande
265	1091	XG	91.65	Extra grande	1091	XG	93.03	Extra grande
266	1213	XG	68.89	No tiene clase	1210	XG	74.65	No tiene clase
267	1114	XG	91.65	Extra grande	1114	XG	93.18	Extra grande
268	1057	XG	92.05	Extra grande	1057	XG	95.74	Extra grande
269	1116	XG	91.64	Extra grande	1116	XG	95.42	Extra grande
270	1168	G	85.20	Grande	1099	G	82.88	No tiene clase
271	1188	XG	75.46	No tiene clase	1184	XG	72.14	No tiene clase
272	1218	XG	75.97	No tiene clase	1212	XG	67.94	No tiene clase
273	1211	XG	75.97	No tiene clase	1204	XG	67.52	No tiene clase
274	1069	XG	91.19	Extra grande	1069	XG	94.29	Extra grande
275	1091	XG	91.65	Extra grande	1090	XG	91.74	Extra grande
276	1212	XG	68.89	No tiene clase	1205	XG	70.41	No tiene clase
277	1114	XG	91.65	Extra grande	1114	XG	93.81	Extra grande
278	1124	XG	91.23	Extra grande	1124	XG	96.33	Extra grande
279	1116	XG	91.64	Extra grande	1116	XG	95.42	Extra grande
280	1211	XG	75.46	No tiene clase	1211	XG	75.38	No tiene clase

281	1188	XG	75.46	No tiene clase	1186	XG	72.53	No tiene clase
282	1218	XG	75.97	No tiene clase	1213	XG	70.37	No tiene clase
283	1211	XG	74.32	No tiene clase	1209	XG	69.26	No tiene clase
284	1071	XG	91.19	Extra grande	1071	XG	96.81	Extra grande
285	1090	XG	91.65	Extra grande	1090	XG	92.11	Extra grande
286	1212	XG	68.89	No tiene clase	1205	XG	76.00	No tiene clase
287	1116	XG	91.49	Extra grande	1116	XG	93.37	Extra grande
288	1091	XG	91.65	Extra grande	1091	XG	92.67	Extra grande
289	1124	XG	91.23	Extra grande	1124	XG	93.37	Extra grande
290	1057	XG	92.05	Extra grande	1057	XG	97.26	Extra grande
291	1206	XG	75.46	No tiene clase	1206	XG	72.85	No tiene clase
292	1218	XG	75.97	No tiene clase	1213	XG	70.90	No tiene clase
293	1211	XG	75.97	No tiene clase	1209	XG	66.58	No tiene clase
294	1075	XG	91.19	Extra grande	1075	XG	95.31	Extra grande
295	1090	XG	91.65	Extra grande	1090	XG	91.28	Extra grande
296	1212	XG	68.89	No tiene clase	1208	XG	74.15	No tiene clase
297	1116	XG	91.49	Extra grande	1116	XG	94.00	Extra grande
298	1091	XG	91.65	Extra grande	1091	XG	93.30	Extra grande

299	1188	XG	75.46	No tiene clase	1188	XG	75.46	No tiene clase
300	1114	XG	91.20	Extra grande	1114	XG	97.49	Extra grande
301	1398	S	85.13	Pequeños	1398	S	86.1	Pequeños
302	1218	XG	75.97	No tiene clase	1217	XG	70.8	No tiene clase
303	1211	XG	75.97	No tiene clase	1208	XG	67.63	No tiene clase
304	1070	XG	91.62	Extra grande	1070	XG	94.26	Extra grande
305	1096	XG	91.69	Extra grande	1096	XG	94.34	Extra grande
306	1216	XG	75.97	No tiene clase	1215	XG	68.51	No tiene clase
307	1118	XG	91.32	Extra grande	1118	XG	94.36	Extra grande
308	1091	XG	91.65	Extra grande	1091	XG	92.94	Extra grande
309	1116	XG	91.64	Extra grande	1116	XG	92.18	Extra grande
310	1248	XG	66.8	No tiene clase	1246	XG	67.04	No tiene clase
311	1186	XG	75.46	No tiene clase	1185	XG	71.56	No tiene clase
312	1218	XG	75.97	No tiene clase	1216	XG	65.37	No tiene clase
313	1211	XG	75.97	No tiene clase	1209	XG	70.75	No tiene clase
314	1068	XG	91.62	Extra grande	1068	XG	95.86	Extra grande
315	1096	XG	91.69	Extra grande	1096	XG	94.34	Extra grande
316	1124	XG	91.23	Extra grande	1124	XG	95.43	Extra grande

317	1118	XG	91.32	Extra grande	1118	XG	94.28	Extra grande
318	1091	XG	91.65	Extra grande	1091	XG	93.49	Extra grande
319	1300	M	85.1	Medianos	1300	M	87.85	Medianos
320	1115	XG	91.64	Extra grande	1115	XG	93.44	Extra grande
321	1385	S	85.76	Pequeños	1385	S	85.3	Pequeños
322	1218	XG	75.97	No tiene clase	1217	XG	71.84	No tiene clase
323	1211	XG	75.97	No tiene clase	1209	XG	67.19	No tiene clase
324	1066	XG	91.62	Extra grande	1066	XG	95.58	Extra grande
325	1096	XG	91.69	Extra grande	1096	XG	93.97	Extra grande
326	1091	XG	91.65	Extra grande	1091	XG	93.49	Extra grande
327	1120	XG	91.34	Extra grande	1120	XG	93.39	Extra grande
328	1097	XG	91.52	Extra grande	1097	XG	93.07	Extra grande
329	1058	XG	92.05	Extra grande	1058	XG	96.31	Extra grande
330	1057	XG	92.05	Extra grande	1057	XG	95.74	Extra grande
331	1186	XG	75.46	No tiene clase	1183	XG	65.65	No tiene clase
332	1218	XG	75.97	No tiene clase	1216	XG	66.03	No tiene clase
333	1211	XG	75.97	No tiene clase	1210	XG	70.78	No tiene clase
334	1066	XG	91.62	Extra grande	1066	XG	94.36	Extra grande



335	1096	XG	91.69	Extra grande	1096	XG	93.97	Extra grande
336	1123	XG	91.23	Extra grande	1123	XG	91.59	Extra grande
337	1120	XG	91.34	Extra grande	1120	XG	93.48	Extra grande
338	1097	XG	91.52	Extra grande	1097	XG	93.07	Extra grande
339	1115	XG	91.64	Extra grande	1115	XG	94.07	Extra grande
340	1054	XG	92.31	Extra grande	1054	XG	95.64	Extra grande
341	1186	XG	75.46	No tiene clase	1185	XG	70.21	No tiene clase
342	1218	XG	75.97	No tiene clase	1215	XG	68.19	No tiene clase
343	1211	XG	75.97	No tiene clase	1208	XG	71.48	No tiene clase
344	1064	XG	91.62	Extra grande	1064	XG	95.67	Extra grande
345	1095	XG	91.69	Extra grande	1095	XG	94.25	Extra grande
346	1114	XG	91.65	Extra grande	1114	XG	92.28	Extra grande
347	1122	XG	91.18	Extra grande	1122	XG	94.47	Extra grande
348	1099	XG	91.52	Extra grande	1099	XG	92.53	Extra grande
349	1248	XG	66.8	No tiene clase	1245	XG	70.32	No tiene clase
350	1091	XG	91.65	Extra grande	1091	XG	93.3	Extra grande
351	1387	S	85.78	Pequeños	1387	S	85	Pequeños
352	1218	XG	75.97	No tiene clase	1215	XG	70.61	No tiene clase

