

UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD DEL CUSCO
FACULTAD DE INGENIERÍA DE PROCESOS
ESCUELA PROFESIONAL DE INGENIERÍA QUÍMICA



TESIS

EVALUACION DEL GRADO DE TOSTADO DE CACAO (*Theobroma cacao* L.) MEDIANTE REDES NEURONALES CONVOLUCIONALES

PRESENTADO POR:

Br. INDIRA REABEL SANTI QUISPE

Br. PAOLA ALEXANDRA CCAHUAYA
GUTIERREZ

**PARA OPTAR AL TÍTULO PROFESIONAL DE
INGENIERO QUÍMICO**

ASESOR:

M. Sc. WILBER EULOGIO PINARES GAMARRA

CUSCO - PERÚ

2025

INFORME DE ORIGINALIDAD

(Aprobado por Resolución Nro.CU-303-2020-UNSAAC)

El que suscribe, **Asesor** del trabajo de investigación/tesis titulada:

EVALUACION DEL GRADO DE TOSTADO DE CACAO (Theobroma cacao L.) MEDIANTE REDES NEURONALES CONVOLUCIONALES

Presentado por: Indira Reabel Santi Quispe DNI N° 70384106

presentado por: Paola Alexandra Cahuaya Gutierrez DNI N°: 76612968

Para optar el título profesional/grado académico de Ingeniero Químico

Informo que el trabajo de investigación ha sido sometido a revisión por 02 veces, mediante el Software Antiplagio, conforme al Art. 6° del **Reglamento para Uso de Sistema Antiplagio de la UNSAAC** y de la evaluación de originalidad se tiene un porcentaje de 1 %.

Evaluación y acciones del reporte de coincidencia para trabajos de investigación conducentes a grado académico o título profesional, tesis

Porcentaje	Evaluación y Acciones	Marque con una (X)
Del 1 al 10%	No se considera plagio.	☒
Del 11 al 30 %	Devolver al usuario para las correcciones.	☐
Mayor a 31%	El responsable de la revisión del documento emite un informe al inmediato jerárquico, quien a su vez eleva el informe a la autoridad académica para que tome las acciones correspondientes. Sin perjuicio de las sanciones administrativas que correspondan de acuerdo a Ley.	☐

Por tanto, en mi condición de asesor, firmo el presente informe en señal de conformidad y **adjunto** las primeras páginas del reporte del Sistema Antiplagio.

Cusco, 15 de agosto de 2023

Firma

Post firma WILBER E. PINAZZI GAMAZA

Nro. de DNI 23879839

ORCID del Asesor 0000 - 0002 - 6008 - 1522

Se adjunta:

1. Reporte generado por el Sistema Antiplagio.
2. Enlace del Reporte Generado por el Sistema Antiplagio: **oid:** 27259 : 483760028

Indira Reabel Santi Quispe - Paola Alexandra Ccah...

EVALUACION DEL GRADO DE TOSTADO DE CACAO (Theobroma cacao L.) MEDIANTE REDES NEURONALES CON...

 Universidad Nacional San Antonio Abad del Cusco

Detalles del documento

Identificador de la entrega

trn:oid:::27259:483760028

Fecha de entrega

15 ago 2025, 11:13 a.m. GMT-5

Fecha de descarga

15 ago 2025, 11:18 a.m. GMT-5

Nombre de archivo

EVALUACION DEL GRADO DE TOSTADO DE CACAO (Theobroma cacao L.) MEDIANTE REDES NEUR....pdf

Tamaño de archivo

9.4 MB

185 Páginas

27.029 Palabras

154.464 Caracteres

1% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Texto citado
- Texto mencionado
- Coincidencias menores (menos de 25 palabras)

Fuentes principales

- 1%  Fuentes de Internet
- 0%  Publicaciones
- 0%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alerta de integridad para revisión

-  **Texto oculto**
8 caracteres sospechosos en N.º de páginas
El texto es alterado para mezclarse con el fondo blanco del documento.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Presentación

Señor decano y distinguidos docentes del Departamento Académico de Ingeniería Química de la Facultad de Ingeniería de Procesos de la Universidad Nacional de San Antonio Abad del Cusco:

En cumplimiento del Reglamento de Grados y Títulos de la Escuela Profesional de Ingeniería Química vigente a la fecha, presentamos a vuestra consideración el trabajo de tesis titulado:

“EVALUACION DEL GRADO DE TOSTADO DE CACAO (*Theobroma cacao* L.) MEDIANTE REDES NEURONALES CONVOLUCIONALES”

Los estudios y pruebas se realizaron en el Laboratorio de Control de Procesos de la Escuela Profesional de Ingeniería Química, donde se desarrolló un sistema automático basado en visión artificial para la clasificación del grado de tostado de granos de cacao, mediante el uso de redes neuronales convolucionales.

Dedicatoria

Dedico este trabajo a mi mamá, Adela, y a mi abuelita, Agueda, por su amor incondicional, esfuerzo incansable y ejemplo de perseverancia. A ellas les debo cada paso que me ha llevado hasta aquí.

A mi hermanita Milagros, por ser mi compañera de siempre y apoyo incondicional, a mi señor padre Saul por motivarme a superarme.

También dedico esta tesis a mí misma, por no rendirme en los momentos difíciles y por seguir creyendo en mis sueños. Y a Noé, por acompañarme con cariño y aliento en este camino.

Paola Ccahuaya

Dedico este trabajo con profundo amor y gratitud a mis padres, Leonarda y Mario, por ser mi inspiración, mi fortaleza y el pilar fundamental a lo largo de mi formación. Su ejemplo y apoyo incondicional han sido esenciales en este logro.

A mi familia, especialmente a Alfredo, Rosa y mis sobrinos, por su cariño y su ayuda constante durante toda mi etapa de estudios.

A mí misma, por mantenerme firme ante los desafíos, por confiar en mis capacidades y avanzar con perseverancia y compromiso.

Y con especial aprecio a Andree, por su ayuda incalculable y por estar a mi lado con paciencia, entrega y comprensión en cada etapa de esta tesis. Su presencia marcó una diferencia invaluable y me acompañó con amor en los momentos más desafiantes.

Indira Santi

Agradecimientos

Agradecemos en primer lugar a Dios, por guiarnos, darnos fortaleza en los momentos más difíciles y permitirnos llegar hasta aquí.

Al Ing. Wilber Pinares, asesor de este trabajo, por su tiempo y disposición con nosotras, así mismo con especial gratitud al Ing. Franklin Salas, por habernos acompañado desde el inicio con compromiso y generosidad, brindándonos no solo su tiempo, conocimientos y guía, sino también la idea inicial que dio forma a este trabajo. Su disposición constante, sin esperar nada a cambio, sus enseñanzas y su calidad humana han sido una inspiración invaluable a lo largo de todo este proceso.

A los docentes de la Escuela Profesional de Ingeniería Química, por compartir con generosidad sus conocimientos a lo largo de nuestra formación.

A nuestros amigos y compañeros de Ingeniería Química e Ingeniería Petroquímica, con quienes compartimos grandes momentos los cuales los llevamos en el corazón.

A nosotras mismas, Reabel y Paola, por mantenernos juntas desde el inicio de nuestra formación universitaria, por cada madrugada de esfuerzo juntas y por demostrar que formamos un gran equipo. Este logro también es prueba de nuestra perseverancia.

Y, por supuesto, a nuestras familias, por ser nuestro motor, por creer en nosotras, y por impulsarnos a cumplir nuestras metas. Los queremos y valoramos profundamente.

Contenido

Presentación.....	ii
Dedicatoria	iii
Contenido	v
Lista de Figuras	x
Lista de Tablas.....	xiv
Resumen	xv
Abstract.....	xvi
Glosario	xvii
Abreviaturas	xx
CAPÍTULO I: GENERALIDADES.....	1
Introducción.....	2
1.1. Descripción del problema	4
1.2. Formulación del problema.....	5
1.2.1. Problema general	5
1.2.2. Problemas específicos	5
1.3. Justificación de la investigación	6
1.4. Objetivos de la investigación	7
1.4.1. Objetivo general	7
1.4.2. Objetivos específicos	7
CAPÍTULO II: MARCO TEÓRICO.....	8

2.1.	Antecedentes de la investigación	9
2.2.	Bases teóricas.....	11
2.2.1.	Aplicaciones de <i>Machine Learning</i> en la industria alimentaria	11
2.2.2.	Métricas de evaluación para clasificación de datos.....	13
2.2.3.	Contenido de humedad	18
2.2.4.	Balance de masa para el sistema de tostación	19
2.3.	Marco conceptual.....	21
2.3.1.	Cacao (<i>Theobroma cacao</i> L.)	21
2.3.2.	Proceso de producción del chocolate	23
2.3.3.	Tostado de los granos de cacao	25
2.3.4.	Tipos de tostado del cacao.....	26
2.3.5.	Grados de tostado del cacao	27
2.3.6.	Efecto del tostado sobre el color de los granos de cacao.....	27
2.3.7.	Parámetros en el proceso de tostado de cacao	28
2.3.8.	Machine Learning.....	29
2.3.9.	Redes Neuronales Convolucionales (CNN)	31
2.3.10.	Sensores y dispositivos de adquisición de imágenes	36
2.3.11.	Técnicas de procesamiento de imágenes	38
CAPÍTULO III: MATERIALES Y MÉTODOS.....		41
3.1.	Muestra	42
3.1.1.	Muestra para proceso de tostado	42
3.1.2.	Muestra para procesamiento de imágenes y entrenamiento de CNNs	42

3.2. Materiales y equipos	42
3.2.1. Materiales	42
3.2.2. Equipos	43
3.2.3. Software.....	43
3.3. Ámbito espacial y temporal	44
3.4. Diseño de la investigación	44
3.5. Identificación de variables	44
3.5.1. Variables independientes.....	44
3.5.2. Variables dependientes.....	44
3.6. Proceso de tostado	44
3.6.1. Granos de cacao.....	44
3.6.2. Equipo utilizado y condiciones de tostado	45
3.6.3. Humedad.....	47
3.7. Procedimiento para la implementación del sistema de adquisición de imágenes..	50
3.8. Procedimientos para el desarrollo de algoritmos de procesamiento de imágenes.	51
3.9. Procedimiento para el reajuste de los hiper parámetros de Redes Neuronales Convolucionales	52
3.10. Procedimiento para la comparación de la capacidad de los algoritmos desarrollados.....	53
3.11. Procedimiento para la validación de la efectividad del sistema propuesto..	54

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	56
4.1. Resultados proceso de tostado	57
4.1.1. Curvas de temperatura.....	57
4.2. Implementación del sistema de adquisición de imágenes.....	65
4.2.1. Diseño de estructura de soporte del SAI	65
4.2.2. Iluminación del Sistema de adquisición de imágenes	65
4.2.3. Corrección de distorsión óptica	66
4.2.4. Distribución de tamaño de granos de cacao	69
4.3. Desarrollo de algoritmos de procesamiento de imágenes.....	71
4.3.1. Preprocesamiento de imágenes.....	71
4.3.2. Identificación de granos individuales	74
4.3.3. Separación de granos superpuestos	74
4.3.4. Etiquetado de granos segmentados.....	77
4.4. Reajuste de los hiper parámetros de Redes Neuronales Convolucionales.....	78
4.4.1. Entrenamiento de <i>MobileNet-v2</i>	79
4.4.2. Entrenamiento de <i>ResNet-18</i>	83
4.4.3. Entrenamiento de <i>ResNet-50</i>	87
4.4.4. Entrenamiento de <i>ResNet-101</i>	90
4.4.5. Entrenamiento de <i>Inception-v3</i>	94
4.5. Evaluación de la capacidad de los algoritmos desarrollados.....	97
4.5.1. Evaluación de <i>MobileNet-v2</i>	97
4.5.2. Evaluación de <i>ResNet-18</i>	98

4.5.3. Evaluación de <i>ResNet-50</i>	99
4.5.4. Evaluación de <i>ResNet-101</i>	100
4.5.5. Evaluación de <i>Inception-v3</i>	101
4.6. Validación de la efectividad del sistema propuesto	104
CONCLUSIONES.....	108
RECOMENDACIONES	111
REFERENCIAS BIBLIOGRÁFICAS	112
APÉNDICES	121
APÉNDICE A	122
APÉNDICE B.....	123
APÉNDICE C.....	125
APÉNDICE D	126
APÉNDICE E	129
APÉNDICE F	133
APÉNDICE G	140
ANEXOS	165
ANEXO A	166

Lista de Figuras

Figura 1 Curva ROC (mostrada en gris).	17
Figura 2 Representación del balance de masa y energía en el proceso de tostado de granos de cacao.....	20
Figura 3 Granos de cacao (<i>Theobroma cacao</i> L.) en estado seco	22
Figura 4 Diagrama de flujo del proceso de elaboración del chocolate.....	24
Figura 5 Ramas del Machine Learning.	31
Figura 6 Arquitectura de la red neuronal convolucional ResNet.	34
Figura 7 Arquitectura de la red neuronal convolucional MobileNet-v2.	34
Figura 8 Arquitectura de la red neuronal convolucional Inception-v3.	35
Figura 9 Mapa mental de sensores y dispositivos de adquisición de imágenes.	37
Figura 10 Calibración de una cámara para la adquisición de imágenes.....	38
Figura 11 Técnicas de procesamiento de imágenes.	39
Figura 12 Tostador de cacao de manufactura local.	45
Figura 13 Programa desarrollado en LabVIEW para registro de temperatura.....	46
Figura 14 Medición de humedad en granos de cacao (minuto 12) – Balanza PCE MA-50X.	49
Figura 15 Obtención de muestras de cacao con diferentes grados de tostado.....	49
Figura 16 Propuesta del sistema de adquisición de imágenes.....	51
Figura 17 Procedimiento para el desarrollo de algoritmos para el procesamiento de imágenes.	52
Figura 18 Evaluación de arquitecturas de CNNs entrenadas.	54
Figura 19 Validación del desempeño de la CNN seleccionada.....	55
Figura 20 Curvas de temperatura durante los procesos de tostado.	58
Figura 21 Curva de humedad en base seca a lo largo del proceso de tostado.	62

Figura 22 Cambio de color de granos de cacao en función del tiempo y temperatura de tostado.....	64
Figura 23 Diseño 3D de la estructura del sistema de adquisición de imágenes.	65
Figura 24 Granos de cacao bajo diferentes tipos de luces.....	66
Figura 25 Calibración de cámara del SAI para corrección de distorsión de ojo de pez..	67
Figura 26 Error de reproyección de la calibración de la distorsión de ojo de pez en cámara.....	68
Figura 27 Sistema de adquisición de imágenes en operación.	69
Figura 28 Distribución de tamaños de los granos de cacao de la corrida 1.....	70
Figura 29 Ventana de selección de técnica de segmentación de imágenes de color Thresholder.....	72
Figura 30 Aplicación de máscara RGB en color Thresholder.....	73
Figura 31 Diagrama secuencial del método de reconocimiento de objetos elipsoidales.	76
Figura 32 Aplicación de algoritmo de procesamiento de imágenes a granos de cacao tostado.....	77
Figura 33 Escala de color de granos de cacao dividida en 5 grados de tostado.	78
Figura 34 Curva de entrenamiento de arquitectura MobileNet-v2.....	79
Figura 35 Matriz de confusión de MobileNet-v2 en la predicción del grado de tostado del cacao.	81
Figura 36 Clasificación de imágenes de validación por MobileNet-v2.	82
Figura 37 Curva de entrenamiento de arquitectura ResNet-18.	84
Figura 38 Matriz de confusión de ResNet-18 en la predicción del grado de tostado del cacao.	85