353	1058	XG	92.05	Extra grande	1058	XG	98.86	Extra grande
354	1057	XG	92.05	Extra grande	1057	XG	93.95	Extra grande
355	1095	XG	91.69	Extra grande	1095	XG	94.25	Extra grande
356	1069	XG	94.28	Extra grande	1068	XG	97	Extra grande
357	1122	XG	91.18	Extra grande	1122	XG	93.58	Extra grande
358	1205	G	85.58	Grande	1205	G	86.95	Grande
359	1148	XG	55.4	No tiene clase	1146	XG	52.19	No tiene clase
360	1194	XG	75.46	No tiene clase	1191	XG	71.74	No tiene clase
361	1186	XG	75.46	Extra grande	1184	XG	67.48	Extra grande
362	1218	XG	75.97	No tiene clase	1216	XG	69.17	No tiene clase
363	1077	XG	92.05	Extra grande	1076	XG	90.51	Extra grande
364	1057	XG	92.05	Extra grande	1057	XG	94.8	Extra grande
365	1096	XG	91.69	Extra grande	1096	XG	93.79	Extra grande
366	1188	XG	75.46	No tiene clase	1187	XG	74.16	No tiene clase
367	1121	XG	91.23	Extra grande	1121	XG	92.3	Extra grande
368	1099	XG	91.52	Extra grande	1099	XG	94.07	Extra grande
369	1244	XG	66.8	No tiene clase	1242	XG	69.14	No tiene clase
370	1201	XG	74.35	No tiene clase	1199	XG	72.2	No tiene clase

371	1248	XG	66.8	No tiene clase	1245	XG	67.53	No tiene clase
372	1248	XG	66.8	No tiene clase	1245	XG	67.53	No tiene clase
373	1218	XG	75.97	No tiene clase	1212	XG	67.16	No tiene clase
374	1058	XG	92.05	Extra grande	1058	XG	98.49	Extra grande
375	1057	XG	92.05	Extra grande	1057	XG	95.18	Extra grande
376	1188	XG	75.46	No tiene clase	1187	XG	74.09	No tiene clase
377	1347	S	84.49	No tiene clase	1347	S	87.36	Pequeños
378	1205	G	85.21	Grande	1205	G	81.05	No tiene clase
379	1057	XG	92.05	Extra grande	1057	XG	96.22	Extra grande
380	1114	XG	91.2	Extra grande	1114	XG	95.06	Extra grande
381	1389	S	85.81	Pequeños	1389	S	85.17	Pequeños
382	1218	XG	75.97	No tiene clase	1215	XG	74.21	No tiene clase
383	1080	XG	92.05	Extra grande	1079	XG	91.28	Extra grande
384	1059	XG	92.05	Extra grande	1059	XG	94.52	Extra grande
385	1096	XG	91.69	Extra grande	1096	XG	93.79	Extra grande

**B. Tabla 2: comparativa de resultados para el análisis de categoría**

Leyenda:

**#M:** Número de muestra

**EA:** Cantidad de elementos analizados

**GE:** Granos enteros

**GQ:** Granos quebrados

**GI:** Granos inmaduros

**I:** Impurezas

**GC:** Granos contrastantes

**CA:** Categoría

0, no pertenece a una categoría

1, categoría 1

2, categoría 2

3, categoría 3

# M	NORMA TÉCNICA							APLICACIÓN SVCM						
	EA	GE	GQ	GI	I	GC	CA	EA	GE	GQ	GI	I	GC	CA
1	1058	99.91	0.00	0.09	0.00	0.00	1	1058	99.81	0.00	0.19	0.00	0.00	1
2	1188	99.83	0.00	0.00	0.17	0.00	1	1186	99.83	0.00	0.00	0.17	0.00	1
3	1218	99.43	0.00	0.00	0.25	0.33	1	1211	99.34	0.00	0.08	0.25	0.33	1
4	1062	99.53	0.00	0.00	0.47	0.00	1	1062	99.53	0.00	0.00	0.47	0.00	1
5	1059	99.81	0.19	0.00	0.00	0.00	1	1059	99.91	0.09	0.00	0.00	0.00	1
6	1099	99.91	0.00	0.00	0.00	0.09	1	1099	99.91	0.00	0.00	0.00	0.09	1
7	1067	100	0.00	0.00	0.00	0.00	1	1065	100	0.00	0.00	0.00	0.00	1
8	1121	99.64	0.09	0.09	0.09	0.09	1	1121	99.64	0.09	0.09	0.09	0.09	1
9	1103	99.82	0.00	0.00	0.00	0.18	1	1102	99.91	0.00	0.00	0.00	0.09	1
10	1354	98.15	0.37	0.89	0.37	0.22	0	1354	98.15	0.52	0.89	0.37	0.22	0
11	1189	99.75	0.17	0.00	0.00	0.00	1	1186	99.83	0.17	0.00	0.00	0.00	1
12	1186	100	0.00	0.00	0.00	0.00	1	1182	99.92	0.00	0.08	0.00	0.00	1
13	1218	99.83	0.00	0.00	0.25	0.33	1	1213	99.43	0.00	0.00	0.25	0.33	1
14	1067	99.06	0.00	0.00	0.94	0.00	1	1067	99.06	0.00	0.00	0.94	0.00	1

**SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA**

15	1061	99.62	0.19	0.00	0.00	0.19	1	1061	99.62	0.19	0.00	0.00	0.19	1
16	1248	99.68	0.00	0.00	0.00	0.32	1	1243	99.52	0.00	0.16	0.00	0.32	1
17	1069	99.81	0.00	0.00	0.00	0.19	1	1068	99.81	0.00	0.00	0.00	0.19	1
18	1182	98.98	0.00	1.02	0.00	0.00	0	1182	98.98	0.00	1.02	0.00	0.00	0
19	1399	99.29	0.00	0.71	0.00	0.00	3	1399	98.93	0.00	1.07	0.00	0.00	0
20	1395	99.21	0.00	0.72	0.07	0.00	3	1395	99.07	0.00	0.86	0.07	0.00	3
21	1088	99.83	0.17	0.00	0.00	0.00	1	1086	99.83	0.17	0.00	0.00	0.00	1
22	1344	98.36	0.37	0.97	0.07	0.22	0	1184	98.21	0.52	0.97	0.07	0.22	0
23	1188	99.83	0.00	0.00	0.17	0.00	1	1186	99.83	0.00	0.00	0.17	0.00	1
24	1058	99.91	0.00	0.00	0.00	0.09	1	1058	99.91	0.00	0.00	0.00	0.09	1
25	1063	99.44	0.19	0.19	0.00	0.19	1	1063	99.53	0.09	0.19	0.00	0.19	1
26	1249	99.60	0.00	0.00	0.08	0.32	1	1240	99.60	0.00	0.00	0.08	0.32	1
27	1081	98.70	0.19	0.00	0.74	0.37	0	1079	98.80	0.19	0.09	0.64	0.28	0
28	1121	99.64	0.09	0.09	0.09	0.09	1	1121	99.55	0.18	0.09	0.09	0.09	1
29	1103	99.82	0.00	0.00	0.18	0.00	1	1103	99.82	0.00	0.00	0.18	0.00	1
30	1063	99.44	0.19	0.19	0.00	0.19	1	1063	99.44	0.19	0.19	0.00	0.19	1
31	1191	99.58	0.00	0.00	0.42	0.00	0	1189	99.58	0.00	0.00	0.42	0.00	0
32	1186	100.0 0	0.00	0.00	0.00	0.00	1	1183	100.0 0	0.00	0.00	0.00	0.00	1
33	1218	99.43	0.00	0.00	0.25	0.33	1	1210	99.34	0.08	0.00	0.25	0.33	1
34	1072	98.60	0.00	0.00	1.40	0.00	1	1072	98.60	0.00	0.00	1.40	0.00	1
35	1065	99.25	0.19	0.19	0.19	0.19	1	1065	99.34	0.09	0.19	0.19	0.19	1
36	1249	99.60	0.00	0.00	0.08	0.32	1	1242	99.60	0.00	0.00	0.08	0.32	1
37	1069	99.81	0.19	0.00	0.00	0.00	1	1067	99.81	0.19	0.00	0.00	0.00	1
38	1185	98.73	0.00	0.84	0.42	0.00	0	1185	98.82	0.00	0.76	0.42	0.00	0
39	1394	99.35	0.00	0.65	0.00	0.00	2	1394	98.64	0.00	1.36	0.00	0.00	0
40	1065	99.25	0.19	0.19	0.19	0.19	1	1065	99.25	0.19	0.19	0.19	0.19	1
41	1188	99.83	0.17	0.00	0.00	0.00	1	1185	99.92	0.08	0.00	0.00	0.00	1
42	1202	99.92	0.00	0.00	0.08	0.00	1	1197	99.84	0.08	0.00	0.08	0.00	1
43	1218	99.42	0.00	0.00	0.25	0.33	1	1210	99.42	0.00	0.00	0.25	0.33	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

44	1148	100.0 0	0.00	0.00	0.00	0.00	1	1147	99.83	0.00	0.17	0.00	0.00	1
45	1058	99.91	0.00	0.00	0.00	0.09	1	1058	99.91	0.00	0.00	0.00	0.09	1
46	1060	99.43	0.19	0.19	0.00	0.19	1	1060	99.43	0.19	0.19	0.00	0.19	1
47	1069	99.81	0.19	0.00	0.00	0.00	1	1067	99.81	0.19	0.00	0.00	0.00	1
48	1121	99.64	0.09	0.09	0.09	0.09	1	1121	99.73	0.09	0.00	0.09	0.09	1
49	1101	100.0 0	0.00	0.00	0.00	0.00	1	1101	100.0 0	0.00	0.00	0.00	0.00	1
50	1391	98.42	0.36	0.93	0.07	0.22	0	1391	98.13	0.43	1.15	0.07	0.22	0
51	1193	99.41	0.00	0.00	0.59	0.00	0	1191	99.41	0.00	0.00	0.59	0.00	0
52	1202	99.92	0.00	0.00	0.08	0.00	1	1199	99.42	0.08	0.50	0.08	0.00	2
53	1211	99.67	0.00	0.00	0.00	0.33	1	1201	99.67	0.00	0.00	0.00	0.33	1
54	1057	100.0 0	0.00	0.00	0.00	0.00	1	1057	100.0 0	0.00	0.00	0.00	0.00	1
55	1060	99.43	0.19	0.19	0.00	0.19	1	1059	99.49	0.17	0.17	0.00	0.17	1
56	1249	99.60	0.00	0.00	0.08	0.32	1	1247	99.52	0.00	0.08	0.08	0.32	1
57	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
58	1195	98.74	0.00	0.84	0.42	0.00	0	1195	98.74	0.00	0.84	0.42	0.00	0
59	1101	100	0.00	0.00	0.00	0.00	1	1101	100	0.00	0.00	0.00	0.00	1
60	1096	99.91	0.00	0.09	0.00	0.00	1	1096	99.91	0.00	0.09	0.00	0.00	1
61	1188	99.83	0.17	0.00	0.00	0.00	1	1186	99.84	0.08	0.08	0.00	0.00	1
62	1202	99.92	0.00	0.00	0.08	0.00	1	1197	99.75	0.08	0.17	0.08	0.00	1
63	1215	99.67	0.00	0.00	0.00	0.33	1	1213	99.67	0.00	0.00	0.00	0.33	1
64	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
65	1069	98.88	0.00	0.00	1.12	0.00	1	1069	98.88	0.00	0.00	1.12	0.00	1
66	1249	99.60	0.00	0.00	0.08	0.32	1	1247	99.52	0.00	0.08	0.08	0.32	1
67	1069	99.81	0.19	0.00	0.00	0.00	1	1066	99.81	0.19	0.00	0.00	0.00	1
68	1121	99.64	0.09	0.09	0.09	0.09	1	1121	99.64	0.09	0.00	0.09	0.09	1
69	1103	99.82	0.18	0.00	0.00	0.00	1	1103	99.91	0.09	0.00	0.00	0.00	1
70	1099	99.91	0.00	0.00	0.00	0.09	1	1099	99.91	0.00	0.00	0.00	0.09	1
71	1196	99.16	0.00	0.00	0.84	0.00	0	1194	99.16	0.00	0.00	0.84	0.00	0

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

72	1203	99.83	0.00	0.00	0.00	0.17	1	1201	99.67	0.00	0.17	0.00	0.17	1
73	1215	99.67	0.00	0.00	0.00	0.33	1	1214	99.67	0.00	0.00	0.00	0.33	1
74	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
75	1056	99.81	0.19	0.00	0.00	0.00	1	1056	99.82	0.09	0.09	0.00	0.00	1
76	1249	99.60	0.19	0.00	0.08	0.32	1	1247	99.60	0.19	0.00	0.08	0.32	1
77	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
78	1165	99.06	0.00	0.94	0.00	0.00	0	1165	99.06	0.00	0.94	0.00	0.00	0
79	1390	99.28	0.00	0.72	0.00	0.00	3	1103	97.70	0.00	2.30	0.00	0.00	0
80	1349	98.30	0.37	0.74	0.37	0.22	0	1349	98.44	0.22	0.74	0.37	0.22	0
81	1187	99.83	0.17	0.00	0.00	0.00	1	1187	99.92	0.08	0.00	0.00	0.00	1
82	1203	99.83	0.00	0.00	0.00	0.17	1	1200	99.67	0.00	0.17	0.00	0.17	1
83	1215	99.67	0.00	0.00	0.00	0.33	1	1214	99.59	0.00	0.08	0.00	0.33	1
84	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
85	1054	100	0.00	0.00	0.00	0.00	1	1054	100	0.00	0.00	0.00	0.00	1
86	1249	99.60	0.00	0.00	0.08	0.32	1	1246	99.60	0.00	0.00	0.08	0.32	1
87	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
88	1121	99.64	0.09	0.09	0.09	0.09	1	1121	99.64	0.09	0.00	0.09	0.09	1
89	1103	99.82	0.00	0.18	0.00	0.00	1	1103	99.82	0.00	0.18	0.00	0.00	1
90	1361	98.38	0.37	0.66	0.37	0.22	0	1361	98.16	0.37	0.88	0.37	0.22	0
91	1195	99.32	0.17	0.17	0.17	0.17	1	1192	99.32	0.17	0.17	0.17	0.17	1
92	1203	99.83	0.00	0.00	0.00	0.17	1	1201	99.75	0.00	0.08	0.00	0.17	1
93	1215	99.67	0.00	0.00	0.00	0.33	1	1214	99.67	0.00	0.00	0.00	0.33	1
94	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
95	1054	100	0.00	0.00	0.00	0.00	1	1054	100	0.00	0.00	0.00	0.00	1
96	1248	99.68	0.32	0.00	0.00	0.00	1	1247	99.44	0.32	0.24	0.00	0.00	1
97	1069	99.81	0.19	0.00	0.00	0.00	1	1067	99.81	0.19	0.00	0.00	0.00	1
98	1162	99.05	0.00	0.95	0.00	0.00	0	1162	99.05	0.00	0.95	0.00	0.00	0
99	1103	99.82	0.00	0.18	0.00	0.00	1	1103	99.73	0.00	0.27	0.00	0.00	1
100	1189	99.75	0.00	0.00	0.00	0.25	1	1188	99.75	0.00	0.00	0.00	0.25	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