Figura 39 Clasificación de imágenes de validación por ResNet-18.....	86
Figura 40 Curva de entrenamiento de arquitectura ResNet-50.	87
Figura 41 Matriz de confusión de ResNet-50 en la predicción del grado de tostado del cacao.	88
Figura 42 Clasificación de imágenes de validación por ResNet-50.....	89
Figura 43 Curva de entrenamiento de arquitectura ResNet-101.	91
Figura 44 Matriz de confusión de ResNet-101 en la predicción del grado de tostado del cacao.	92
Figura 45 Clasificación de imágenes de validación por ResNet-101.....	93
Figura 46 Curva de entrenamiento de arquitectura Inception-v3.....	94
Figura 47 Matriz de confusión de Inception-v3 en la predicción del grado de tostado del cacao.	95
Figura 48 Clasificación de imágenes de validación por Inception-v3.	96
Figura 49 Curva ROC de MobileNet-v2 obtenida en la clasificación de granos de cacao.	98
Figura 50 Curva ROC de ResNet-18 obtenida en la clasificación de granos de cacao.	99
Figura 51 Curva ROC de ResNet-50 obtenida en la clasificación de granos de cacao.	100
Figura 52 Curva ROC de ResNet-101 obtenida en la clasificación de granos de cacao.	101
Figura 53 Curva ROC de Inception-v3 obtenida en la clasificación de granos de cacao.	102
Figura 54 Clasificación de granos de cacao tostado – Minuto 20.....	105
Figura 55 Evolución de la distribución de grado de tostado de granos de cacao a lo largo del tiempo.	106

Figura 56 Porcentaje de semejanza entre clasificado de Inception-v3 y expertos. 107

Lista de Tablas

Tabla 1 Matriz de confusión multiclase.....	14
Tabla 2 Análisis proximal del cacao criollo peruano fermentado y seco.	23
Tabla 3 Técnicas de tostado aplicadas a diferentes tipos de muestra de cacao.	28
Tabla 4 Capas de una Red Neuronal Convolutiva y sus características.	32
Tabla 5 Comparación de arquitecturas de redes neuronales convolucionales.....	36
Tabla 6 Equipos utilizados en la investigación.....	43
Tabla 7 Datos de humedad (Base Húmeda y Base Seca) y cambio de masa de los granos de cacao en el tostado.	61
Tabla 8 Coordenadas de máscara RGB creada en color Threshold.	72
Tabla 9 Valores de precisión y Recall calculados de la matriz de confusión de MobileNet-v2.	81
Tabla 10 Valores de precisión y Recall calculados de la Matriz de confusión de ResNet-18.....	85
Tabla 11 Valores de precisión y Recall calculados de la Matriz de confusión de ResNet-50.....	89
Tabla 12 Valores de precisión y Recall calculados de la Matriz de confusión de ResNet-101.....	92
Tabla 13 Valores de precisión y Recall calculados de la Matriz de confusión de Inception-v3.....	96
Tabla 14 Comparación de métricas de CNN entrenadas.	102

Resumen

El tostado del cacao es una etapa clave en su procesamiento, ya que influye significativamente en el desarrollo de compuestos sensoriales esenciales como el aroma y el sabor. Sin embargo, en la actualidad, la evaluación del grado de tostado se realiza de forma empírica, lo que genera inconsistencias en la calidad del producto final. En este contexto, la presente investigación propone la implementación de un sistema automático de evaluación del grado de tostado de granos de cacao (*Theobroma Cacao* L.) mediante el uso de Redes Neuronales Convolucionales (CNN). Para ello, se diseñó e implementó un sistema de adquisición de imágenes (SAI), que permite capturar la colorimetría de los granos durante el proceso de tostado. Las imágenes fueron sometidas a técnicas de procesamiento que incluyen segmentación, preprocesamiento y etiquetado, con el fin de generar una base de datos que sirva como entrada para el entrenamiento de modelos de aprendizaje profundo. Se evaluaron cinco arquitecturas de CNN: MobileNet-v2, ResNet-18, ResNet-50, ResNet-101 e Inception-v3. La clasificación se realizó en cinco grados de tostado definidos por expertos. Los resultados demostraron que el modelo Inception-v3 obtuvo la mayor precisión en la clasificación, superando el 95 % de exactitud en pruebas controladas y manteniendo un rendimiento robusto. Esta investigación evidencia que la visión artificial y el aprendizaje profundo constituyen herramientas efectivas para estandarizar el proceso de tostado, reducir la variabilidad sensorial y mejorar la trazabilidad del cacao. Asimismo, la solución propuesta ofrece una alternativa accesible y escalable para pequeños productores, promoviendo una mayor competitividad en la cadena de valor del cacao peruano.

Palabras clave: cacao, tostado, visión artificial, redes neuronales convolucionales, clasificación automática.

Abstract

Cocoa roasting is a crucial stage in its processing, as it significantly influences the development of key sensory compounds such as aroma and flavor. However, the current assessment of the roasting degree is performed empirically, leading to inconsistencies in the final product quality. In this context, the present study proposes the implementation of an automated classification system for the roasting degree of cocoa beans (*Theobroma cacao* L.) using Convolutional Neural Networks (CNNs). To achieve this, an image acquisition system (IAS) was designed and implemented to capture the colorimetric characteristics of the beans during the roasting process. The collected images underwent processing techniques including segmentation, preprocessing, and labeling to build a dataset used for training deep learning models. Five CNN architectures were evaluated: MobileNet-v2, ResNet-18, ResNet-50, ResNet-101, and Inception-v3. Classification was conducted across five roasting levels defined by experts. Results showed that the Inception-v3 model achieved the highest accuracy, exceeding 95% in controlled tests and maintaining robust performance. This research demonstrates that computer vision and deep learning are effective tools to standardize the roasting process, reduce sensory variability, and improve cocoa traceability. Furthermore, the proposed solution offers an accessible and scalable alternative for small producers, enhancing competitiveness in the Peruvian cocoa value chain.

Key words: cocoa, roasting, computer vision, convolutional neural networks, automatic classification.

Glosario

Accuracy:

Métrica que indica cuántas predicciones hizo correctamente un modelo con respecto al total.

Aprendizaje profundo (Deep Learning):

Rama de la inteligencia artificial que utiliza redes neuronales con múltiples capas para aprender características complejas de los datos, como imágenes o sonidos.

Arquitectura CNN (Red Neuronal Convolucional):

Tipo de red neuronal especializada en el procesamiento de imágenes, capaz de detectar patrones visuales como bordes, colores y texturas.

Batch:

Subconjunto del total de datos que se procesa en una iteración durante el entrenamiento de una red neuronal.

Binarización:

Proceso de convertir una imagen a blanco y negro (valores de 0 y 1), útil para separar objetos del fondo.

Clasificación:

Proceso mediante el cual un modelo predice a qué categoría pertenece un dato. En este caso, se clasifica el grado de tostado del cacao.

Convolución:

Operación matemática central en las redes neuronales convolucionales. Permite extraer características como bordes, formas o texturas en una imagen aplicando filtros (kernels).

Curva ROC:

Gráfico que muestra la capacidad de un modelo para distinguir entre niveles. Cuanto más cerca esté la curva del vértice superior izquierdo, mejor el modelo.

Época (Epoch):

En *machine learning*, una época corresponde a una pasada completa por todo el conjunto de datos de entrenamiento.

Etiquetado de datos:

Proceso de asignar manualmente una categoría a cada imagen (por ejemplo, “crudo”, “tostado”, “quemado”) para que el modelo aprenda a reconocerlas.

Inferencia:

Fase en la que un modelo ya entrenado se utiliza para predecir nuevos datos.

Iteración:

Cada paso o actualización que realiza el modelo durante el entrenamiento al procesar un batch de datos.

Madera MDF (Medium-Density Fibreboard):

Tablero de fibras de madera de densidad media, fabricado a partir de fibras de madera y resinas prensadas.

Matriz de confusión:

Tabla que compara las predicciones del modelo con los valores reales. Permite calcular métricas como precisión, sensibilidad y especificidad.

Máscara de color:

Filtro aplicado a una imagen para resaltar únicamente los píxeles que cumplen con un rango específico de color. Se usa en segmentación para aislar objetos según su tonalidad.

Modelo:

Algoritmo entrenado para identificar patrones en los datos y hacer predicciones.

Overfitting (Sobreajuste):

Ocurre cuando un modelo aprende demasiado bien los datos de entrenamiento y no generaliza bien a datos nuevos.

Pixel:

Unidad mínima de una imagen digital. Cada píxel contiene información de color y forma parte de una matriz de valores que componen la imagen completa.

Red neuronal:

Modelo computacional inspirado en el cerebro humano, compuesto por nodos (neuronas) conectados en capas, que permiten aprender patrones complejos.

Segmentación de imágenes:

Proceso de dividir una imagen en regiones o partes.

Umbralización:

Técnica para convertir una imagen en binaria usando un valor límite (umbral) que decide qué píxeles quedan como blanco o negro.

Abreviaturas

AI	Inteligencia Artificial (<i>Artificial Intelligence</i>)
AUC	Área bajo la Curva (<i>Area Under Curve</i>)
CNN	Red Neuronal Convolutacional (<i>Convolutional Neural Network</i>)
FC	Capa Totalmente Conectada (<i>Fully Connected</i>)
GPU	Unidad de Procesamiento Gráfico (<i>Graphics Processing Unit</i>)
IoU	Intersección sobre Unión (<i>Intersection over Union</i>)
mAP	Precisión Media Promedio (<i>Mean Average Precision</i>)
ML	Aprendizaje Automático (<i>Machine Learning</i>)
ReLU	Unidad Lineal Rectificada (<i>Rectified Linear Unit</i>)
RGB	Modelo de color Rojo, Verde, Azul (<i>Red, Green, Blue</i>)
RoI	Región de Interés (<i>Region of Interest</i>)
SAI	Sistema de Adquisición de Imágen
SVM	Máquinas de Vectores de Soporte (<i>Support Vector Machines</i>)

CAPÍTULO I: GENERALIDADES

Introducción

El tostado es una etapa fundamental en el procesamiento del cacao, ya que afecta directamente su composición química, desarrollo de sabor y características sensoriales (Afoakwa *et al.*, 2013). Actualmente, este proceso no está completamente estandarizado y suele depender de la experiencia del operario, quien determina el grado de tostado mediante una evaluación visual y sensorial (Jinap *et al.*, 1998). Este método empírico puede provocar variaciones en la calidad del tostado y reducir la eficiencia del procesamiento (Kongor *et al.*, 2016).

En el Perú, la producción de cacao ha crecido de manera sostenida en los últimos años, alcanzando 225,000 toneladas en 2022, con un rendimiento promedio de 1.2 toneladas por hectárea (MINAGRI, 2022). Sin embargo, hasta un 30% de la producción puede verse afectada por variaciones en el tostado, lo que impacta en la calidad del grano y su valor en el mercado internacional (De la Cruz *et al.*, 2020).

Diferentes factores, como la temperatura, el tiempo de tostado y la humedad, influyen en la transformación de los compuestos del cacao (Misnawi *et al.*, 2004). La falta de métodos objetivos y en tiempo real para evaluar el grado de tostado dificulta la obtención de un producto homogéneo (Aprotosoai *et al.*, 2016).

En respuesta a esta problemática, diversas investigaciones han explorado el uso de visión artificial y aprendizaje profundo en la clasificación y control de calidad en productos agrícolas (Essah *et al.*, 2022). Este estudio propone el desarrollo de un sensor basado en Redes Neuronales Convolucionales (CNN) para clasificar el grado de tostado del cacao, eliminando la subjetividad del proceso y permitiendo una estandarización precisa sin necesidad de intervención humana experta.

El sistema utiliza imágenes para identificar patrones visuales asociados con diferentes grados de tostado, mejorando la consistencia y calidad del cacao procesado. Esto optimizará el control del tostado y contribuirá a una mayor eficiencia en la producción.

Los resultados de este estudio proporcionarán una herramienta innovadora para mejorar la estandarización del tostado del cacao, reduciendo la variabilidad en el proceso y facilitando su aplicación en distintos contextos industriales.

1.1. Descripción del problema

El cacao (*Theobroma cacao* L.) es una materia prima de alto valor en la agroindustria, y su calidad final depende de múltiples factores, incluyendo la variedad genética, las condiciones de cultivo y las etapas del procesamiento poscosecha. En el Perú, las regiones de Cusco, Amazonas, Ayacucho y Junín representan aproximadamente el 80% de la producción nacional de cacao (Chávez *et al.*, 2022). La mayoría de los productores en estas zonas son pequeños agricultores que realizan el procesamiento inicial del cacao, incluyendo fermentación, secado y tostado, antes de comercializar los granos.

El tostado es una de las etapas más críticas en este proceso, ya que influye directamente en el desarrollo de compuestos volátiles responsables del aroma y sabor, así como en la reducción de la acidez, el amargor y la astringencia del cacao (Gutiérrez, 2017). Además, el tostado permite la deshidratación adecuada de los granos y reduce la carga microbiana, garantizando un producto más seguro para su consumo.

A pesar de su importancia, la evaluación del grado de tostado se realiza mayoritariamente de forma empírica, basada en la percepción sensorial de los operarios. Este método subjetivo genera inconsistencias en la calidad del producto final, afectando su aceptación en el mercado y la rentabilidad de los productores (Tan *et al.*, 2019; Hemamalini *et al.*, 2022). Uno de los principales desafíos para mejorar esta evaluación es el costo elevado de los equipos analíticos avanzados, como la Cromatografía de Gases/Espectrometría de Masas (GC-MS), los cuales son inaccesibles para la mayoría de los pequeños productores (Yang *et al.*, 2022).

Ante esta problemática, las técnicas de visión artificial y Redes Neuronales Convolucionales (CNN) han demostrado ser herramientas efectivas para la clasificación y control de calidad en productos agrícolas (Essah *et al.*, 2022). Estudios recientes han

validado el uso de estas tecnologías en la clasificación automática de alimentos como frutas, vegetales, granos y café, analizando características visuales como color, forma y textura (Oliveira M. *et al.*, 2021; Hossain *et al.*, 2018; Tripathi ; Maktedar, 2021; Valero ; Anderson, 2020).

En este contexto, la presente investigación propone el desarrollo de un sistema de clasificación automática del grado de tostado de los granos de cacao, utilizando técnicas de aprendizaje profundo basadas en Redes Neuronales Convolucionales. Este enfoque permitirá reducir la subjetividad en la evaluación del tostado, optimizar los tiempos de producción y mejorar la estandarización del proceso, beneficiando especialmente a pequeños productores que buscan mejorar la calidad y competitividad de su cacao en el mercado.

1.2. Formulación del problema

1.2.1. Problema general

¿En qué medida el uso de Redes Neuronales Convolucionales permite evaluar el grado de tostado de los granos de cacao?

1.2.2. Problemas específicos

- ¿Cuáles son los elementos necesarios para implementar un sistema de adquisición de imágenes capaz de capturar las características visuales de los granos de cacao tostados, como el color, tamaño y forma?
- ¿Qué algoritmos de procesamiento de imágenes son los más adecuados para identificar con precisión los granos de cacao?
- ¿Qué estructuras de Redes Neuronales Convolucionales son más apropiadas para clasificar el grado de tostado de los granos de cacao en tiempo real?

- ¿Cuáles son las métricas para comparar la capacidad de los algoritmos implementados para diferenciar los grados de tostado de los granos de cacao?
- ¿Cómo se valida la efectividad del sistema propuesto para clasificar los granos de cacao tostados?

1.3. Justificación de la investigación

Esta investigación propone la implementación de un sistema de visión artificial y aprendizaje automático para evaluar de manera cuantitativa el grado de tostado de los granos de cacao. La adopción de esta tecnología permite reducir la subjetividad y variabilidad inherentes a la evaluación sensorial tradicional, proporcionando un análisis más preciso y reproducible. Con ello, se busca mejorar la estandarización del proceso de tostado y garantizar una mayor uniformidad en la calidad del producto final del tostado.

Además, la automatización del monitoreo colorimétrico permite reducir los tiempos de evaluación, para mejorar la eficiencia operativa y minimizar pérdidas por sobretostado. Esto no solo beneficia a productores artesanales y a la industria chocolatera en general, sino que también abre nuevas posibilidades para la trazabilidad y el control de calidad en la cadena de producción del cacao.