101	1194	99.32	0.17	0.17	0.17	0.17	1	1193	99.24	0.25	0.17	0.17	0.17	1
102	1203	99.83	0.00	0.00	0.00	0.17	1	1203	99.58	0.08	0.17	0.00	0.17	1
103	1215	99.67	0.00	0.00	0.00	0.33	1	1213	99.59	0.08	0.00	0.00	0.33	1
104	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
105	1198	99.00	0.00	0.00	1.00	0.00	0	1196	99.00	0.00	0.00	1.00	0.00	0
106	1248	99.68	0.00	0.00	0.00	0.32	1	1245	99.68	0.00	0.00	0.00	0.32	1
107	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
108	1123	99.46	0.18	0.09	0.09	0.18	1	1123	99.55	0.09	0.09	0.09	0.18	1
109	1115	99.73	0.00	0.00	0.00	0.27	1	1115	99.73	0.00	0.00	0.00	0.27	1
110	1189	99.75	0.00	0.00	0.00	0.25	1	1188	99.67	0.00	0.08	0.00	0.25	1
111	1194	99.32	0.17	0.17	0.17	0.17	1	1193	99.32	0.17	0.17	0.17	0.17	1
112	1203	99.83	0.00	0.17	0.00	0.00	1	1201	99.75	0.00	0.25	0.00	0.00	1
113	1215	99.67	0.00	0.00	0.00	0.33	1	1213	99.67	0.00	0.00	0.00	0.33	1
114	1058	99.91	0.00	0.00	0.09	0.00	1	1058	99.82	0.00	0.09	0.09	0.00	1
115	1201	98.75	0.00	0.00	1.25	0.00	0	1199	98.75	0.00	0.00	1.25	0.00	0
116	1248	99.68	0.00	0.00	0.00	0.32	1	1247	99.60	0.00	0.08	0.00	0.32	1
117	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
118	1123	99.46	0.18	0.09	0.09	0.18	1	1123	99.55	0.09	0.09	0.09	0.18	1
119	1115	99.73	0.00	0.00	0.00	0.27	1	1115	99.64	0.00	0.09	0.00	0.27	1
120	1189	99.75	0.00	0.00	0.00	0.25	1	1187	99.75	0.00	0.00	0.00	0.25	1
121	1194	99.32	0.17	0.17	0.17	0.17	1	1192	99.16	0.25	0.25	0.17	0.17	1
122	1203	99.83	0.00	0.17	0.00	0.00	1	1202	99.75	0.00	0.25	0.00	0.00	1
123	1216	99.59	0.00	0.00	0.00	0.41	1	1213	99.59	0.00	0.00	0.00	0.41	1
124	1065	99.25	0.00	0.00	0.75	0.00	1	1065	99.25	0.00	0.00	0.75	0.00	1
125	1197	99.08	0.00	0.92	0.00	0.00	0	1196	99.00	0.00	1.00	0.00	0.00	0
126	1248	99.68	0.00	0.00	0.00	0.32	1	1245	99.52	0.00	0.16	0.00	0.32	1
127	1069	99.81	0.19	0.00	0.00	0.00	1	1067	99.81	0.19	0.00	0.00	0.00	1
128	1124	99.38	0.18	0.18	0.09	0.18	1	1124	99.29	0.18	0.27	0.09	0.18	1
129	1115	99.73	0.00	0.00	0.27	0.00	1	1115	99.64	0.00	0.09	0.27	0.00	1



SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

130	1198	99.00	0.00	1.00	0.00	0.00	0	1196	99.00	0.00	1.00	0.00	0.00	0
131	1194	99.32	0.17	0.17	0.17	0.17	1	1194	99.32	0.17	0.17	0.17	0.17	1
132	1203	99.83	0.00	0.17	0.00	0.00	1	1202	99.83	0.08	0.58	0.00	0.00	2
133	1216	99.59	0.00	0.00	0.00	0.41	1	1215	99.51	0.08	0.00	0.00	0.41	1
134	1058	99.91	0.00	0.00	0.09	0.00	1	1058	99.91	0.00	0.00	0.09	0.00	1
135	1054	100	0.00	0.00	0.00	0.00	1	1054	100	0.00	0.00	0.00	0.00	1
136	1248	99.68	0.00	0.00	0.00	0.32	1	1245	99.52	0.00	0.16	0.00	0.32	1
137	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
138	1125	99.28	0.18	0.18	0.18	0.18	1	1125	99.28	0.18	0.09	0.18	0.27	1
139	1112	100	0.00	0.00	0.00	0.00	1	1112	100	0.00	0.00	0.00	0.00	1
140	1201	98.75	0.00	1.25	0.00	0.00	0	1199	98.75	0.00	1.25	0.00	0.00	0
141	1194	99.33	0.17	0.17	0.17	0.17	1	1192	99.24	0.17	0.25	0.17	0.17	1
142	1203	99.83	0.00	0.17	0.00	0.00	1	1200	99.25	0.08	0.67	0.00	0.00	2
143	1216	99.59	0.00	0.00	0.00	0.41	1	1215	99.51	0.08	0.00	0.00	0.41	1
144	1070	98.79	0.47	0.00	0.75	0.00	1	1070	98.79	0.47	0.00	0.75	0.00	1
145	1121	100	0.00	0.00	0.00	0.00	1	1121	100	0.00	0.00	0.00	0.00	1
146	1248	99.68	0.00	0.00	0.00	0.32	1	1247	99.52	0.08	0.08	0.00	0.32	1
147	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
148	1125	99.28	0.18	0.18	0.18	0.18	1	1125	99.29	0.18	0.09	0.18	0.27	1
149	1112	100	0.00	0.00	0.00	0.00	1	1112	99.91	0.09	0.00	0.00	0.00	1
150	1189	99.75	0.00	0.00	0.00	0.25	1	1187	99.75	0.00	0.00	0.00	0.25	1
151	1195	99.32	0.17	0.17	0.17	0.17	1	1193	99.25	0.17	0.25	0.17	0.17	1
152	1203	99.83	0.00	0.17	0.00	0.00	1	1201	99.75	0.00	0.25	0.00	0.00	1
153	1216	99.91	0.00	0.00	0.00	0.41	1	1214	99.43	0.16	0.00	0.00	0.41	1
154	1058	99.91	0.00	0.09	0.00	0.00	1	1058	99.81	0.00	0.09	0.09	0.00	1
155	1293	99.61	0.00	0.00	0.39	0.00	0	1293	99.38	0.00	0.23	0.39	0.00	0
156	1248	99.68	0.00	0.00	0.00	0.32	1	1247	99.52	0.00	0.16	0.00	0.32	1
157	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
158	1122	99.55	0.18	0.90	0.90	0.90	1	1122	99.55	0.18	0.90	0.90	0.90	1

**SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA**

159	1115	99.73	0.27	0.00	0.00	0.00	1	1115	99.82	0.18	0.00	0.00	0.00	1
160	1099	99.91	0.00	0.00	0.09	0.00	1	1099	99.91	0.00	0.00	0.09	0.00	1
161	1194	99.32	0.17	0.17	0.17	0.17	1	1192	99.16	0.25	0.25	0.17	0.17	1
162	1203	99.83	0.00	0.17	0.00	0.00	1	1202	99.42	0.08	0.50	0.00	0.00	1
163	1216	99.59	0.00	0.00	0.00	0.41	1	1213	99.43	0.08	0.08	0.00	0.41	1
164	1080	97.87	0.46	0.00	0.74	0.93	1	1080	97.96	0.37	0.00	0.74	0.93	1
165	1120	100	0.00	0.00	0.00	0.00	1	1120	100	0.00	0.00	0.00	0.00	1
166	1248	99.68	0.00	0.00	0.00	0.32	1	1247	99.52	0.00	0.16	0.00	0.32	1
167	1069	99.81	0.00	0.19	0.00	0.00	1	1067	99.81	0.00	0.19	0.00	0.00	1
168	1122	99.55	0.18	0.90	0.90	0.90	1	1122	99.55	0.09	0.18	0.90	0.90	1
169	1115	99.73	0.27	0.00	0.00	0.00	1	1115	99.73	0.18	0.09	0.00	0.00	1
170	1098	100	0.00	0.00	0.00	0.00	1	1098	100	0.00	0.00	0.00	0.00	1
171	1194	9.33	0.17	0.17	0.17	0.17	1	1193	9.33	0.08	0.25	0.17	0.17	1
172	1201	100	0.00	0.00	0.00	0.00	1	1200	99.92	0.00	0.08	0.00	0.00	1
173	1216	99.59	0.00	0.00	0.00	0.41	1	1214	99.59	0.00	0.00	0.00	0.41	1
174	1058	99.91	0.09	0.00	0.00	0.00	1	1058	99.91	0.09	0.00	0.00	0.00	1
175	1120	100	0.00	0.00	0.00	0.00	1	1120	100	0.00	0.00	0.00	0.00	1
176	1244	100	0.00	0.00	0.00	0.00	1	1243	99.92	0.00	0.08	0.00	0.00	1
177	1069	99.81	0.00	0.19	0.00	0.00	1	1068	99.81	0.00	0.19	0.00	0.00	1
178	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
179	1115	99.73	0.00	0.27	0.00	0.00	1	1115	99.73	0.00	0.27	0.00	0.00	1
180	1098	100	0.00	0.00	0.00	0.00	1	1098	100	0.00	0.00	0.00	0.00	1
181	1194	99.32	0.17	0.17	0.17	0.17	1	1192	99.32	0.17	0.17	0.17	0.17	1
182	1201	100	0.00	0.00	0.00	0.00	1	1199	99.92	0.00	0.08	0.00	0.00	1
183	1216	99.59	0.00	0.00	0.00	0.41	1	1215	99.51	0.08	0.00	0.00	0.41	1
184	1085	97.42	0.46	0.46	0.74	0.92	1	1084	97.51	0.37	0.46	0.74	0.92	1
185	1119	100	0.00	0.00	0.00	0.00	1	1119	99.91	0.09	0.00	0.00	0.00	1
186	1244	100	0.00	0.00	0.00	0.00	1	1242	99.92	0.00	0.08	0.00	0.00	1
187	1069	99.81	0.00	0.19	0.00	0.00	1	1067	99.81	0.00	0.19	0.00	0.00	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

188	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
189	1115	99.73	0.00	0.27	0.00	0.00	1	1115	99.73	0.00	0.27	0.00	0.00	1
190	1367	98.24	0.51	0.66	0.37	0.22	0	1367	98.02	0.51	0.88	0.37	0.22	0
191	1188	99.83	0.00	0.17	0.00	0.00	1	1186	99.83	0.00	0.17	0.00	0.00	1
192	1201	100	0.00	0.00	0.00	0.00	1	1200	100	0.00	0.00	0.00	0.00	1
193	1211	100	0.00	0.00	0.00	0.00	1	1209	99.92	0.08	0.00	0.00	0.00	1
194	1058	99.91	0.00	0.09	0.00	0.00	1	1058	99.81	0.09	0.19	0.00	0.00	1
195	1119	100	0.00	0.00	0.00	0.00	1	1119	100	0.00	0.00	0.00	0.00	1
196	1244	100	0.00	0.00	0.00	0.00	1	1243	99.92	0.00	0.08	0.00	0.00	1
197	1069	99.81	0.00	0.19	0.00	0.00	1	1067	99.81	0.00	0.19	0.00	0.00	1
198	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
199	1116	99.64	0.00	0.00	0.09	0.27	1	1116	99.64	0.00	0.00	0.09	0.27	1
200	1218	99.42	0.00	0.00	0.25	0.33	1	1210	99.34	0.00	0.08	0.25	0.33	1
201	1188	99.83	0.00	0.00	0.17	0.00	1	1184	99.83	0.00	0.00	0.17	0.00	1
202	1201	100	0.00	0.00	0.00	0.00	1	1195	100	0.00	0.00	0.00	0.00	1
203	1211	100	0.00	0.00	0.00	0.00	1	1207	99.83	0.17	0.00	0.00	0.00	1
204	1072	98.60	0.00	0.47	0.47	0.47	1	1072	98.23	0.19	0.65	0.47	0.47	1
205	1118	100	0.00	0.00	0.00	0.00	1	1118	99.91	0.09	0.00	0.00	0.00	1
206	1244	100	0.00	0.00	0.00	0.00	1	1238	99.92	0.00	0.08	0.00	0.00	1
207	1069	99.81	0.00	0.19	0.00	0.00	1	1067	99.81	0.00	0.19	0.00	0.00	1
208	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
209	1116	99.64	0.00	0.00	0.09	0.27	1	1116	99.64	0.00	0.00	0.09	0.27	1
210	1058	99.91	0.00	0.09	0.00	0.00	1	1058	99.81	0.00	0.19	0.00	0.00	1
211	1206	98.34	0.00	1.66	0.00	0.00	0	1206	98.18	0.00	1.82	0.00	0.00	0
212	1201	100	0.00	0.00	0.00	0.00	1	1194	99.83	0.00	0.17	0.00	0.00	1
213	1211	100	0.00	0.00	0.00	0.00	1	1207	99.92	0.08	0.00	0.00	0.00	1
214	1117	100	0.00	0.00	0.00	0.00	1	1114	99.91	0.09	0.00	0.00	0.00	1
215	1118	100	0.00	0.00	0.00	0.00	1	1118	100	0.00	0.00	0.00	0.00	1
216	1244	100	0.00	0.00	0.00	0.00	1	1238	99.84	0.00	0.16	0.00	0.00	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