Finalmente, el conocimiento generado en este estudio sirve como referencia para futuras investigaciones y desarrollos tecnológicos en el procesamiento del cacao. La metodología propuesta se puede aplicar a otras etapas críticas de la producción de chocolate, como la fermentación y el secado, contribuyendo al desarrollo de nuevas herramientas para la mejora continua de la industria del cacao.

1.4. Objetivos de la investigación

1.4.1. Objetivo general

Evaluar el grado de tostado de cacao (*Theobroma cacao* L.) mediante Redes Neuronales Convolucionales.

1.4.2. Objetivos específicos

- Implementar un sistema de adquisición de imágenes para capturar la colorimetría de los granos de cacao tostados.
- Desarrollar algoritmos de procesamiento de imágenes para identificar con precisión los granos de cacao.
- Realizar el reajuste de los hiper parámetros de las arquitecturas de Redes Neuronales Convolucionales (*MobileNet-v2*, *ResNet-18*, *ResNet-50*, *ResNet-101* e *Inception-v3*) para que clasifiquen el grado de tostado en los granos de cacao.
- Comparar el rendimiento de las diferentes arquitecturas de Redes Neuronales Convolucionales para la clasificación de los grados de tostado de los granos de cacao, en términos de F1-score, ROC y tiempo de entrenamiento.
- Validar la efectividad de clasificación del grado de tostado de granos de cacao empleando una arquitectura de Red Neuronal Convolutional seleccionada.

CAPÍTULO II: MARCO TEÓRICO

2.1. Antecedentes de la investigación

En la investigación de Harvyanti *et al.* en 2023, el cacao (*Theobroma cacao* L.) se propuso utilizar Redes Neuronales Convolucionales (CNN) para identificar una de las enfermedades más frecuentes en las hojas de cacao, *Lasiodiplodia theobromae* (Pat.). Compararon cuatro arquitecturas CNN: *AlexNet*, *SqueezeNet*, *DarkNet-19* y una CNN modificada, para detectar plantas de cacao infectadas. El conjunto de datos utilizado constó de 1200 imágenes, 600 de plantas sanas y 600 de plantas infectadas. Los mejores resultados se obtuvieron con el modelo *DarkNet-19*, alcanzando una precisión de prueba del 98.61%.

En la misma línea Kumi *et al.* en 2022 demostraron la efectividad de utilizar tecnología móvil y aprendizaje profundo para la detección automatizada de las principales enfermedades que afectan al cultivo de cacao: Brote hinchado y Vaina negra. Los investigadores recopilaron un conjunto de imágenes de frutos de cacao infestados y sanos, y emplearon cuatro modelos de Redes Neuronales Convolucionales (CNN) para clasificarlos: *SSD MobileNet V2*, *EfficientDet D0*, *CenterNet ResNet-50 V2* y *SSD ResNet-50 V1 FPN*. Los resultados muestran que el modelo *SSD ResNet-50 V1 FPN* obtuvo el mejor desempeño, con una mayor precisión media (mAP) y logrando detectar correctamente dos de los tres niveles evaluados. En cuanto al proceso de entrenamiento, este modelo también presentó la menor pérdida de clasificación (23.87%), ligeramente mejor que el *SSD MobileNet V2* (24.95%).

Así mismo, en un estudio realizado por Lopes *et al.* en 2022, se exploró el uso de técnicas de visión por computadora y *Deep Learning* para la clasificación de 5 variedades de granos de cacao: PH16; BN34; SR162; CEPC-2002 y Para-Parazinho (PP). Los investigadores compararon un Sistema de Visión Computacional Profunda (DCVS) y un Sistema de Visión Computacional Tradicional (CVS) para clasificar los granos de cacao

en diferentes variedades. Para el DCVS, utilizaron las arquitecturas *ResNet-18* y *ResNet-50*, mientras que para el CVS experimentaron con algoritmos tradicionales de *Machine Learning*, como Máquinas de Vector Soporte (SVM) y Bosques Aleatorios (RF). Donde emplearon un conjunto de datos con 1,239 muestras para evaluar ambos sistemas. El DCVS utilizando *ResNet-18* obtuvo la mejor precisión, alcanzando el 96.82%, en comparación con el 85.71% del CVS usando SVM.

Por otro parte, un estudio reciente de Yang *et al.* (2022) propone un método de determinación del grado de tostado en granos de cacao utilizando análisis de imágenes y *Machine Learning*. El método buscó reemplazar los costosos equipos analíticos y paneles sensoriales tradicionalmente utilizados. Los investigadores tostaron granos de cacao durante 10 a 40 minutos, capturaron imágenes de estos granos seccionados, y desarrollaron un algoritmo basado en máquinas de aprendizaje extremo (ELM) para extraer características de color y textura. Entrenaron una red ELM con 350 muestras y lograron una precisión de clasificación del 93,75%. Además, identificaron la cafeína y la teobromina como los principales compuestos químicos, lo que les permitió clasificar exitosamente los granos con diferentes niveles de tostado.

Mientras que, Areni *et al.* (2020) desarrolló una aplicación móvil que utiliza algoritmos de *Deep Learning* para clasificar imágenes de cacao en cuatro categorías: frutos sanos, atacados por plagas, atacados por enfermedades y condiciones normales. Entrenado con 615 conjuntos de datos, el sistema alcanzó una precisión del 100% en la identificación de frutos atacados, con una similitud promedio del 83.75% para condiciones normales, 84.87% para ataques de enfermedades y 80.80% para ataques de plagas.

Por otro lado, Adhitya *et al.* en 2020 investigaron el uso de Redes Neuronales Convolucionales (CNN) para la clasificación de granos de cacao de diferentes calidades.

Empleó las siguientes arquitecturas de CNN para extraer las características del conjunto de datos: *ResNet 50*, *ResNet 101*, *Inception*, e *Inception-ResNet architecture*. En este estudio se dividieron las imágenes en 30% para entrenamiento y 70% para pruebas, lograron una precisión del 82.14% al clasificar siete niveles de granos de cacao: Granos enteros, granos partidos, fracciones de granos, granos con piel dañada, granos fermentados, granos no fermentados y granos mohosos. Los resultados mostraron que la arquitectura más rápida fue *ResNet 50*, mientras que *Inception-ResNet* alcanzó la mayor precisión de clasificación, llegando a un 75% de exactitud.

Finalmente, Leme *et al.* (2019) utilizó redes neuronales artificiales como modelo de transformación de color, y modelos de regresión polinomial cuadrática/cúbica y modelos neuronales para aproximar el índice de tostado de granos de café. Este estudio tuvo como objetivo desarrollar un modelo de visión computacional que relacionó los patrones de color en el espacio CIE Lab* y en escala de grises con la escala numérica de tostado definida por la Specialty Coffee Association of America. En el caso de granos enteros, la prueba de Tukey (95% de nivel de confianza) mostró que el modelo neuronal superó a los modelos polinomiales para la aproximación del índice de tostado, obteniendo un factor R^2 de 0.99. Para granos molidos, el modelo de regresión polinomial cuadrática en escala de grises fue el mejor predictor, con un error promedio de 0.93.

2.2. Bases teóricas

2.2.1. Aplicaciones de *Machine Learning* en la industria alimentaria

El *Machine Learning* es un área de la inteligencia artificial que se ocupa de identificar patrones en los datos y utilizar estos para hacer predicciones sobre datos no vistos anteriormente (Vieira *et al.*, 2020). Las técnicas de *Machine Learning* han ganado un interés creciente en la industria alimentaria, ya que permiten el desarrollo de modelos

predictivos y sistemas inteligentes que aprenden patrones en los datos y toman decisiones en base a ellos. Esto las convierte en herramientas valiosas para mejorar los procesos de control de calidad, abordando desafíos complejos de la industria. Las aplicaciones de *Machine Learning* han demostrado su relevancia en diversas áreas, desde la clasificación de granos de cacao hasta la detección de defectos en productos finales.

Un caso de estudio destacado es el trabajo realizado por Oliveira *et al.* (2021), donde se desarrolló un sistema de clasificación automática de granos de cacao fermentados y no fermentados utilizando técnicas de *Deep Learning*. El sistema logró una precisión del 93% en la clasificación, demostrando el potencial de estas tecnologías para mejorar la eficiencia y la trazabilidad en la cadena de suministro del cacao.

Otro ejemplo relevante es el estudio de Hortinela, C., & Tupas, R. (2022), en el cual se recolectaron y clasificaron los granos de cacao con la asistencia de un experto en cacao, y posteriormente entrenaron el modelo en base a las propiedades físicas de cada tipo. El modelo entrenado mostró un desempeño satisfactorio, alcanzando una precisión general del 90.67%.

Además, de estos casos específicos, las aplicaciones de *Machine Learning* en la industria alimentaria abarcan una amplia gama de tareas, como la predicción de la vida útil de los alimentos, la optimización de procesos de producción, la detección de patógenos y contaminantes, y el análisis de preferencias del consumidor (Liu *et al.*, 2022; Qing *et al.*, 2021).

Estos avances tecnológicos ofrecen beneficios significativos para la industria alimentaria, incluyendo un aumento en la eficiencia, una mayor consistencia en la calidad del producto, una reducción de los costos asociados a los rechazos y una mejor trazabilidad a lo largo de la cadena de suministro. Además, la implementación de estas

tecnologías contribuye a minimizar el riesgo de contaminación y a mejorar la seguridad alimentaria (Essah *et al.*, 2022).

2.2.2. Métricas de evaluación para clasificación de datos

Según Hossin & Sulaiman (2015), las métricas de evaluación son herramientas fundamentales en el aprendizaje automático, especialmente para problemas de clasificación. Permiten cuantificar el rendimiento de un modelo y tomar decisiones informadas sobre su ajuste y aplicación. En este sentido, la correcta elección de las métricas de evaluación es esencial para obtener un clasificador eficiente, especialmente en modelos generativos.

2.2.2.1. Matriz de confusión

Según Burkov A. (2019), una matriz de confusión es una tabla que describe el rendimiento de un modelo de clasificación, como se muestra en la Tabla 1 Esta tabla registra la cantidad de coincidencias entre la clasificación real y la predicción del modelo.

Para mantener la coherencia, las columnas representan las predicciones del modelo, mientras que las filas muestran la clasificación real. Las clases están organizadas en el mismo orden en ambas dimensiones, por lo que los elementos correctamente clasificados se encuentran en la diagonal principal (de arriba a la izquierda a abajo a la derecha), indicando las veces que el modelo acertó.

Tabla 1*Matriz de confusión multiclase*

Clasificación real	Clasificación predicha				
	Clases	a	b	c	d
	A	VN	FP	VN	VN
	B	FN	VP	FN	FN
	C	VN	FP	VN	VN
	D	VN	FP	VN	VN

Nota. La clase B se toma como referencia para el cálculo de las métricas. Los falsos positivos (FP) y falsos negativos (FN) considerados en las fórmulas corresponden únicamente a los valores ubicados en la misma fila y columna que el verdadero positivo (VP) dentro de la matriz de confusión. Extraído de (Margherita Grandini, 2020).

Donde:

- VP: Verdadero positivo
- FP: Falso positivo
- VN: Verdadero negativo
- FN: Falso negativo

La matriz de confusión proporciona una visión detallada del rendimiento del modelo, permitiendo identificar no solo cuántas predicciones fueron correctas, sino también los tipos específicos de errores que el modelo está cometiendo. Es fundamental para calcular otras métricas como Exactitud, Precisión, Sensibilidad, y F1-Score

2.2.2.2. Presición global

La presición global (o Accuracy), según Burkov (2019) mide la tasa de predicciones correctas sobre el número total de instancias evaluadas. Esta métrica es ampliamente utilizada debido a su facilidad de cálculo, baja complejidad y aplicabilidad.

Matemáticamente, se define como la ecuación 1:

$$acc = \frac{VP + VN}{VP + FP + VN + FN} \quad (1)$$

2.2.2.3. Sensibilidad

La sensibilidad (o Recall) mide la proporción de verdaderos positivos que son correctamente identificados por un modelo (Drzewiecki, 2017). Matemáticamente, se define como la ecuación 2.

$$R = \frac{VP}{VP + FN} \quad (2)$$

2.2.2.4. Precisión

Es el porcentaje de verdaderos positivos sobre todos los que el modelo predijo como positivos (Burkov, 2019). Matemáticamente se define como la ecuación 3.

$$P = \frac{VP}{VP + FP} \quad (3)$$

2.2.2.5. F1-score

El F1-Score es la media armónica de la Precisión y la Sensibilidad. Se utiliza para balancear ambos aspectos, proporcionando una métrica única que considera tanto los falsos positivos como los falsos negativos (Bekkar, Djemaa, Alitouche, 2013). Matemáticamente, la precisión y el F1-score se definen en la ecuación 4.

$$F1 = \frac{2 \cdot P \cdot R}{P + R} \quad (4)$$

Donde:

- P: Precisión
- R: Sensibilidad

2.2.2.6. Curva ROC

La Curva ROC (Receiver Operating Characteristic) es una representación gráfica que ilustra el rendimiento de un modelo de clasificación binaria a medida que varía el umbral de decisión. La curva se traza con el FPR (False Positive Rate) en el eje X y el TPR (True Positive Rate o Recall) en el eje Y, las cuales se definen por las ecuaciones 5 y 6, respectivamente.


$$FPR = \frac{FP}{FP + VN} \quad (5)$$

$$TPR = \frac{VP}{VP + FN} \quad (6)$$

El Área Bajo la Curva ROC (AUC-ROC) varía entre 0 y 1, donde 1 indica un modelo perfecto y 0.5 indica un modelo semejante a una clasificación aleatoria (Fawcett, 2006). En la Figura 1 se pueden apreciar diferentes AUC ROC.

Figura 1

Curva ROC (mostrada en gris).



Nota. Extraído de Burkov (2019)

2.2.2.7. Sensibilidad macro y Precisión macro

Para calcular la precisión macro y el Recall macro, primero se identifican los verdaderos positivos (VP), falsos positivos (FP) y falsos negativos (FN) para cada clase. Luego, se calcula el Recall y la precisión de cada clase utilizando las ecuaciones 2 y 3, respectivamente.

Finalmente, se obtiene el promedio de estos valores a través de todas las clases, lo que da como resultado las métricas macro-promediadas, proporcionando una medida equilibrada del rendimiento del modelo sin considerar el tamaño de cada clase. Matemáticamente, la sensibilidad y precisión macro se definen en las ecuaciones 7 y 8, respectivamente.

$$Recall_{macro} = \frac{\sum_{k=1}^N Recall_{clase\ N}}{N} \quad (7)$$

$$Precisión_{macro} = \frac{\sum_{k=1}^N Precisión_{clase\ N}}{N} \quad (8)$$

2.2.3. Contenido de humedad

Según Singh y Heldman (2014), el contenido de humedad se refiere a la cantidad de agua presente en una muestra, y es una propiedad fundamental en el análisis de alimentos y productos agrícolas, ya que influye directamente en su calidad, estabilidad y comportamiento durante procesos térmicos como el tostado o secado.

Existen dos formas comúnmente aceptadas para expresar el contenido de humedad:

- Base húmeda (M%): Representa la proporción de agua respecto a la masa total de la muestra (es decir, incluyendo tanto el agua como la materia seca). Se calcula como el cociente entre la masa de agua y la masa total del producto húmedo.

$$M\% = \frac{m_{agua}}{m_{muestra}} \quad (9)$$

- Base seca (D%): Indica la cantidad de agua en relación con la masa de sólidos secos. Es decir, se refiere a la proporción de agua por unidad de materia seca presente en la muestra.

$$D\% = \frac{m_{agua}}{m_{sólidos\ secos}} \quad (10)$$

La elección entre una u otra base depende del tipo de análisis que se realice. En estudios de secado o transferencia de masa, la base seca suele ser preferida porque permite describir la pérdida de agua sin que las variaciones de la masa total afecten el contenido de humedad. Combinando las ecuaciones 9 y 10, la relación entre ambos puede ser descrita de por la ecuación 11:

$$D\% = \frac{M\%}{1 - M\%} \quad (11)$$


2.2.4. Balance de masa para el sistema de tostación

La Figura 2 ilustra el esquema del sistema de tostación en un tostador de tambor rotatorio. A la izquierda, se observa el tambor que contiene los granos de cacao, el cual gira con una velocidad angular ω , promoviendo la mezcla y exposición uniforme de los granos al calor. El calentamiento se produce principalmente por el quemador, que suministra energía térmica ($\dot{Q}_{quemador}$) a la base del tambor, mientras que parte de este calor se pierde al ambiente ($\dot{Q}_{perdido}$) a través de la superficie externa.

El recuadro de la derecha amplía la interacción entre las fases sólida y gaseosa dentro del tambor. Los gases (mezcla de aire, vapor de agua y compuestos orgánicos volátiles – COVs) intercambian calor y masa con los granos de cacao mediante convección ($\dot{Q}_{gas-grano}$) y transferencia de masa ($\dot{m}_{agua\ evap}$ y $\dot{m}_{COVs}$). El flujo de aire de entrada ($\dot{m}_{aire,ent}$) alimenta el sistema, mientras que los gases de salida ($\dot{m}_{gas\ sal}$) arrastran humedad y compuestos volátiles. Adicionalmente, se representan las transferencias de calor entre el quemador, la pared del tambor y los granos ($\dot{Q}_{pared-grano}$), así como entre la pared y los gases ($\dot{Q}_{pared-gas}$), destacando la compleja red de interacciones térmicas y de masa que caracterizan el proceso de tostación.

Figura 2

Representación del balance de masa y energía en el proceso de tostado de granos de cacao.



Se considera un sistema abierto (con flujo de salida) y transitorio (con propiedades que varían en el tiempo).

El principio fundamental es:

$$\frac{dM(t)}{dt} = \sum \dot{m}_{entrada} - \sum \dot{m}_{salida} - \text{pérdidas} \quad (12)$$

Para el balance de masa se considera:

- No hay masa que entra al sistema.
- La masa abandona el sistema únicamente a través de los gases y vapores generados.
- No hay generación ni consumo de masa total en sí misma, sino transformación de componentes.

La tasa de cambio de la masa total de los granos ($M_{grano}(t)$) es igual a la tasa neta de masa que abandona el sistema. En consecuencia, la ecuación (12) se reescribe de la siguiente forma:

$$\frac{dM(t)}{dt} = -\dot{m}_{agua,evap} - \dot{m}_{COVs} = \text{perdidas} \quad (13)$$

Donde:

- $M_{grano}(t)$: Masa total del sistema en el tiempo t (kg).
- t : Tiempo (s).
- $\dot{m}_{agua,evap}$: Flujo másico de evaporación de agua desde la superficie de los granos hacia el entorno (kg/s). Esta masa cruza la frontera del sistema.
- $\dot{m}_{COVs}$: Flujo másico de liberación de otros compuestos orgánicos volátiles (diferentes al agua) desde los granos hacia el entorno (kg/s). Esta masa también cruza la frontera del sistema.

2.3. Marco conceptual

2.3.1. Cacao (*Theobroma cacao* L.)

El cacao es el fruto del árbol del mismo nombre, que crece predominantemente en regiones tropicales de África y América del Sur. Este árbol, perteneciente a la familia Malvaceae, produce semillas conocidas como granos de cacao. Los granos de cacao son la materia prima esencial para la producción de chocolate y otros productos derivados del cacao, como el polvo de cacao y la manteca de cacao (Asefi *et al.*, 2023).

A nivel taxonómico, *Theobroma cacao* L. se clasifica dentro de tres grandes grupos genéticos: Criollo, Forastero y Trinitario, cada uno con características físicas y

sensoriales distintas (ICCO, 2021). En la Figura 3 se muestra una imagen referencial de granos de cacao secos.

Figura 3

Granos de cacao (Theobroma cacao L.) en estado seco.



Nota. Imagen extraída de Vecteezy (2025).

En el Perú, y particularmente en la región de Cusco, destaca la variedad Chuncho, originaria del Valle de La Convención, reconocida internacionalmente por su alta calidad sensorial, riqueza en polifenoles y gran diversidad genética (Hurtado & Mamani, 2018). Se caracteriza por presentar frutos de color amarillo y características sensoriales suaves, lo que la convierte en una de las variedades más apreciadas para la producción de chocolate fino.

Dado que el comportamiento del grano durante el proceso de tostado está influenciado directamente por su composición química, se consideró relevante describir los valores típicos de su análisis proximal. La Tabla 2 resume los componentes típicos encontrados en los granos de cacao criollo peruano.

Tabla 2

Análisis proximal del cacao criollo peruano fermentado y seco.

Componente	Rango típico (%)
Humedad	4.2
Proteínas	9.9
Grasa	49.4
Carbohidratos	39.7
Ceniza	0.9


Nota. Adaptado de Febrianto, A., Wang, S., & Zhu, F. (2021).

2.3.2. Proceso de producción del chocolate

El proceso de producción de chocolate comienza con la agricultura de los granos de cacao, seguida de la fermentación, donde se desarrollan sabores clave y aromas; en esta etapa ocurren cambios significativos en el pH y la temperatura que afectan la estabilidad de compuestos bioactivos, especialmente los polifenoles (Guillen-Guerrero & de la Rosa-Millan, 2025). Luego, los granos se secan al sol o con una fuente de calor para reducir su humedad y se tuestan para eliminar compuestos no deseados y potenciar el aroma. Durante esta etapa se producen reacciones químicas como Maillard y caramelización, que influyen en el color, sabor y propiedades químicas del cacao. Posteriormente, la alcalinización reduce la amargura y estabiliza el color antes de mezclar los ingredientes principales. El conchado mejora textura y sabor, y finalmente el chocolate se enfría de forma controlada para lograr la calidad y apariencia deseada. Este proceso se resume en la Figura 4, que describe el flujo productivo para obtener chocolate a partir de granos previamente fermentados y secos.

Figura 4

Diagrama de flujo del proceso de elaboración del chocolate.



Nota. Diagrama de flujo adaptado de Palga Mejía (2023) y Ticona Apaza (2024).

2.3.3. Tostado de los granos de cacao

Durante el proceso de tostado, se desencadenan una serie de reacciones físicas y químicas complejas. Desde el punto de vista físico, el calor aplicado provoca la evaporación del agua restante contenida en los granos. Donde la temperatura y el tiempo de tostado son factores clave que determinan la extensión de estas reacciones y, por lo tanto, el grado de tostado alcanzado.

Por otro lado, durante el proceso de tostado ocurren diversas reacciones químicas que incluyen la degradación de polisacáridos y proteínas presentes en los granos de cacao, lo que conduce a la formación de compuestos volátiles y no volátiles responsables del desarrollo del aroma y sabor (Peña *et al.*, 2022). Asimismo, según Afoakwa (2014), se producen reacciones de pardeamiento no enzimático, principalmente la reacción de Maillard, que ocurre entre azúcares reductores y aminoácidos, y la caramelización, que implica la descomposición térmica de los azúcares. Ambas reacciones contribuyen significativamente al color marrón característico del cacao tostado y a la generación de sabores complejos esenciales para el perfil sensorial del producto final.

Se distinguen varios grados de tostado, desde un tostado ligero hasta un tostado oscuro o intenso. Un tostado ligero preserva más los sabores frutales y florales del cacao, mientras que un tostado más intenso produce sabores más tostados, ahumados y amargos (Afoakwa *et al.*, 2008).

Un tostado adecuado puede mejorar la solubilidad y la viscosidad de la masa de cacao, además de reducir la acidez y la astringencia (Gutiérrez, 2017). Sin embargo, un tostado excesivo puede provocar la formación de compuestos indeseables, como la acrilamida, y la degradación de compuestos beneficiosos, como los polifenoles (Peña *et al.*, 2022).

2.3.4. Tipos de tostado del cacao

Existen diversas técnicas de tostado que varían en cuanto al principio de transferencia de calor, tiempos de procesamiento, eficiencia energética y preservación de compuestos funcionales. A continuación, se describen los principales tipos de tostado empleados en la industria y la investigación.

2.3.4.1. Tostado convencional

El tostado convencional se realiza en grandes tambores rotativos donde el cacao es calentado principalmente por convección de aire caliente, complementado por conducción y fricción entre los granos. Las temperaturas suelen oscilar entre 110 °C y 150 °C, con tiempos de procesamiento que van desde 20 minutos hasta 2 horas, dependiendo de la calidad del grano y el perfil sensorial deseado.

2.3.4.2. Tostado en capa delgada

En este método, el cacao se tuesta una vez que ha sido desgranado (nibs) o procesado como licor (pasta de cacao). La transferencia de calor se realiza en cilindros de calentamiento o mediante fricción asistida por aire caliente. Esta técnica permite un control más preciso del proceso, obteniendo un tostado homogéneo al trabajar con partículas de tamaño reducido. Sin embargo, requiere etapas adicionales de procesamiento previo y puede ocasionar cierta pérdida de aromas volátiles propios del grano entero (Beckett, 2008)

2.3.4.3. Tostado de lecho fluidizado

El tostado en lecho fluidizado consiste en suspender los granos de cacao sobre una corriente de aire caliente que fluye desde la parte inferior, generando un movimiento similar al de ebullición. Este sistema permite una transferencia de calor muy eficiente y rápida, favoreciendo la formación de compuestos aromáticos como las pirazinas, claves

en el aroma del chocolate. Aunque es un método muy efectivo, su implementación requiere equipos especializados con un mayor consumo energético.

2.3.5. Grados de tostado del cacao

Aunque no existe una escala universalmente estandarizada para los grados de tostado del cacao, en la práctica sensorial e industrial se reconocen generalmente cuatro grados: bajo, medio, alto y sobre-tostado. Estos grados se diferencian por el color del grano, el perfil de aroma, la textura y el sabor, los cuales se ven afectados por la temperatura y el tiempo de exposición al calor.

Según Bioversity International (2021), los grados de tostado del cacao pueden clasificarse sensorialmente mediante una escala del 0 al 10, donde un tostado bajo corresponde a valores entre 2 y 3, medio entre 4 y 6, alto en 7 y sobre-tostado entre 8 y 10. Esta escala permite estandarizar la intensidad del tostado percibida por evaluadores entrenados.

2.3.6. Efecto del tostado sobre el color de los granos de cacao

Antes del tostado, los granos de cacao presentan naturalmente un color marrón oscuro, debido a la formación de pigmentos durante la fermentación y el secado. Según Asefi *et al.* (2023), el color del cacao se ve afectado por los compuestos formados durante el tostado, como los derivados de la epicatequina. Estos compuestos intensifican el color del cacao, haciéndolo más oscuro.

Durante el tostado, los polifenoles y antocianinas presentes en los granos crudos experimentan reacciones químicas, como oxidación, polimerización, reacciones de Maillard y degradación de proteínas, que generan pigmentos marrones. Según Lee, Yoo, Lee, Kwon y Pyun (2001) la concentración de estos pigmentos alcanza su punto máximo a 134 °C y disminuye a temperaturas más altas.

El análisis de pigmentos generado durante el tostado se considera una técnica precisa para evaluar la calidad del cacao tostado y ha sido utilizada en estudios que analizan la relación entre temperatura, humedad y coloración del grano.

2.3.7. Parámetros en el proceso de tostado de cacao

2.3.7.1. Temperatura de tostado

La temperatura es uno de los parámetros más críticos en el proceso de tostado. Generalmente, de acuerdo con Asefi *et al.* (2023) el cacao se tuesta a temperaturas que varían entre 120 °C y 150 °C. La elección de la temperatura depende del perfil de sabor deseado y del tipo de producto final. Un tostado a temperaturas más altas puede desarrollar sabores más intensos, reducir el contenido de agua y disminuir la concentración de polifenoles. En cambio, temperaturas más bajas conservan más compuestos volátiles y nutrientes, que son sensibles al calor. En la Tabla 3 se muestran diferentes técnicas de tostado dependiendo del tipo de muestra.

Tabla 3

Técnicas de tostado aplicadas a diferentes tipos de muestra de cacao.

Forma de la muestra	Técnica de tostado y temperatura	Referencias
Grano de cacao	Horno convectivo y tostador de lecho fluidizado. 110 – 140 °C	Peña <i>et al.</i> (2022)
Grano de cacao	Horno convectivo capaz de cambiar la velocidad del flujo de aire. 135–150 °C	Żyżelewicz, Budryn, <i>et al.</i> (2014)
Grano de cacao	Horno de vapor sobrecalentado. 150–250 °C	Zzaman and Yang (2013)
Cacao en polvo	Horno convectivo. 130–150 °C	Quiroz-Reyes and Fogliano (2018)
Licor de cacao no fermentado	Tostador en baño de aceite. 170 °C	Nurhayati <i>et al.</i> (2019)

Nota. Adaptado de Peña *et al.* (2022)

2.3.7.2. Tiempo del tostado

El tiempo de exposición al calor también es crucial. Los tiempos de tostado suelen oscilar entre 15 y 45 minutos, dependiendo de la temperatura y del tipo de grano de cacao. Un tostado prolongado puede llevar a un desarrollo excesivo de sabores amargos y sobretostados, mientras que un tostado corto puede no desarrollar completamente los sabores deseados.

2.3.7.3. Pérdida de humedad

Durante el tostado, los granos de cacao pierden una cantidad significativa de humedad. La pérdida de humedad es importante porque afecta la textura y el contenido de humedad del producto final. Según Peña, Ataç Mogol y Fogliano (2024), el contenido de agua se reduce a aproximadamente 1% y la actividad del agua a 0.2.

2.3.7.4. Evaluación sensorial

Las pruebas sensoriales son esenciales para determinar la calidad del tostado. Los expertos catadores evalúan el sabor, el aroma, color y la textura del cacao tostado para asegurar que se hayan alcanzado las características deseadas (Afoakwa, 2014). Estas evaluaciones ayudan a ajustar los parámetros de tostado para optimizar el perfil sensorial del producto final.

2.3.8. Machine Learning

El aprendizaje automático (*Machine Learning*) es una rama de la inteligencia artificial que permite a las computadoras aprender de los datos y mejorar su rendimiento en una tarea específica sin ser programadas explícitamente para ello. Consiste en recolectar ejemplos representativos de un fenómeno, ya sean observaciones reales o datos generados, para construir mediante algoritmos un modelo estadístico capaz de identificar patrones, hacer predicciones y tomar decisiones de forma autónoma. De esta manera, el


sistema “aprende” a partir de la experiencia contenida en los datos, ajustando sus parámetros internos para mejorar progresivamente su precisión (Burkov, 2019).

En la Figura 5 se observa un esquema general de las ramas principales del *Machine Learning* (ML), dividido en dos enfoques: supervisado y no supervisado. El aprendizaje supervisado se basa en entrenar modelos con datos etiquetados y se subdivide en tareas de clasificación, donde se predicen categorías (por ejemplo, identificar si una imagen es de un gato o un perro), y regresión, donde se estiman valores continuos (como predecir el precio de una casa).

Por otro lado, el aprendizaje no supervisado trabaja con datos sin etiquetar y busca descubrir patrones ocultos. Aquí se encuentra el clustering, técnica que agrupa datos similares entre sí, siendo K-means uno de los algoritmos más representativos, su objetivo es agrupar un conjunto de datos en K grupos o clústeres según su similitud ((Bishop, 2006). También se incluyen en este enfoque ciertas redes neuronales, que ayudan a identificar estructuras complejas en los datos. Este diagrama permite visualizar cómo se organizan y relacionan los principales métodos dentro del campo del *Machine Learning*.

Figura 5

Ramas del Machine Learning.



Nota. Adaptado de Vieira, S., Pinaya, W. H. L.; Mechelli, A. (2020). Introduction to *Machine Learning*. In *Machine Learning*. Academic Press.

2.3.9. Redes Neuronales Convolucionales (CNN)

Una Red Neuronal Convolutiva (CNN) es un tipo de red neuronal profunda diseñada para procesar y analizar datos estructurados en cuadrículas, como imágenes.