217	1069	99.81	0.00	0.19	0.00	0.00	1	1067	99.81	0.00	0.19	0.00	0.00	1
218	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
219	1116	99.64	0.27	0.00	0.09	0.00	1	1116	99.64	0.18	0.00	0.18	0.00	1
220	1099	99.91	0.00	0.09	0.00	0.00	1	1099	99.91	0.00	0.09	0.00	0.00	1
221	1211	97.94	0.00	1.65	0.41	0.00	0	1211	97.69	0.00	1.90	0.41	0.00	0
222	1201	0.99	0.00	0.01	0.00	0.00	1	1195	99.50	0.00	0.50	0.00	0.00	2
223	1216	97.53	0.41	1.64	0.41	0.00	0	1216	97.37	0.41	1.81	0.41	0.00	0
224	1067	99.06	0.00	0.00	0.47	0.47	1	1066	98.70	0.09	0.07	0.47	0.00	1
225	1063	99.44	0.19	0.19	0.00	0.19	1	1063	99.53	0.09	0.19	0.00	0.19	1
226	1249	99.60	0.00	0.32	0.08	0.00	1	1240	99.60	0.00	0.00	0.08	0.32	1
227	1081	98.70	0.19	0.00	0.74	0.37	1	1079	98.80	0.19	0.09	0.65	0.28	1
228	1121	99.64	0.09	0.09	0.09	0.09	1	1121	99.55	0.18	0.09	0.09	0.09	1
229	1103	99.82	0.00	0.00	0.18	0.00	1	1103	99.82	0.00	0.00	0.18	0.00	1
230	1063	99.44	0.19	0.19	0.00	0.19	1	1063	99.44	0.19	0.19	0.00	0.19	1
231	1189	99.75	0.00	0.17	0.00	0.00	1	1184	99.75	0.00	0.25	0.00	0.00	1
232	1201	100	0.00	0.00	0.00	0.00	1	1196	99.92	0.00	0.08	0.00	0.00	1
233	1211	100	0.00	0.00	0.00	0.00	1	1209	99.83	0.17	0.00	0.00	0.00	1
234	1067	100.00	0.00	0.00	0.00	0.00	1	1065	99.91	0.09	0.00	0.00	0.00	1
235	1117	100	0.00	0.00	0.00	0.00	1	1117	99.91	0.09	0.00	0.00	0.00	1
236	1213	99.92	0.00	0.08	0.00	0.00	1	1200	99.83	0.00	0.17	0.00	0.00	1
237	1069	99.81	0.00	0.19	0.00	0.00	1	1065	99.81	0.00	0.19	0.00	0.00	1
238	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
239	1116	99.64	0.00	0.00	0.27	0.09	2	1116	99.64	0.00	0.00	0.27	0.09	2
240	1160	96.98	3.02	0.00	0.00	0.00	0	1160	96.90	3.10	0.00	0.00	0.00	0
241	1221	97.13	0.41	1.64	0.41	0.41	0	1221	96.97	0.41	1.80	0.41	0.41	0
242	1213	99.84	0.00	0.00	0.00	0.16	1	1204	99.83	0.08	0.00	0.00	0.08	1
243	1211	100	0.00	0.00	0.00	0.00	1	1208	99.92	0.08	0.00	0.00	0.00	1
244	1067	100	0.00	0.00	0.00	0.00	1	1066	99.91	0.09	0.00	0.00	0.00	1
245	1091	99.91	0.00	0.00	0.00	0.09	1	1091	99.91	0.00	0.00	0.00	0.09	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

246	1213	99.92	0.00	0.08	0.00	0.00	1	1200	99.83	0.00	0.17	0.00	0.00	1
247	1069	99.81	0.00	0.19	0.00	0.00	1	1056	99.81	0.00	0.19	0.00	0.00	1
248	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
249	1116	99.64	0.00	0.00	0.27	0.09	2	1116	99.64	0.00	0.00	0.27	0.09	2
250	1098	99.91	0.00	0.00	0.00	0.09	1	1098	99.91	0.00	0.00	0.00	0.09	1
251	1226	96.74	0.41	1.63	0.41	0.82	0	1226	96.66	0.49	1.63	0.41	0.82	0
252	1214	99.75	0.00	0.00	0.00	0.25	1	1206	99.67	0.08	0.00	0.00	0.25	1
253	1211	100	0.00	0.00	0.00	0.00	1	1209	100	0.00	0.00	0.00	0.00	1
254	1067	100	0.00	0.00	0.00	0.00	1	1065	99.91	0.09	0.00	0.00	0.00	1
255	1091	99.91	0.00	0.00	0.00	0.09	1	1091	99.91	0.00	0.00	0.00	0.09	1
256	1213	99.92	0.00	0.08	0.00	0.00	1	1206	99.83	0.00	0.17	0.00	0.00	1
257	1069	99.81	0.00	0.19	0.00	0.00	1	1066	99.81	0.00	0.19	0.00	0.00	1
258	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
259	1116	99.64	0.09	0.00	0.27	0.00	2	1116	99.64	0.09	0.00	0.27	0.00	2
260	1099	99.82	0.00	0.00	0.18	0.00	1	1099	99.82	0.00	0.00	0.18	0.00	1
261	1188	99.83	0.00	0.17	0.00	0.00	1	1185	99.75	0.00	0.25	0.00	0.00	1
262	1214	99.75	0.00	0.00	0.00	0.25	1	1207	99.50	0.25	0.00	0.00	0.25	1
263	1211	100	0.00	0.00	0.00	0.00	1	1210	100	0.00	0.00	0.00	0.00	1
264	1069	99.81	0.19	0.00	0.00	0.00	1	1069	99.72	0.19	0.09	0.00	0.00	1
265	1091	99.91	0.00	0.00	0.09	0.00	1	1091	99.91	0.00	0.00	0.09	0.00	1
266	1213	99.92	0.00	0.08	0.00	0.00	1	1210	99.75	0.08	0.17	0.00	0.00	1
267	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
300	1057	99.81	0.00	0.19	0.00	0.00	1	1057	99.81	0.00	0.19	0.00	0.00	1
269	1116	99.64	0.09	0.00	0.27	0.00	2	1116	99.73	0.00	0.00	0.27	0.00	2
270	1168	97.17	2.83	0.00	0.00	0.00	3	1099	96.82	3.18	0.00	0.00	0.00	0
271	1188	99.83	0.00	0.17	0.00	0.00	1	1184	99.75	0.00	0.25	0.00	0.00	1
272	1218	99.43	0.00	0.00	0.25	0.33	1	1212	99.34	0.00	0.08	0.25	0.33	1
273	1211	100	0.00	0.00	0.00	0.00	1	1204	100	0.00	0.00	0.00	0.00	1
274	1069	99.81	0.19	0.00	0.00	0.00	1	1069	99.91	0.09	0.00	0.00	0.00	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