La arquitectura de una CNN se refiere a la estructura y organización de sus capas, incluyendo cómo se conectan y cómo procesan los datos. Estas capas aplican filtros a las entradas y extraen características como bordes y texturas, las cuales se combinan y analizan en capas más profundas para reconocer patrones complejos. La arquitectura de las CNN es jerárquica y requiere muchas imágenes para entrenarse y aprender a identificar objetos.

En la Tabla 4 se presentan las principales capas que conforman una Red Neuronal Convolutiva (CNN), junto con su función y operación dentro del modelo (Alzubaidi *et al.*, J Big Data, 2021)

Tabla 4

Capas de una Red Neuronal Convolutiva y sus características.

Capa	Función	Operación Realizada
Capa Convolutiva	Extraer características de la imagen	Aplica filtros (kernels) sobre la imagen de entrada para generar mapas de características.
Capa de Pooling	Reducir la dimensión de los mapas de características	Aplica operaciones como max pooling o average pooling para reducir la cantidad de datos y mejorar eficiencia.
Capa de Activación	Introducir no linealidad	Aplica funciones como ReLU, Sigmoid o Tanh para mejorar la capacidad de aprendizaje del modelo.
Capa Fully Connected (FC)	Realizar clasificación	Conecta todas las neuronas de la capa anterior a la siguiente capa, obteniendo la salida final.
Capa de Pérdida (Loss Function)	Calcular el error del modelo	Compara la salida del modelo con la salida real y ajusta los pesos en el entrenamiento.

Nota. Adaptado de Alzubaidi *et al.* (2021).

2.3.9.1. Tipos de arquitecturas de Redes Neuronales Convolucionales

Según Koonce & Koonce, (2021), las Redes Residuales (*ResNets*) son una arquitectura avanzada de redes neuronales profundas que introducen un concepto innovador llamado "conexiones residuales". Este enfoque permite a la red aprender de manera más eficiente al centrarse en la diferencia o "residuo" entre la entrada y la salida esperada. En lugar de aprender la función completa, la red se enfoca en esta pequeña discrepancia, lo que facilita la construcción de modelos más profundos sin sufrir problemas de degradación. Un ejemplo común es *ResNet-50*, que cuenta con 50 capas, una representación gráfica de este tipo de arquitectura se encuentra en la Figura 6.


Por otro lado, *MobileNet* es un modelo de red neuronal convolucional diseñado específicamente para ser ligero y eficiente en términos de parámetros y capacidad de cómputo, lo que lo hace ideal para dispositivos móviles. *MobileNet-v2* (Akay *et al.*, 2021) tiene una estructura optimizada, la cual se puede observar en la Figura 7, que le permite mantener un número significativamente menor de parámetros en comparación con modelos como *ResNet*, a pesar de tener 28 capas.

Inception es otra arquitectura relevante, la cual se puede visualizar en la Figura 8, especialmente en el contexto de Redes Neuronales Convolucionales profundas. Es conocida por su estructura modular basada en bloques *Inception*, los cuales permiten una extracción eficiente de características a múltiples escalas. *Inception* está diseñada para mejorar la precisión manteniendo un número razonable de parámetros, lo que la hace una opción equilibrada entre rendimiento y eficiencia computacional. A diferencia de *ResNet* y *MobileNet*, *Inception* busca optimizar la capacidad de aprendizaje sin incrementar excesivamente la profundidad, utilizando convoluciones factoradas y reduciendo el número de parámetros innecesarios.

Estas arquitecturas han sido comparadas en diversos estudios, incluyendo el trabajo de Liu (2023), quien analizó su desempeño en la autenticación biométrica en dispositivos móviles. Su investigación muestra que cada arquitectura tiene sus propias ventajas, dependiendo del contexto y las necesidades específicas de la aplicación, como eficiencia, precisión o capacidad de operación.

Figura 6


Arquitectura de la red neuronal convolucional ResNet.



Nota. Adaptado de Williams & Li (2018)

Figura 7


Arquitectura de la red neuronal convolucional MobileNet-v2.



Nota. Adaptado de Akay & Du *et al.* (2021).

Figura 8

Arquitectura de la red neuronal convolucional Inception-v3.



Nota. Adaptado de Villanueva *et al.* (2022)

En la Tabla 5 se presenta una comparación entre diferentes arquitecturas de Redes Neuronales Convolucionales, incluyendo *ResNet-50*, *MobileNet-v2* y *Inception-v3-53*, adaptado de He *et al.* (2016), Sandler *et al.* (2018) y Redmon & Farhadi (2018).

Tabla 5

Comparación de arquitecturas de redes neuronales convolucionales.

Arquitectura	N° de Capas	Memoria de parámetros	Tamaño de entrada de la imagen	Ventaja principal	Aplicación común
<i>MobileNet-v2</i>	53	14 MB	224x224	Ligera y eficiente para dispositivos móviles	Visión artificial en teléfonos y IoT
<i>ResNet-18</i>	18	45 MB	224x224	Evita la degradación del gradiente con conexiones residuales Visión artificial en teléfonos y IoT	Clasificación de imágenes / Visión artificial en teléfonos y IoT
<i>ResNet-50</i>	50	98 MB	224x224		
<i>ResNet-101</i>	101	171 MB	224x224		
<i>Inception-v3</i>	48	91 MB	299x299	Optimizada para detección en tiempo real	YOLO (detección de objetos)

Nota. Adaptado de MathWorks (2024)

2.3.10. Sensores y dispositivos de adquisición de imágenes

En el campo de la captura de imágenes digitales, la cámara es el componente fundamental que permite la adquisición de fotografías y videos (Holst y Lomheim, 2011; Nakamura, 2016). Dentro de estas cámaras, los dos principales tipos de sensores de imagen ampliamente utilizados son los dispositivos de carga acoplada (CCD) y los sensores de óxido metálico complementario sobre silicio (CMOS).


Los sensores CCD funcionan acumulando los fotones que inciden en cada celda activa durante el tiempo de exposición. Por otro lado, los sensores CMOS aprovechan directamente la conductividad de fotodetectores individuales, que pueden activarse y amplificarse localmente antes de ser leídos mediante un esquema de multiplexación

(Holst & Lomheim, 2011). En la Figura 9 se muestran características adicionales de ambos tipos de sensores.

Tradicionalmente, los sensores CCD han sido preferidos en aplicaciones de alta calidad, como las cámaras réflex digitales, mientras que los CMOS han destacado en aplicaciones de bajo consumo. No obstante, en la actualidad, los sensores CMOS se utilizan en la mayoría de las cámaras digitales.

Figura 9

Mapa mental de sensores y dispositivos de adquisición de imágenes.



Nota. Adaptado de Nakamura (2016).


Por otro lado, el proceso de calibración implica determinar los parámetros intrínsecos y extrínsecos de la cámara, lo que permite corregir distorsiones de la lente y

establecer la relación entre las coordenadas 2D de la imagen y las coordenadas 3D del mundo real (Szeliski, 2022). Esto se logra mediante la captura de imágenes de un patrón de calibración conocido y el posterior procesamiento de estas imágenes para estimar los parámetros de la cámara (Zhang, 2000).

La implementación de un proceso de calibración es crucial para garantizar la precisión y fiabilidad de las aplicaciones de visión artificial. (Hartley & Zisserman, 2003). En la Figura 10 se aprecian los pasos para una correcta calibración de una cámara para la adquisición de imágenes.

Figura 10

Calibración de una cámara para la adquisición de imágenes.



Nota. Adaptado de Zhang (2000).

2.3.11. Técnicas de procesamiento de imágenes


El procesamiento de imágenes digitales es un campo fundamental que involucra una serie de técnicas y algoritmos para analizar y extraer información valiosa a partir de

datos visuales. Este proceso consta de la manipulación y el tratamiento de imágenes digitales mediante la ejecución de diversas etapas, tal como se ilustra en la Figura 11, la cual consiste en: adquisición de imágenes, preprocesamiento, segmentación, extracción de características, selección de características y clasificación.

Figura 11

Técnicas de procesamiento de imágenes.

Técnicas de procesamiento de imágenes



Nota. Adaptado de Szeliski (2022).

2.3.11.1. Adquisición de imágenes

Constituye el primer paso dentro del proceso de procesamiento digital de imágenes. Esta etapa se encarga de capturar y digitalizar la información visual proveniente del mundo real, convirtiéndola en una representación numérica que pueda ser procesada y analizada por medios computacionales (Szeliski, 2022).

2.3.11.2. Preprocesamiento de imágenes

Según Gonzalez & Woods (2018) el preprocesamiento implica la aplicación de técnicas para mejorar la calidad de la imagen y prepararla para análisis posteriores. Algunas técnicas comunes incluyen el ajuste de brillo, contraste y la corrección de distorsiones geométricas.

2.3.11.3. Segmentación de imágenes

Implica dividir la imagen en regiones u objetos de interés. Existen varias técnicas de segmentación, como la umbralización, donde se asigna un valor umbral para separar los píxeles en diferentes regiones (Szeliski, 2022). Otra técnica de segmentación es la detección de bordes, que identifica los píxeles que marcan los límites entre diferentes regiones de la imagen. Los métodos más empleados son el detector de bordes de Canny o el detector de bordes de Sobel (Gonzalez & Woods, 2018).

2.3.11.4. Extracción de características

Se aplican para identificar y cuantificar las propiedades relevantes para la clasificación o análisis posterior. Esto puede incluir características de color, textura, forma y otras características morfológicas (Zerouaoui & Idri, 2021). Un ejemplo de estas técnicas es el histograma de color que puede ser utilizado para caracterizar la distribución de los valores de color en una región de la imagen.

CAPÍTULO III: MATERIALES Y MÉTODOS

3.1. Muestra

3.1.1. Muestra para proceso de tostado

La muestra utilizada para el proceso de tostado estuvo constituida por granos de cacao (*Theobroma cacao* L.) en estado seco, procedentes de la provincia de La Convención, distrito de Quellouno (Cusco, Perú). Estos granos fueron obtenidos mediante el proceso tradicional de fermentación y secado al sol, siguiendo prácticas empleadas por los productores locales.

3.1.2. Muestra para procesamiento de imágenes y entrenamiento de CNNs

La muestra utilizada para el procesamiento de imágenes y el entrenamiento de las redes neuronales convolucionales (CNNs) estuvo compuesta por imágenes capturadas de granos de cacao (*Theobroma cacao* L.) durante el proceso de tostado. Cada dos minutos se seleccionaron aleatoriamente 10 granos, los cuales fueron fotografiados antes de ser almacenados en bolsas herméticas tipo ziplock.

3.2. Materiales y equipos

3.2.1. Materiales

- Portamuestras blanco (16x20 cm) de polipropileno.
- Vernier Calibre 150mm Bahco.
- Bolsas Ziplock (5x15 cm).

3.2.2. Equipos

Tabla 6 *Equipos utilizados en la investigación.*

Equipos	Especificaciones
Tostadora de cacao	Tambor rotatorio de manufactura local, calentamiento a gas sin control de temperatura, capacidad 500 g
Balanza analítica	Eurotech modelo: FSF-A3304B
Balanza de humedad	PCE MA-50X (capacidad: 50 g / precisión: 0.1 mg)
Cámara web	Teraware, resolución Full HD 1080P
Aro de luz	Roadtrip 10", múltiples temperaturas de color
Termocupla	Termopar tipo K con rosca M6, cable de 3 metros
Soporte de cámara	Estructura para fijación de la cámara
Laptop	Acer Nitro AN515-55, Intel Core i5, 16 GB RAM, GPU NVIDIA GTX 1650
Ventilador	Convencional 12 V, utilizado para enfriamiento post-tostado

3.2.3. Software

- Software Matlab versión 2024a
- AutoCAD versión 2023
- LabVIEW 2017

3.3. Ámbito espacial y temporal

Esta investigación se desarrolló en el Laboratorio de Control de Procesos (PIQ211) de la Escuela Profesional de Ingeniería Química de la Universidad Nacional de San Antonio Abad del Cusco, durante el periodo de agosto a diciembre del 2024.

3.4. Diseño de la investigación

De acuerdo con la clasificación de Hernández Sampieri, R. (2014), la investigación corresponde a tipo: aplicada, con enfoque cuantitativo, de alcance correlacional y cuasi experimental.

3.5. Identificación de variables

3.5.1. Variables independientes

- El tiempo de tostado

3.5.2. Variables dependientes

- Temperatura interna del tostador
- Humedad del grano
- Color de la cáscara del grano

3.6. Proceso de tostado

3.6.1. Granos de cacao

Para el proceso de tostado, se trabajó con granos previamente fermentados y secados. Tras la recepción de los granos de cacao fermentados y secados, se llevó a cabo una selección manual preliminar con la finalidad de eliminar impurezas y materiales no aptos para el proceso de tostado. Esta selección consistió en:

- Descartar granos de tamaño pequeño o deformes, que podrían generar resultados no representativos durante el tostado.

- Remover cáscaras vacías (vainas sin almendra), provenientes de defectos en la cosecha o el despulpado.
- Separar restos vegetales como hojas secas, pedazos de ramas y otras impurezas arrastradas durante la cosecha, fermentación o secado.


Previo al uso de las muestras, se determinó su contenido de humedad inicial mediante el método de estufa a 105 ± 2 °C durante 24 horas, de acuerdo con la norma AOAC (2015), método 934.01 (ver Anexo A).

3.6.2. Equipo utilizado y condiciones de tostado

El proceso de tostado se realizó en un tostador de tambor rotatorio manufactura local (Figura 12, ver Apéndice A para el plano), el cual operó con un sistema de calentamiento a gas sin control automático de temperatura, donde se procesaron lotes de 300 gramos de cacao por batch.

Figura 12

Tostador de cacao de manufactura local.





La agitación del tambor se mantuvo constante a 23 rpm para garantizar una distribución uniforme del calor durante el proceso de tostado. La temperatura se registró mediante una termocupla tipo K ubicada en la zona central del tambor, cuyos datos fueron capturados y monitoreados en tiempo real a través de un programa desarrollado en LabVIEW (ver Figura 13). Este tipo de sensor genera una señal eléctrica de muy bajo voltaje (en el orden de los milivoltios) como resultado de la diferencia de temperatura entre dos metales distintos unidos en sus extremos.

La señal fue leída por un módulo de adquisición DAQmx y su conversión a grados Celsius se realizó directamente en LabVIEW, a través de una tarea configurada que interpreta el voltaje como temperatura. Esto permitió monitorear la temperatura en tiempo real, visualizarla mediante un gráfico ("Waveform Chart") y registrar los datos automáticamente en un archivo. Con esta configuración se obtuvo la curva de temperatura en función del tiempo. Las temperaturas finales de tostado estuvieron en el rango de 150 - 180 °C, con tiempos entre 20 a 30 minutos.

Figura 13

Programa desarrollado en LabVIEW para registro de temperatura.





3.6.3. Humedad

Durante el proceso de tostado, se seleccionó una muestra de 10 granos de cacao por cada punto de muestreo. Aunque en la práctica industrial usualmente se toman solo 1 o 2 granos al final del proceso (incluso en lotes de hasta 10 kg) debido a que se asume una distribución uniforme de calor en todo el lote, en este estudio se optó por un número mayor. La elección de 10 granos permitió obtener una muestra más representativa para el análisis, sin afectar la continuidad del proceso ni la integridad del lote, y facilitó un seguimiento más detallado del comportamiento del grano durante el tostado.

Estas muestras se recolectaron cada dos minutos durante el proceso de tostado, y cada muestra, una vez extraída, se colocó sobre el portamuestras para ser fotografiada (toma de muestras para el procesamiento de imágenes). Luego, las muestras se dejaron enfriar y, una vez frías, se almacenaron en bolsas herméticas tipo ziplock para su conservación y posterior análisis de humedad.

El análisis del contenido de humedad se realizó 2 horas después mediante una balanza de humedad modelo PCE MA-50X. Este equipo cuenta con un rango máximo de

50 g, una precisión de 0,1 mg y requiere un peso mínimo de muestra de 5 gramos para realizar el análisis. Para ello, en cada análisis se descascarillaron los granos, se trituraron y se colocaron los nibs sobre la balanza del equipo hasta superar el peso mínimo necesario.

El equipo utilizado combina una balanza analítica con un sistema de calentamiento por lámpara halógena, y determina el contenido de humedad a partir del principio de pérdida de masa por secado. Para ello, la muestra se pesa inicialmente y luego se somete a calentamiento; a medida que el agua se evapora, la masa disminuye. Esta variación es registrada continuamente por el equipo hasta que se alcanza un valor constante de masa, lo que indica que la muestra ha perdido toda su humedad libre. La diferencia entre la masa inicial y la masa final corresponde al contenido de humedad de la muestra, expresado como un porcentaje del peso original.

La balanza PCE MA-50X permite expresar el contenido de humedad de tres formas distintas: en base húmeda (M%), en base seca (D%), y como proporción respecto al contenido inicial (R%). Por defecto, el equipo mostró los resultados en M% (contenido de humedad en base húmeda, M%), que representó el porcentaje de agua respecto a la masa total de la muestra al inicio del análisis (ver Figura 14). Esta forma de expresión fue, posteriormente, convertida a base seca (D%) para construir la curva de humedad en función del tiempo, lo cual permitió analizar la cinética de secado durante el proceso de tostado.

Figura 14


Medición de humedad en granos de cacao (minuto 12) – Balanza PCE MA-50X.



En la Figura 15 se muestra el diagrama de bloques que resume la obtención de las muestras.

Figura 15

Obtención de muestras de cacao con diferentes grados de tostado.



3.7. Procedimiento para la implementación del sistema de adquisición de imágenes

Para la implementación del Sistema de Adquisición de Imágenes (SAI), se propuso el diseño representado en la Figura 16, el cual resume e ilustra la disposición de sus componentes principales. Este diseño incluye la estructura de soporte, el porta muestras, el aro de luz, la cámara, y la computadora utilizada para el procesamiento de las imágenes.


Para la captura de imágenes se hizo uso de una cámara web Full HD 1080P Teraware, ubicada en posición perpendicular del porta - muestras. Por otro lado, el aro de luz se orientó hacia el porta muestras con el objetivo de proporcionar una iluminación homogénea y minimizar las variaciones en la calidad de las imágenes adquiridas.

La cámara y el aro de luz fueron conectados a una computadora portátil mediante una interfaz USB, donde se empleó el software MATLAB para el procesamiento de imágenes, donde se configuraron parámetros como distorsión de lente, selección de tipo de iluminación para asegurar la calidad de las imágenes adquiridas.

Una vez implementado el SAI, se tomaron fotos de las muestras ya tostadas de cacao para posteriormente utilizarlas en el desarrollo de los algoritmos de procesamiento de imágenes.

Figura 16

Propuesta del sistema de adquisición de imágenes.



3.8. Procedimiento para el desarrollo de algoritmos de procesamiento de imágenes

Una vez recopilado el conjunto de imágenes a través del SAI, se seleccionó una imagen de manera aleatoria para iniciar la implementación del código correspondiente a los algoritmos de procesamiento de imágenes. El desarrollo de estos algoritmos incluyó diversas técnicas computacionales, tales como recorte de imagen, creación de máscara RGB para la eliminación de fondo, binarización de imagen, umbralización, identificación de regiones de interés, detección de bordes, detección de boxes, clustering mediante K-means, detección de puntos convexos para reconocimiento de elipses.


Estas técnicas permitieron aislar los granos de cacao dentro de las imágenes, delimitándolos mediante recuadros para su posterior segmentación y etiquetado manual en función al color de cada grano. A continuación, cada imagen fue recortada individualmente según las regiones segmentadas y clasificada, en cinco categorías de grado de tostado: 1, 2, 3, 4 y 5; con el apoyo de 3 expertos en tostado de cacao.

Posteriormente, los fragmentos de imágenes fueron organizados en carpetas correspondientes a cada grado de tostado, conformando así una base de datos estructurada destinada al entrenamiento y validación de las redes neuronales convolucionales (CNN).

El proceso de desarrollo de los algoritmos de procesamiento de imágenes se resume en el diagrama de bloques presentado en la Figura 17, donde se ilustran las etapas clave desde la adquisición de imágenes hasta la generación de la base de datos.

Figura 17

Procedimiento para el desarrollo de algoritmos para el procesamiento de imágenes.



3.9. Procedimiento para el reajuste de los hiper parámetros de Redes Neuronales

Convolucionales

Según los autores citados en los antecedentes de este trabajo, se seleccionaron tres arquitecturas de Redes Neuronales Convolucionales (CNN) para el reconocimiento y clasificación de granos de cacao: MobileNet, ResNet e Inception. La elección de estas arquitecturas permitió evaluar cuál de sus versiones específicas (como *MobileNet-v2*, *ResNet-18*, *ResNet-50*, *ResNet-101* e *Inception-v3*) ofrece un mejor desempeño para la

tarea. El entrenamiento y validación de los modelos consistió en la siguiente división de la base de datos:

- 70% para entrenamiento: Este subconjunto se utilizó para entrenar los diferentes modelos de CNN. Durante esta fase, los modelos aprendieron a partir de los datos para ajustar sus parámetros, aplicación de un optimizador, la cantidad de épocas, etc.
- 20% para validación: Este subconjunto se empleó para evaluar el desempeño de los modelos durante el entrenamiento. Las pruebas de validación se realizaron en paralelo con el entrenamiento de las CNN.


3.10. Procedimiento para la comparación de la capacidad de los algoritmos desarrollados

El 10% de la base de datos se reservó para la evaluación final de los modelos una vez entrenados. Este subconjunto se utilizó para medir la precisión y exactitud de los modelos en datos no vistos durante el proceso de entrenamiento y validación.

Para evaluar la exactitud de la predicción del grado de tostado de las estructuras de CNN entrenadas, se generó la matriz de confusión para realizar el cálculo de las métricas como Accuracy, Precisión, Sensibilidad, F1-score, la curva ROC. La arquitectura que obtuvo los mejores resultados en estas métricas fue seleccionada como la más adecuada para la tarea de clasificación de grados de tostado en granos de tostado. En la Figura 18 se muestra un diagrama de bloques que resume el entrenamiento y evaluación de las arquitecturas de CNN.

Figura 18

Evaluación de arquitecturas de CNNs entrenadas.




3.11. Procedimiento para la validación de la efectividad del sistema propuesto.

Para evaluar el desempeño del modelo, se aplicó la red neuronal convolucional (CNN) entrenada con las mejores métricas a diferentes procesos de granos de cacao. Durante este proceso, se extrajeron muestras cada dos minutos y se colocaron en el portamuestras, permitiendo que el algoritmo predijera automáticamente el grado de tostado correspondiente.

La Figura 19 presenta un resumen del proceso de validación del desempeño del modelo, mostrando la comparación entre las predicciones del algoritmo y la clasificación realizada por los expertos.

Figura 19

Validación del desempeño de la CNN seleccionada.



CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1. Resultados proceso de tostado

4.1.1. Curvas de temperatura


Los datos de temperatura, adquiridos mediante la termocupla tipo K y el módulo DAQmx a través de LabVIEW según lo detallado en el apartado 3.6.2., fueron exportados a Excel para su organización y posteriormente procesado en MATLAB para la generación de las curvas de temperatura en función del tiempo. La Figura 20 presenta estas curvas, mostrando los perfiles térmicos del interior del tambor del tostador para cada proceso de tostado ejecutado.

El registro de las curvas de temperatura durante el proceso de tostado es fundamental para comprender las condiciones térmicas bajo las cuales los granos de cacao experimentan cambios físicos y químicos, como la pérdida de humedad, la generación de compuestos volátiles y la transformación de color. Estas transformaciones permiten clasificar visualmente el grado de tostado, por lo que monitorear la evolución térmica proporciona un contexto clave para interpretar los resultados de visión artificial, al correlacionar las imágenes adquiridas con el tiempo y la temperatura del proceso. La medición de temperatura dentro del tambor se realizó mediante una termocupla instalada para registrar la temperatura del gas en su interior, compuesto por una mezcla de aire, vapor de agua y compuestos orgánicos volátiles (COVs) liberados durante el tostado.

La medición no representa de manera directa la temperatura de los granos de cacao, ya que el sensor no se encontraba embebido en ellos ni fijado a su superficie. No obstante, debido a la rotación del tambor, es posible que la termocupla haya tenido contactos breves y esporádicos con algunos granos, provocando pequeñas fluctuaciones puntuales en la señal.

Figura 20

Curvas de temperatura durante los procesos de tostado.



El análisis de las curvas de temperatura evidencia que, en ausencia de granos (línea azul - TTO), la fase gaseosa alcanzó temperaturas más elevadas en menor tiempo, lo que indica que la energía suministrada por el sistema de calentamiento se destinó principalmente a aumentar la energía interna del gas. En contraste, cuando el tambor contenía granos (TC4, TC5, TC6 y TC7), la pendiente de incremento térmico del gas fue menor. Este comportamiento se atribuye a que una fracción de la energía transferida desde las paredes del tambor se destinó al calentamiento de la masa sólida de los granos, así como a los procesos de evaporación de agua y volatilización de compuestos orgánicos volátiles (COVs). Estos fenómenos representan transferencias de calor adicionales que reducen la energía disponible para incrementar la temperatura del gas.

El análisis de las curvas de temperatura obtenidas en presencia de granos de cacao (TC4, TC5, TC6 y TC7) revela un comportamiento característico: un incremento inicial pronunciado seguido por una disminución progresiva en la pendiente hasta alcanzar un

estado cuasiestacionario. Este régimen ocurre cuando la temperatura del gas se estabiliza alrededor de un valor constante, lo cual indica que la tasa neta de acumulación de energía en el gas tiende a cero. En este punto, la energía suministrada al gas se equilibra con la energía que este transfiere o pierde a través de los mecanismos considerados en el balance de energía.

En los instantes iniciales del proceso, el término $\dot{Q}_{pared \rightarrow gas}(t)$ domina el balance, ya que el gradiente de temperatura entre las paredes del tambor y el gas es máximo. Parte de esta energía se transfiere inmediatamente hacia los granos ($\dot{Q}_{granos \rightarrow gas}(t)$ negativo desde la perspectiva del gas, ya que fluye hacia el sólido), contribuyendo a elevar su temperatura interna. De forma simultánea, se inicia la evaporación de agua ($\dot{m}_{agua, evap} \Delta H_{vap, agua}$) y la liberación de compuestos volátiles que extraen calor latente del gas, reduciendo la velocidad de incremento térmico.

A medida que avanza el tueste, la temperatura de los granos se aproxima a la del gas, disminuyendo la magnitud de $\dot{Q}_{pared \rightarrow gas}(t)$. Sin embargo, el flujo de evaporación de agua y liberación de volátiles tiende a mantenerse significativa, especialmente en etapas intermedias, debido a la continua deshidratación y a las reacciones químicas del grano. Esta demanda energética, sumada a la pérdida de energía por el flujo saliente de gases calientes ($-\dot{m}_{gas, sal}(t) h_{gas, sal}(t)$), compensa progresivamente el calor suministrado desde las paredes, llevando al sistema gaseoso a un equilibrio dinámico.

En el estado cuasiestacionario, el término dominante en la disipación de energía suele ser el asociado a la salida de gases calientes ($-\dot{m}_{gas, sal}(t) h_{gas, sal}(t)$), ya que el flujo másico de aire, vapor de agua y volátiles transporta cantidades significativas de entalpía fuera del volumen de control. Los términos de evaporación de agua y volatilización, aunque menores en etapas finales, continúan presentes, contribuyendo al mantenimiento de la temperatura estable.

Este comportamiento refleja que, en presencia de granos, la capacidad calorífica total del sistema aumenta, y la energía aportada se distribuye en múltiples procesos simultáneos (calentamiento del sólido, evaporación, volatilización y pérdidas), lo que limita el ascenso térmico del gas y condiciona la temperatura de equilibrio alcanzada.

4.1.2. Curva de contenido de humedad

En las primeras etapas del tueste, cuando el contenido de humedad del grano es elevado, gran parte del calor suministrado se destina a la evaporación del agua, lo que mantiene la temperatura interna por debajo del umbral necesario para que las reacciones de Maillard avancen de manera significativa; además, el exceso de agua diluye la concentración de azúcares reductores y aminoácidos en la fase sólida, ralentizando su cinética. Conforme la humedad disminuye por evaporación, la temperatura del grano aumenta y la concentración de solutos se eleva, favoreciendo así la velocidad de estas reacciones y potenciando la formación de compuestos aromáticos y de color, como las melanoidinas. Sin embargo, si la humedad desciende en exceso y la superficie del grano se seca demasiado rápido, la movilidad molecular de los reactivos en la capa externa se reduce, lo que puede ralentizar la reacción en esa zona, aunque permanezca activa en el interior donde persiste cierta humedad residual.

En la Tabla 7 se presentan los datos obtenidos del análisis de humedad de los granos de cacao. La primera columna corresponde al tiempo de muestreo, medido cada dos minutos durante el proceso de tostado. La segunda columna muestra los valores de humedad en base húmeda (M%), registrados mediante la balanza de humedad PCE MA-50X, mientras que la tercera columna corresponde a los valores convertidos a base seca (D%) mediante la ecuación 11.

Tabla 7


Datos de humedad (Base Húmeda y Base Seca) y cambio de masa de los granos de cacao en el tostado.

Tiempo (min)	Humedad de granos de cacao (M%)	Humedad de granos de cacao (D%)
0	8.3000	9.0513
2	8.0920	8.8045
4	5.1881	5.4720
6	4.8853	5.1362
8	4.1791	4.3614
10	3.6858	3.8269
12	3.0793	3.1771
14	3.1501	3.2526
16	2.7108	2.7863
18	2.1546	2.2020
20	2.4078	2.4672
22	2.1855	2.2343
24	1.9132	1.9505
26	1.8334	1.8676
28	1.8193	1.8530

Los valores de humedad en base seca fueron empleados para construir la Figura 21, la cual representa la evolución del contenido de humedad en función del tiempo.

Figura 21

Curva de humedad en base seca a lo largo del proceso de tostado.



En la Figura 21, se observa la evolución del contenido de humedad (D%) a lo largo del proceso de tostado. La humedad inicial, fue de 9.05%, y esta disminuyó gradualmente hasta alcanzar valores cercanos al 1.9 %. Este comportamiento concuerda con lo señalado por Peña et al. (2022), que indica que durante el tostado la humedad del grano se reduce de manera continua hasta niveles comprendidos entre el 2 % y el 3 %.

Para modelar la cinética de secado y la pérdida de humedad de la muestra, se partió de la ecuación 13 del balance de masa:

$$\frac{dM(t)}{dt} = -\dot{m}_{agua,evap} - \dot{m}_{COVs} = \text{perdidas} \quad (13)$$

Se sabe que:

$$M(t) = M_{seco}(1 + D(t))$$

Reemplazando en la ecuación 13:

$$\frac{dM(t)}{dt} = M_{seco} \frac{d}{dt} (1 + D(t))$$

$$\frac{dM(t)}{dt} = M_{seco} \frac{dD(t)}{dt} \quad (14)$$

Si el flujo de evaporación del agua es proporcional al contenido de humedad del grano en ese instante, entonces:

$$p\acute{e}rdid\acute{a}s = kD(t)M_{seco} \quad (15)$$

Reemplazando la ecuación 14 y 15 en 13, se tiene:

$$M_{eco} \frac{dD(t)}{dt} = kD(t)M_{seco}$$

$$\frac{dD(t)}{D(t)} = -kdt$$

Integrando esta ecuación diferencial:

$$\int_{D_{in}}^{D_{final}} \frac{dD(t)}{D(t)} = -k \int_0^t dt$$

$$\ln\left(\frac{D_{final}}{D_{in}}\right) = -kt$$

$$D_{final} = D_{in}e^{-kt}$$

La ecuación resultante presenta una forma funcional análoga al modelo cinético de Lewis y Pabis (Inyang *et al.*, 2018), que es comúnmente utilizado para describir la cinética de secado en diversos materiales. El modelo tiene la forma $MR = ae^{-kt}$. Donde, MR es la razón de humedad (Moisture Ratio), el coeficiente $a = 9.0513$ representa la humedad inicial, el término exponencial $e^{-0.0754t}$ describe la velocidad de disminución


de la humedad. Finalmente, el coeficiente de determinación (R^2) obtenido fue de 0.969, lo que indica un buen ajuste del modelo a los datos experimentales.