275	1091	99.91	0.00	0.00	0.09	0.00	1	1090	99.91	0.00	0.00	0.09	0.00	1
276	1212	100	0.00	0.00	0.00	0.00	1	1205	99.83	0.08	0.08	0.00	0.00	1
277	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
278	1124	99.38	0.18	0.18	0.18	0.09	1	1124	99.38	0.18	0.09	0.18	0.18	1
279	1116	99.64	0.00	0.09	0.27	0.00	1	1116	99.64	0.00	0.09	0.27	0.00	1
280	1211	97.94	0.41	0.41	0.41	0.83	0	1211	97.94	0.41	0.41	0.41	0.83	0
281	1188	99.83	0.00	0.17	0.00	0.00	1	1186	99.75	0.00	0.25	0.00	0.00	1
282	1218	99.43	0.00	0.00	0.25	0.33	1	1213	99.34	0.00	0.08	0.25	0.33	1
283	1211	100	0.00	0.00	0.00	0.00	1	1209	99.83	0.00	0.17	0.00	0.00	1
284	1071	99.83	0.00	0.00	0.17	0.00	1	1071	99.83	0.00	0.00	0.17	0.00	1
285	1090	100	0.00	0.00	0.00	0.00	1	1090	100	0.00	0.00	0.00	0.00	1
286	1212	100	0.00	0.00	0.00	0.00	1	1205	99.83	0.17	0.00	0.00	0.00	1
287	1116	99.91	0.00	0.00	0.00	0.00	1	1116	99.81	0.00	0.19	0.00	0.00	1
288	1091	100	0.00	0.00	0.00	0.00	1	1091	99.91	0.09	0.00	0.00	0.00	1
289	1124	100	0.00	0.00	0.00	0.00	1	1124	99.92	0.00	0.08	0.00	0.00	1
290	1057	99.81	0.00	0.19	0.00	0.00	1	1057	99.81	0.00	0.19	0.00	0.00	1
291	1206	98.34	0.41	0.41	0.41	0.41	0	1206	98.34	0.41	0.41	0.41	0.41	0
292	1218	99.64	0.00	0.00	0.09	0.27	1	1213	99.64	0.00	0.00	0.09	0.27	1
293	1211	99.91	0.00	0.09	0.00	0.00	1	1209	99.81	0.00	0.19	0.00	0.00	1
294	1075	99.83	0.00	0.17	0.00	0.00	1	1075	99.83	0.00	0.17	0.00	0.00	1
295	1090	100	0.00	0.00	0.00	0.00	1	1090	99.83	0.00	0.17	0.00	0.00	1
296	1212	100	0.00	0.00	0.00	0.00	1	1208	99.92	0.08	0.00	0.00	0.00	1
297	1116	100	0.00	0.00	0.00	0.00	1	1116	99.91	0.09	0.00	0.00	0.00	1
298	1091	100	0.00	0.00	0.00	0.00	1	1091	100	0.00	0.00	0.00	0.00	1
299	1188	100	0.00	0.00	0.00	0.00	1	1188	99.84	0.00	0.16	0.00	0.00	1
267	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
301	1398	98.64	0.36	0.72	0.07	0.21	3	1398	98.28	0.64	0.79	0.07	0.21	3
302	1218	99.42	0.00	0.00	0.25	0.33	1	1217	99.34	0.80	0.00	0.25	0.33	1
303	1211	100	0.00	0.00	0.00	0.00	1	1208	100	0.00	0.00	0.00	0.00	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

304	1070	99.25	0.19	0.19	0.19	0.19	1	1070	99.35	0.90	0.19	0.19	0.19	1
305	1096	99.91	0.00	0.00	0.00	0.09	1	1096	99.91	0.00	0.00	0.00	0.09	1
306	1216	99.59	0.00	0.00	0.00	0.41	1	1215	99.59	0.00	0.00	0.00	0.41	1
307	1118	100	0.00	0.00	0.00	0.00	1	1118	100	0.00	0.00	0.00	0.00	1
308	1091	99.91	0.00	0.09	0.00	0.00	1	1091	99.91	0.00	0.09	0.00	0.00	1
309	1116	99.64	0.09	0.00	0.27	0.00	1	1116	99.64	0.09	0.00	0.27	0.00	1
310	1248	99.68	0.00	0.00	0.00	0.32	1	1246	99.60	0.00	0.08	0.00	0.32	1
311	1186	100	0.00	0.00	0.00	0.00	1	1185	100	0.00	0.00	0.00	0.00	1
312	1218	99.43	0.00	0.00	0.25	0.33	1	1216	99.51	0.00	0.00	0.16	0.33	1
313	1211	100	0.00	0.00	0.00	0.00	1	1209	99.84	0.08	0.08	0.00	0.00	1
314	1068	99.44	0.19	0.19	0.00	0.19	1	1068	99.44	0.19	0.19	0.00	0.19	1
315	1096	99.91	0.00	0.00	0.00	0.09	1	1096	99.91	0.00	0.00	0.00	0.09	1
316	1124	99.38	0.18	0.18	0.09	0.18	1	1124	99.29	0.18	0.27	0.09	0.18	1
317	1118	100	0.00	0.00	0.00	0.00	1	1118	100	0.00	0.00	0.00	0.00	1
318	1091	99.91	0.00	0.09	0.00	0.00	1	1091	99.91	0.00	0.09	0.00	0.00	1
319	1300	99.62	0.00	0.00	0.38	0.00	0	1300	99.38	0.00	0.23	0.38	0.00	0
320	1115	99.73	0.00	0.00	0.27	0.00	1	1115	99.73	0.00	0.00	0.27	0.00	1
321	1385	98.84	0.36	0.72	0.07	0.00	3	1385	98.70	0.43	0.79	0.07	0.00	3
322	1218	99.43	0.00	0.00	0.25	0.33	1	1217	99.43	0.00	0.00	0.25	0.33	1
323	1211	100	0.00	0.00	0.00	0.00	1	1209	99.82	0.00	0.08	0.00	0.00	1
324	1066	99.62	0.19	0.00	0.00	0.19	1	1066	99.72	0.09	0.00	0.00	0.19	1
325	1096	99.91	0.00	0.00	0.09	0.00	1	1096	99.91	0.00	0.00	0.09	0.00	1
326	1091	99.91	0.00	0.00	0.00	0.09	1	1091	99.91	0.00	0.00	0.00	0.09	1
327	1120	100	0.00	0.00	0.00	0.00	1	1120	100	0.00	0.00	0.00	0.00	1
328	1097	100	0.00	0.00	0.00	0.00	1	1097	100	0.00	0.00	0.00	0.00	1
329	1058	99.91	0.00	0.00	0.00	0.09	1	1058	99.91	0.00	0.00	0.00	0.09	1
330	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
331	1186	100	0.00	0.00	0.00	0.00	1	1183	99.92	0.00	0.08	0.00	0.00	1
332	1218	99.42	0.00	0.00	0.25	0.33	1	1216	99.51	0.00	0.00	0.16	0.33	1

SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

333	1211	100	0.00	0.00	0.00	0.00	1	1210	99.83	0.08	0.08	0.00	0.00	1
334	1066	99.62	0.19	0.00	0.00	0.19	1	1066	99.62	0.19	0.00	0.00	0.19	1
335	1096	99.91	0.00	0.00	0.09	0.00	1	1096	99.91	0.00	0.00	0.09	0.00	1
336	1123	99.47	0.18	0.09	0.09	0.18	1	1123	99.55	0.09	0.09	0.09	0.18	1
337	1120	100	0.00	0.00	0.00	0.00	1	1120	100	0.00	0.00	0.00	0.00	1
338	1097	100	0.00	0.00	0.00	0.00	1	1097	100	0.00	0.00	0.00	0.00	1
339	1115	99.73	0.27	0.00	0.00	0.00	1	1115	99.82	0.18	0.00	0.00	0.00	1
340	1054	100	0.00	0.00	0.00	0.00	1	1054	100	0.00	0.00	0.00	0.00	1
341	1186	100	0.00	0.00	0.00	0.00	1	1185	100	0.00	0.00	0.00	0.00	1
342	1218	99.43	0.00	0.00	0.25	0.33	1	1215	99.34	0.08	0.00	0.25	0.33	1
343	1211	100	0.00	0.00	0.00	0.00	1	1208	99.83	0.17	0.00	0.00	0.00	1
344	1064	99.81	0.19	0.00	0.00	0.00	1	1064	99.91	0.09	0.00	0.00	0.00	1
345	1095	100	0.00	0.00	0.00	0.00	1	1095	100	0.00	0.00	0.00	0.00	1
346	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
347	1122	100	0.00	0.00	0.00	0.00	1	1122	100	0.00	0.00	0.00	0.00	1
348	1099	99.82	0.18	0.00	0.00	0.00	1	1099	99.82	0.18	0.00	0.00	0.00	1
349	1248	99.68	0.00	0.00	0.00	0.32	1	1245	99.60	0.00	0.08	0.00	0.32	1
350	1091	99.91	0.09	0.00	0.00	0.00	1	1091	99.91	0.09	0.00	0.00	0.00	1
351	1387	98.85	0.36	0.72	0.07	0.00	3	1387	98.05	1.01	0.87	0.07	0.00	3
352	1218	99.42	0.00	0.00	0.25	0.33	1	1215	99.42	0.00	0.00	0.25	0.33	1
353	1058	99.91	0.00	0.00	0.00	0.09	1	1058	99.91	0.00	0.00	0.00	0.09	1
354	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
355	1095	100	0.00	0.00	0.00	0.00	1	1095	100	0.00	0.00	0.00	0.00	1
356	1069	99.81	0.19	0.00	0.00	0.00	1	1068	99.81	0.19	0.00	0.00	0.00	1
357	1122	100	0.00	0.00	0.00	0.00	1	1122	100	0.00	0.00	0.00	0.00	1
358	1205	96.68	2.74	0.17	0.41	0.00	0	1205	96.68	2.74	0.17	0.41	0.00	0
359	1148	100	0.00	0.00	0.00	0.00	1	1146	99.83	0.00	0.17	0.00	0.00	1
360	1194	99.33	0.17	0.17	0.17	0.17	1	1191	99.24	0.25	0.17	0.17	0.17	1
361	1186	100	0.00	0.00	0.00	0.00	1	1184	100	0.00	0.00	0.00	0.00	1