4.1.3. Curva de cambio de color respecto a la temperatura y tiempo

En la Figura 22, se ilustra la evolución del color de los granos de cacao en función del tiempo y la temperatura de tostado. Se observa una relación directa entre el aumento de temperatura y el oscurecimiento del grano, lo que valida la clasificación en grados de tostado del 1 al 5. Este cambio cromático está vinculado a las reacciones térmicas internas (como Maillard y caramelización), las cuales también están influenciadas por el contenido de humedad residual. Por ello, el color se convierte en un indicador clave tanto para el control del proceso como para la calibración de modelos de clasificación mediante redes neuronales convolucionales (CNN), dada su alta correlación con el grado de tostado percibido sensorialmente.

Figura 22

Cambio de color de granos de cacao en función del tiempo y temperatura de tostado.




4.2. Implementación del sistema de adquisición de imágenes

4.2.1. Diseño de estructura de soporte del SAI

Los planos de la estructura propuesta para el SAI fueron diseñados en AutoCAD, permitiendo una visualización detallada en 3D, como se puede ver en la Figura 23. A partir de estos planos, se realizó el corte láser del material MDF (Medium Density Fiberboard), seleccionado por su facilidad de manipulación y precisión en los acabados, para la fabricación del prototipo físico.

Figura 23

Diseño 3D de la estructura del sistema de adquisición de imágenes.



Nota. a) Estructura del SAI diseñada en 3D. b) Piezas para ensamblar el SAI cortadas en material MDF


4.2.2. Iluminación del Sistema de adquisición de imágenes

Se seleccionó un aro de luz de 26 cm de diámetro, orientado hacia el porta muestras para garantizar una iluminación homogénea. Se optó por luz blanca fría, ya que ofrecía mejor contraste y facilitaba la segmentación de los granos, a diferencia de la luz cálida y la luz neutra, que generaban variaciones cromáticas. La Figura 24 muestra

fotografías comparativas, donde la luz blanca fría demostró ser la opción más adecuada para el procesamiento de imágenes.

Figura 24

Granos de cacao bajo diferentes tipos de luces.



Nota. a) Granos de cacao bajo luz cálida. b) Granos de cacao bajo luz neutra. c) Granos de cacao bajo luz blanca fría.


4.2.3. Corrección de distorsión óptica

La cámara web Full HD 1080P Teraware, presentó distorsión de ojo de pez, un efecto común en lentes gran angular que provoca deformaciones en la imagen. Para corregir la distorsión se utilizó una calibración basada en un patrón de tablero de ajedrez.

Este procedimiento consistió en capturar imágenes de una hoja con un patrón cuadrículado impreso, permitiendo identificar la magnitud y tipo de distorsión mediante la comparación de los píxeles en distintas regiones de la imagen, como se puede observar en la Figura 25.

Figura 25

Calibración de cámara del SAI para corrección de distorsión de ojo de pez.




La Figura 26 muestra el gráfico de errores de reproyección obtenidos durante la calibración de la cámara, donde se observa que la primera imagen presenta un error ligeramente superior a la segunda. Ambas se encuentran cercanas al error medio global

de 1.01 píxeles, indicado por la línea azul discontinua. Según el Manual para la Calibración de Cámaras Fotográficas de la UNAM (2020), un error promedio inferior a un píxel es considerado aceptable. En este caso, el valor obtenido supera ligeramente este umbral, por lo que podrían aplicarse mejoras en la calidad del patrón de calibración, la detección de puntos y las condiciones de iluminación para aumentar la precisión.

Figura 26


Error de reproyección de la calibración de la distorsión de ojo de pez en cámara.



En la Figura 27 se muestra el Sistema de Adquisición de Imágenes (SAI) diseñado para la captura y análisis de granos de cacao tostado. El sistema está compuesto por una cámara montada en una estructura elevada con un aro de luz LED para garantizar una iluminación homogénea. Los granos están organizados sobre una superficie blanca, lo que muestra un entorno controlado para la captura de imágenes.

Figura 27

Sistema de adquisición de imágenes en operación.



Para visualizar las imágenes capturadas por el sistema de adquisición de imágenes de los granos de cacao tostados, consultar el Apéndice B.

4.2.4. Distribución de tamaño de granos de cacao

Una vez implementado el sistema de adquisición de imágenes, este facilitó la obtención de las distribuciones de tamaño de los granos de cacao en los siete procesos de tostado realizados. Para ello, se colocaron 3 granos sobre el portamuestras (grande, mediano y pequeño) y se capturaron imágenes en alta resolución, lo que permitió que el SAI identificara cuántos píxeles conformaban cada grano en la imagen. Posteriormente, cada uno de estos granos fue medido manualmente utilizando un vernier, obteniendo sus longitudes reales en milímetros.

Con esta información se calculó el factor de conversión de píxeles a milímetros, al comparar el tamaño en píxeles detectado por el sistema de adquisición de imágenes con la medición real en milímetros.


Siendo el factor de conversión: $Factor_{ctamaño} = 0.1099 \left(\frac{\text{milímetros}}{\text{píxeles}} \right)$

Este factor fue introducido en el código de MATLAB, permitiendo que el sistema identificara automáticamente las dimensiones reales (en mm) de cada grano detectado en las imágenes, sin necesidad de medirlos manualmente uno por uno (Ver apéndice C para visualizar cálculo de factor de corrección de tamaño). De esta manera, el SAI pudo generar las distribuciones de tamaño para cada proceso de tostado de forma rápida, objetiva y eficiente.

En la Figura 28 se presenta la distribución de tamaño correspondiente al primer proceso de tostado, mientras que los histogramas de los demás procesos pueden consultarse en el Apéndice D.

Figura 28

Distribución de tamaños de los granos de cacao de la corrida 1.



Los resultados de las siete distribuciones de largo y ancho de los granos de cacao indican una distribución sesgada hacia la izquierda. Las medidas de tendencia central muestran que la longitud promedio de los granos es de 21.0 mm, mientras que el ancho

promedio es de 11.7 mm. Además, la baja dispersión de los datos sugiere una homogeneidad considerable en las dimensiones de los granos.

La homogeneidad en el tamaño de los granos de cacao es un factor clave en el procesamiento, ya que influye directamente en la eficiencia del tostado. Como señala Beckett (2008), cuando las condiciones de tostado se establecen para el tamaño promedio del grano, los más pequeños tienden a sobre-tostarse, mientras que los más grandes pueden no alcanzar la temperatura interna adecuada, afectando la conversión de los precursores del sabor.

4.3. Desarrollo de algoritmos de procesamiento de imágenes


4.3.1. Preprocesamiento de imágenes

El preprocesamiento de imágenes consistió en cargar todas las imágenes obtenidas por el SAI de los granos de cacao tostados en MATLAB. Posteriormente, se recortaron para enfocar exclusivamente el área donde se encuentran los granos, eliminando los bordes del portamuestras y el fondo.

Además, se eliminó el fondo blanco del portamuestras utilizando la herramienta Color Thresholder de MATLAB. Para la segmentación de color, MATLAB ofrece cuatro métodos (RGB, HSV, YCbCr y L*a*b), como se puede observar en la Figura 29; en este caso, se utilizó RGB, ya que permitió aislar con mayor precisión los tonos grises del fondo sin afectar las tonalidades marrones de los granos de cacao.

Figura 29

Ventana de selección de técnica de segmentación de imágenes de color Thresholder.



En la Tabla 8 se presentan las coordenadas utilizadas para la aplicación de la máscara RGB, la cual permitió aislar con precisión los granos de cacao al eliminar el fondo no deseado. Esta máscara facilitó el reconocimiento de los granos por parte del algoritmo, evitando posibles confusiones. En la Figura 30 se observa el proceso completo, que incluye la imagen original, la aplicación de la máscara RGB y la binarización final, lo que fue de utilidad para la detección y segmentación de los granos.


Tabla 8

Coordenadas de máscara RGB creada en color Thresholder.

	R	G	B
Límite mínimo	0.000	0.000	0.000
Límite máximo	150.000	80.000	51.000

Figura 30

Aplicación de máscara RGB en color Threshold.



Nota. En la Figura 30 se puede visualizar: a) Foto de granos de cacao antes de la máscara RGB. b) Foto de granos de cacao sin fondo después de la aplicación de máscara RGB. c) Foto de granos de cacao en forma binaria.

4.3.2. Identificación de granos individuales

Se utilizaron imágenes binarias para identificar las regiones de interés, donde los píxeles blancos (valor 1) representaban los granos de cacao y los píxeles negros (valor 0) correspondían al fondo. Para contabilizar los granos, se realizó un barrido de píxeles en dos direcciones: de izquierda a derecha y de arriba hacia abajo, registrando como regiones de interés aquellos valores iguales a 1. Esta primera clasificación permitió obtener información estadística sobre el tamaño de los granos y la cantidad de píxeles que los conforman. A partir de estos datos, se establecieron tres categorías en función del área de cada grano en píxeles:

- Grano pequeño = 8500 píxeles
- Grano mediano = 9000 píxeles
- Grano grande = 26000 píxeles

Para visualizar y diferenciar los granos en la imagen, se utilizó el comando boxes, que enmarcó cada grano según su clasificación:

Box Rojo: Aplicada a regiones de tamaño entre 26000 y 8500 píxeles, es decir granos individuales.

4.3.3. Separación de granos superpuestos

Para abordar la identificación de granos de cacao superpuestos en las imágenes obtenidas, se implementaron criterios y métodos específicos dentro del Sistema de Adquisición de Imágenes (SAI). En primer lugar, se estableció que las regiones con áreas


mayores a 26,000 píxeles correspondían potencialmente a conglomerados de dos o más granos, por lo que estas zonas fueron enmarcadas automáticamente mediante un "box" azul. Este umbral se definió empíricamente, a partir del análisis del área promedio de granos individuales detectados en diferentes condiciones de tostado.

Para la separación de estos granos adheridos o muy próximos, se aplicaron dos enfoques complementarios de segmentación:

- Algoritmo K-means Clustering: Este método no supervisado permitió la agrupación de píxeles en función de su densidad y proximidad espacial. Las regiones con conexiones delgadas o de baja densidad entre dos cuerpos principales fueron separadas mediante segmentación, generando un "box" amarillo. Esta técnica fue útil cuando los granos estaban unidos por pequeños puentes de materia o sombras, ya que lograba identificar límites difusos entre objetos contiguos.
- Reconocimiento de objetos elipsoidales superpuestos: En casos donde los granos se encontraban altamente unidos, sin distinción clara de fronteras, se recurrió a un método basado en el ajuste de elipses propuesto por Zou et al. (2020), el cual se muestra en la Figura 31.

Figura 31

Diagrama secuencial del método de reconocimiento de objetos elipsoidales.



Nota: La imagen (a) corresponde a una imagen binaria sintética con cuatro elipses; en (b) se presenta la generación de elipses candidatas a partir de píxeles máximos regionales (puntos rojos); en (c) se superponen todas las elipses candidatas; en (d) el contorno se divide en segmentos utilizando puntos cóncavos (círculos verdes); y en (e) se muestra el resultado final obtenido al resolver la optimización para identificar los segmentos que corresponden a las elipses candidatas.

Este procedimiento se basó en:

- Generación y filtrado de elipses candidatas: Se aplicó una transformada de distancia Euclidiana sobre la imagen binarizada, lo que permitió detectar centros de masa locales y generar un conjunto de elipses candidatas que representaban posibles objetos individuales. Estas elipses fueron posteriormente filtradas por un criterio de superposición y cobertura.
- Ajuste óptimo por aproximación poligonal: Se identificaron puntos cóncavos en los contornos de las regiones mediante aproximación poligonal, lo que facilitó la partición del contorno en segmentos significativos. A partir de estos, se seleccionó un subconjunto mínimo de elipses capaces de representar cada segmento de

manera eficiente, maximizando la correspondencia entre la forma real y la forma ajustada.

En la Figura 32 se muestra una imagen con los granos de cacao ya segmentados por el algoritmo desarrollado, se observan los boxes rojos en granos individuales y box amarillos para aquellos granos superpuestos y segmentados por K-means.

Figura 32

Aplicación de algoritmo de procesamiento de imágenes a granos de cacao tostado.



En el Apéndice E se puede visualizar el pseudo código, que incluye a detalle los comandos utilizados para el desarrollo del algoritmo de segmentación.

4.3.4. Etiquetado de granos segmentados

Después de la implementación del algoritmo de procesamiento de imágenes, se procedió al etiquetado individual de los granos. En la Figura 33 se muestra el cambio de color en los granos de cacao debido al proceso de tostado, clasificado en cinco grados: grado 1 (crudo) hasta grado 5 (quemado). Para el etiquetado, se proporcionó esta paleta

de referencia a tres expertos en tostado de cacao, quienes clasificaron los granos de una única corrida de tostado según los grados establecidos.

Durante el proceso, se extrajeron entre 9 y 10 granos cada 2 minutos, a lo largo de 26 minutos, obteniendo un total de aproximadamente 140 imágenes por corrida, ya que se realizaron 7 corridas el conjunto de datos total fue de 980.

Figura 33

Escala de color de granos de cacao dividida en 5 grados de tostado.



Las imágenes segmentadas y etiquetadas se almacenaron en carpetas separadas según su grado, con el fin de utilizarlas posteriormente en el entrenamiento de las Redes Neuronales Convolucionales (CNN).

4.4. Reajuste de los hiper parámetros de Redes Neuronales Convolucionales

El reajuste de hiper parámetros incluyó una tasa de aprendizaje de 0.0001, 30 épocas y 360 iteraciones, además de la modificación de la última capa *fully connected* de todas las arquitecturas para adaptarla a cinco salidas, correspondientes a los cinco grados de tostado establecidos. El entrenamiento de las CNN se realizó con un conjunto de datos dividido en 70 % para entrenamiento y 20 % para validación, ejecutándose ambos procesos de manera simultánea. Se empleó el descenso de gradiente estocástico (SGD) como método de optimización, basado en la minimización de la función de pérdida e integrado directamente en el proceso de entrenamiento. El proceso se llevó a cabo


utilizando un total de 575 imágenes seleccionadas de un conjunto inicial de 980 imágenes distribuidas en 5 carpetas diferentes, cada una correspondiente a un grado de evaluación de los granos de cacao. Se emplearon 115 imágenes por grado, tomando como referencia la carpeta con menor cantidad de imágenes (grado 5), de modo que se garantizara un número equilibrado entre grados. Todas las imágenes fueron redimensionadas según el requisito de cada arquitectura: 224×224 píxeles para MobileNet-v2, ResNet-18, ResNet-50 y ResNet-101, y 299×299 píxeles para Inception-v3.

4.4.1. Entrenamiento de *MobileNet-v2*

En la Figura 34, se observa la evolución de la precisión (Accuracy) y la pérdida (Loss) a lo largo del entrenamiento, la línea azul representa el rendimiento del modelo sobre los datos de entrenamiento, mientras que la línea roja muestra los valores obtenidos en la validación.

Figura 34

Curva de entrenamiento de arquitectura MobileNet-v2.



La precisión de entrenamiento aumentó progresivamente, finalizando con un valor cercano al 82% en la última iteración. Sin embargo, se observan fluctuaciones

significativas, lo que sugiere que el modelo aún experimenta cierta variabilidad en el ajuste. Este resultado es similar al obtenido por Adhitya *et al.* (2020), donde se usaron diferentes arquitecturas CNN para clasificar granos de cacao, logrando una precisión del 82.14%.

Por otro lado, la función de pérdida disminuyó constantemente, lo que indica que el modelo aprendió de manera efectiva. No obstante, en las últimas iteraciones, la curva de pérdida de validación se estabilizó, lo que puede sugerir que el modelo ha alcanzado su capacidad de generalización.