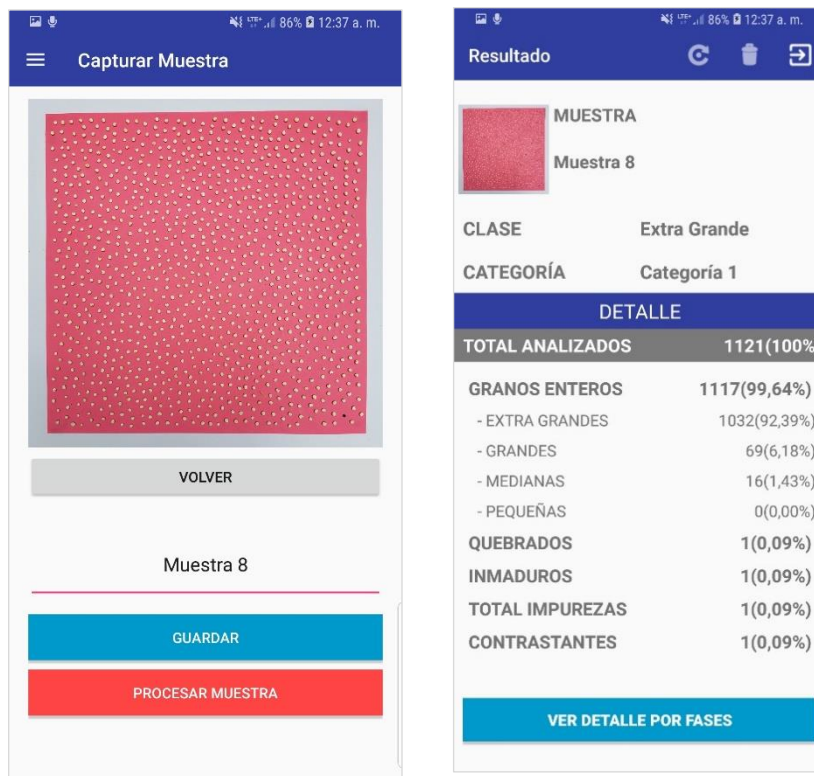
SISTEMA DE VISIÓN COMPUTACIONAL  
MÓVIL EN LA IDENTIFICACIÓN DE LA  
CALIDAD DE QUINUA BLANCA

362	1218	99.43	0.00	0.00	0.25	0.33	1	1216	99.51	0.00	0.00	0.16	0.33	1
363	1077	98.14	0.46	0.46	0.46	0.46	1	1076	97.96	0.46	0.65	0.46	0.46	1
364	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
365	1096	99.91	0.09	0.00	0.00	0.00	1	1096	99.91	0.09	0.00	0.00	0.00	1
366	1188	99.83	0.00	0.17	0.00	0.00	1	1187	99.73	0.00	0.25	0.00	0.00	1
367	1121	99.64	0.09	0.09	0.09	0.09	1	1121	99.64	0.18	0.00	0.09	0.09	1
368	1099	99.82	0.00	0.18	0.00	0.00	1	1099	99.82	0.00	0.18	0.00	0.00	1
369	1244	100	0.00	0.00	0.00	0.00	1	1242	100	0.00	0.00	0.00	0.00	1
370	1201	100	0.00	0.00	0.00	0.00	1	1199	99.92	0.00	0.08	0.00	0.00	1
371	1248	99.68	0.00	0.00	0.00	0.32	1	1245	99.68	0.00	0.00	0.00	0.32	1
372	1248	99.68	0.00	0.00	0.00	0.32	1	1245	99.68	0.00	0.00	0.00	0.32	1
373	1218	99.43	0.00	0.00	0.25	0.33	1	1212	99.50	0.00	0.00	0.17	0.33	1
374	1058	99.91	0.00	0.00	0.00	0.09	1	1058	99.91	0.00	0.00	0.00	0.09	1
375	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
376	1188	99.83	0.17	0.00	0.00	0.00	1	1187	99.83	0.17	0.00	0.00	0.00	1
377	1347	98.14	0.37	0.89	0.37	0.22	0	1347	98.07	0.45	0.97	0.30	0.22	0
378	1205	97.10	2.74	0.17	0.00	0.00	3	1205	96.76	3.07	0.17	0.00	0.00	0
379	1057	100	0.00	0.00	0.00	0.00	1	1057	100	0.00	0.00	0.00	0.00	1
380	1114	100	0.00	0.00	0.00	0.00	1	1114	100	0.00	0.00	0.00	0.00	1
381	1389	98.92	0.29	0.72	0.07	0.00	3	1389	98.06	1.01	0.86	0.07	0.00	3
382	1218	99.43	0.00	0.00	0.25	0.33	1	1215	99.43	0.08	0.00	0.33	0.33	3
383	1080	97.82	0.46	0.46	0.74	0.46	1	1079	97.78	0.56	0.46	0.74	0.46	1
384	1059	99.81	0.19	0.00	0.00	0.00	1	1059	99.91	0.09	0.00	0.00	0.00	1
385	1096	99.91	0.00	0.09	0.00	0.00	1	1096	99.91	0.00	0.09	0.00	0.00	1

**ANEXO n.º 02**

**Capturas de pantalla de la GUI de sistema de visión computacional móvil**

A. Interfaz de inicio (procesar muestra y resultado)



B. Interfaces de detalle (preprocesamiento de imagen)



C. Interfaces de detalle (segmentación y descripción)



D. Interfaces de detalle (reconocimiento)



**ANEXO n.º 03**

**Proceso de preparación de muestras basadas en la norma técnica peruana**

A. Pesado de muestra




B. Medición de tamaño de los granos




**ANEXO n.º 04**  
**Captura y procesamiento de muestras**

A. Enfocando la cámara al objetivo



B. Separando los granos de quinua



C. Muestra obtenida



D. Procesando muestras