En la Figura 35 se observa la matriz de confusión obtenida tras el entrenamiento y evaluación de la arquitectura *MobileNet-v2*. A partir de esta matriz, y utilizando las ecuaciones 2, 3, 7 y 8, se calcularon los valores de Recall y Precisión para cada una de los cinco grados, así como las métricas macro correspondientes para la CNN en general. Los resultados detallados se presentan en la Tabla 9.

Figura 35

Matriz de confusión de MobileNet-v2 en la predicción del grado de tostado del cacao.




Tabla 9


Valores de precisión y Recall calculados de la matriz de confusión de MobileNet-v2.


	Precisión	Recall
Grado 1	0.833	1.000
Grado 2	1.000	0.600
Grado 3	0.800	0.800
Grado 4	0.833	1.000
Grado 5	1.000	1.000
Macro	0.893	0.880

En la Figura 36 se observa la clasificación realizada por *MobileNet-v2* una vez entrenada, se observa que la red puede clasificar correctamente los grados 1,4 y 5; sin embargo, tiene dificultades en el diferenciar el grado 2 y 3.

Figura 36

Clasificación de imágenes de validación por MobileNet-v2.






4.4.2. Entrenamiento de *ResNet-18*

El tiempo de entrenamiento de ResNet-18 duró un tiempo de ejecución de 45 minutos y 8 segundos. En la Figura 37 se muestra que la precisión (Accuracy) de entrenamiento aumentó de forma constante (línea azul), alcanzando valores cercanos al 84% en las últimas iteraciones. La precisión de validación sigue una tendencia similar, lo que sugiere una buena capacidad de generalización del modelo. La pérdida (Loss) disminuyó rápidamente en las primeras iteraciones y se estabilizó en valores bajos.

Figura 37

Curva de entrenamiento de arquitectura ResNet-18.



La validación (línea roja) mostró un comportamiento estable, en comparación con otros modelos como *MobileNet-v2*, *ResNet-18* parece alcanzar una mayor estabilidad en menos tiempo, lo que sugiere que esta arquitectura es más eficiente para la tarea.

En la Figura 38 se observa la matriz de confusión obtenida tras el entrenamiento y evaluación de la arquitectura *ResNet-18*. A partir de esta matriz, y utilizando las ecuaciones 2, 3, 7 y 8, se calcularon los valores de Recall y Precisión para cada una de los cinco grados, así como las métricas macro correspondientes para la CNN en general. Los resultados detallados se presentan en la Tabla 10.

Figura 38

Matriz de confusión de ResNet-18 en la predicción del grado de tostado del cacao.




Tabla 10


Valores de precisión y Recall calculados de la Matriz de confusión de ResNet-18.

	Precisión	Recall
Grado 1	1.000	1.000
Grado 2	0.909	1.000
Grado 3	0.563	0.900
Grado 4	1.000	0.300
Grado 5	1.000	1.000
Macro	0.894	0.840

En la Figura 39 se observa la clasificación realizada por *ResNet-18* una vez entrenada, se observa que la red puede clasificar correctamente los grados 1,2,3 y 5; sin embargo, tiene mucho error en distinguir entre el grado 3 y 4.

Figura 39

Clasificación de imágenes de validación por ResNet-18.




4.4.3. Entrenamiento de *ResNet-50*

En la Figura 40, se puede observar que el entrenamiento tuvo una duración de 1 hora, 50 minutos y 28 segundos. La precisión (Accuracy) del modelo muestra un crecimiento progresivo, alcanzando un valor cercano al 91% al finalizar el entrenamiento.

La pérdida (Loss) disminuyó de manera estable en ambas curvas, lo que indica que el modelo se ajustó correctamente a los datos.

Figura 40

Curva de entrenamiento de arquitectura ResNet-50.



Comparado con *ResNet-18*, el tiempo de entrenamiento de *ResNet-50* fue más del doble, lo cual era esperable debido a la mayor profundidad de la red. Las fluctuaciones en la precisión y pérdida (líneas azules) pueden deberse a la complejidad del modelo y la naturaleza de los datos.

Los resultados de *ResNet-18* (precisión: 84%) y *ResNet-50* (precisión: 91%) se alinean con el estudio de Lopes *et al.* (2022), donde *ResNet-18* obtuvo 96.82% de precisión en la clasificación de variedades de cacao, superando a los métodos

tradicionales. La tendencia observada en tu análisis, donde *ResNet-50* requiere más tiempo de entrenamiento, pero logra mejor precisión, también concuerda con Adhitya *et al.* (2020), donde *ResNet-50* fue más rápido, pero Inception-ResNet alcanzó mayor exactitud.

En la Figura 41 se observa la matriz de confusión obtenida tras el entrenamiento y evaluación de la arquitectura *ResNet-50*. A partir de esta matriz, y utilizando las ecuaciones 2, 3, 7 y 8, se calcularon los valores de Recall y precisión para cada una de los cinco grados, así como las métricas macro correspondientes para la CNN en general. Los resultados detallados se presentan en la Tabla 11.

Figura 41

Matriz de confusión de ResNet-50 en la predicción del grado de tostado del cacao.




Tabla 11


Valores de precisión y Recall calculados de la Matriz de confusión de ResNet-50.


	Precisión	Recall
Grado 1	1.000	1.000
Grado 2	0.833	1.000
Grado 3	0.727	0.800
Grado 4	0.850	0.700
Grado 5	1.000	0.900
Macro	0.882	0.880

En la Figura 42 se observa la clasificación realizada por *ResNet-50* una vez entrenada, se observa que la red puede clasificar correctamente los grados 1,2,3 y 5; presenta errores al distinguir entre el grado 3 y 4, pero son mucho menores que con *ResNet-18*.

Figura 42

Clasificación de imágenes de validación por ResNet-50.






4.4.4. Entrenamiento de *ResNet-101*

En la Figura 43 se visualiza que el entrenamiento tuvo una duración de 2 horas, 55 minutos y 26 segundos para la Arquitectura *ResNet-101*, la precisión (Accuracy) del modelo alcanzó valores cercanos al 97-98% en el conjunto de entrenamiento. La pérdida (Loss) muestra una disminución progresiva, con valores bajos al final del entrenamiento.

Figura 43

Curva de entrenamiento de arquitectura ResNet-101.



ResNet-101 tuvo el tiempo de entrenamiento elevado (casi 3 horas), lo cual es esperable debido a su mayor profundidad. La precisión final es similar a la de *ResNet-50*, lo que sugiere que el aumento de la profundidad no generó una mejora significativa en el rendimiento.

En la Figura 44 se observa la matriz de confusión obtenida tras el entrenamiento y evaluación de la arquitectura *ResNet-101*. A partir de esta matriz, y utilizando las ecuaciones 2, 3, 7 y 8, se calcularon los valores de Recall y precisión para cada una de los cinco grados, así como las métricas macro correspondientes para la CNN en general. Los resultados detallados se presentan en la Tabla 12.

Figura 44

Matriz de confusión de ResNet-101 en la predicción del grado de tostado del cacao.




Tabla 12


Valores de precisión y Recall calculados de la Matriz de confusión de ResNet-101.


	Precisión	Recall
Grado 1	1.000	1.000
Grado 2	0.800	0.800
Grado 3	0.700	0.700
Grado 4	0.818	0.900
Grado 5	1.000	0.900
Macro	0.864	0.860

En la Figura 45 se observa la clasificación realizada por *ResNet-101* una vez entrenada, se observa que la red puede clasificar correctamente los grados 1 y 5, la red aún presenta dificultades para diferenciar los grados 2, 3 y 4, pero el error es menor a comparación de las otras redes.

Figura 45

Clasificación de imágenes de validación por ResNet-101.






4.4.5. Entrenamiento de *Inception-v3*

En la Figura 46, se observa que el entrenamiento tuvo una duración de 3 horas, 18 minutos y 30 segundos, la precisión (Accuracy) del modelo alcanzó valores cercanos al 87% en el conjunto de entrenamiento.

La pérdida (Loss) muestra una reducción progresiva con valores bajos al final del entrenamiento.

Figura 46

Curva de entrenamiento de arquitectura Inception-v3.



Inception-v3 tuvo el tiempo de entrenamiento más alto de todos los modelos evaluados (3h 18min 30s), debido a su arquitectura más compleja. Su precisión final es similar a la de *ResNet-50* y *ResNet-101*, lo que sugiere que el incremento en la arquitectura no necesariamente se traduce en una mejora significativa del rendimiento. El comportamiento de la pérdida y precisión es estable, con fluctuaciones en la precisión debido a la variabilidad de los datos.

En la Figura 47 se observa la matriz de confusión obtenida tras el entrenamiento y evaluación de la arquitectura *ResNet-101*. A partir de esta matriz, y utilizando las ecuaciones 2, 3, 7 y 8, se calcularon los valores de Recall y precisión para cada una de los cinco grados, así como las métricas macro correspondientes para la CNN en general. Los resultados detallados se presentan en la Tabla 13.

Figura 47

Matriz de confusión de Inception-v3 en la predicción del grado de tostado del cacao.




Tabla 13


Valores de precisión y Recall calculados de la Matriz de confusión de Inception-v3.


	Precisión	Recall
Grado 1	1.000	1.000
Grado 2	1.000	1.000
Grado 3	0.889	0.800
Grado 4	0.750	0.900
Grado 5	1.000	0.900
Macro	0.928	0.920

En la Figura 48 se observa la clasificación realizada por *Inception-v3* una vez entrenada, se observa que la red puede clasificar correctamente los grados 1,2,4 y 5, presenta error en el grado 3, pero es mínimo

Figura 48

Clasificación de imágenes de validación por Inception-v3.





4.5. Evaluación de la capacidad de los algoritmos desarrollados.

Para evaluar el desempeño de las arquitecturas de CNN en la clasificación del grado de tostado de los granos de cacao, se analizaron diversas métricas sobre el conjunto de prueba, correspondiente al 10% de la base de datos. Entre estas métricas se incluyen la Precisión, Recall, F1-score y el área bajo la curva ROC (AUC-ROC).

4.5.1. Evaluación de *MobileNet-v2*


En la Figura 49 se muestra la curva ROC obtenido para la arquitectura *MobileNet-v2*. Cada línea de color corresponde a una clase específica, y en la leyenda se indican los

valores del área bajo la curva (AUC) obtenidos para cada una. Los valores de AUC varían entre 0.9175 y 1, lo que indica un alto desempeño del modelo en la discriminación de los grados. En particular, la clase 5 obtuvo un valor AUC de 1, lo que sugiere una clasificación perfecta en este conjunto de prueba.

Además, los puntos de operación del modelo están representados por marcadores circulares en la curva de cada clase, indicando el umbral de decisión óptimo. La línea diagonal discontinua representa la curva de una clasificación aleatoria (AUC = 0.5), y se observa que todas las curvas ROC se encuentran por encima de esta referencia, lo que confirma el buen rendimiento del modelo.

Figura 49

Curva ROC de MobileNet-v2 obtenida en la clasificación de granos de cacao.




4.5.2. Evaluación de ResNet-18

En la Figura 50 se presenta la curva ROC obtenida para la arquitectura *ResNet-18* en la clasificación del grado de tostado de granos de cacao. Se observa un excelente

desempeño del modelo, con valores AUC de 1 en tres de las cinco grados y valores superiores a 0.95 en las restantes.

Figura 50

Curva ROC de ResNet-18 obtenida en la clasificación de granos de cacao.




Los puntos de operación del modelo muestran una alta capacidad de discriminación, con una curva ROC que se mantiene por encima de la línea de clasificación aleatoria ($AUC = 0.5$). Estos resultados indican que la arquitectura ResNet-18 logra una predicción precisa y confiable en la mayoría de los grados evaluados.

4.5.3. Evaluación de ResNet-50

En la Figura 51 se presenta la curva ROC obtenida para la arquitectura ResNet-50 en la clasificación del grado de tostado de granos de cacao. Se observa un desempeño sólido del modelo, con un AUC de 1 en una de las cinco clases, mientras que las demás presentan valores superiores a 0.92, destacando la capacidad del modelo para diferenciar entre categorías.

Figura 51

Curva ROC de ResNet-50 obtenida en la clasificación de granos de cacao.




4.5.4. Evaluación de ResNet-101

En la Figura 52 se presenta la curva ROC obtenida para la arquitectura ResNet-101 en la clasificación del grado de tostado de granos de cacao. Se observa un desempeño sólido del modelo, con un AUC de 1 en una de los cinco grados, lo que indica una clasificación perfecta en esa categoría. Los demás grados presentan valores de AUC superiores a 0.90, con un mínimo de 0.9025, lo que destaca la capacidad del modelo para diferenciar entre las distintas categorías con alta precisión.

Figura 52

Curva ROC de ResNet-101 obtenida en la clasificación de granos de cacao.




4.5.5. Evaluación de *Inception-v3*

En la Figura 53 se presenta la curva ROC obtenida para la arquitectura *Inception-v3* en la clasificación del grado de tostado de granos de cacao. Se observa un desempeño sobresaliente del modelo, con un AUC de 1 en tres de los cinco grados, lo que indica una clasificación perfecta en estas categorías. Los demás grados presentan valores de AUC de 0.9925 y 0.98, lo que demuestra una alta capacidad del modelo para diferenciar entre las distintas categorías con una mínima tasa de error.

Figura 53

Curva ROC de Inception-v3 obtenida en la clasificación de granos de cacao.



En la Tabla 14 se presentan los valores de Precisión Macro, Recall Macro, F1-score Macro y AUC-ROC Macro para cada una de las arquitecturas de CNN evaluadas. El F1-score se calculó utilizando la ecuación 4, proporcionando una medida equilibrada entre la Precisión y el Recall para cada modelo.

Tabla 14

Comparación de métricas de CNN entrenadas.

	Precisión Macro	Recall Macro	F1-score Macro	AUC - ROC Macro
MobleNet-v2	0.893	0.880	0.887	0.965
ResNet-18	0.894	0.840	0.866	0.984
ResNet-50	0.882	0.880	0.881	0.968
ResNet-101	0.864	0.860	0.862	0.958
Inception-v3	0.928	0.920	0.924	0.995

Entre los modelos evaluados, *Inception-v3* mostró el mejor desempeño general, obteniendo la mayor precisión (0.928), Recall (0.920), F1-score (0.924) y el mayor AUC-ROC (0.995). Esto indica que este modelo no solo tiene una alta capacidad para predecir correctamente los grados de tostado, sino también un excelente balance entre sensibilidad y especificidad. Estos son comparables a los hallazgos de Adhitya *et al.* (2020), donde *Inception* logró la mayor precisión en la clasificación de granos de cacao (75%), superando a otras arquitecturas.

En términos de F1-score, *MobileNet-v2* (0.887) y *ResNet-50* (0.881) también presentaron buenos resultados, con valores cercanos al de *Inception-v3*, lo cual es consistente con Kumi *et al.* (2022), donde SSD *MobileNet-v2* mostró un desempeño competitivo en la detección de enfermedades del cacao. Esto sugiere que estos modelos tienen un desempeño sólido en la clasificación del grado de tostado de los granos de cacao.

Por otro lado, *ResNet-18* y *ResNet-101* mostraron los valores más bajos de F1-score (0.866 y 0.862, respectivamente), lo que indica que tienen una menor capacidad para equilibrar precisión y Recall. Sin embargo, *ResNet-18* obtuvo un AUC-ROC de 0.984, lo que sugiere que, a pesar de un F1-score ligeramente menor, su capacidad de discriminación sigue siendo alta.

Finalmente, el tiempo de entrenamiento es un factor clave a considerar. *ResNet-18* tuvo el menor tiempo de entrenamiento (45 minutos) mientras que *Inception-v3* presentó un tiempo mayor a 3 horas. En este sentido, *Inception-v3* representa la alternativa más atractiva con un buen equilibrio entre rendimiento en métricas y eficiencia computacional.

4.6. Validación de la efectividad del sistema propuesto


Para validar el desempeño del modelo, se implementó la red *Inception-v3*, seleccionada previamente con base en métricas de *Recall*, *Precisión*, *F1-score* y curva *ROC*. Dado que el algoritmo inicial estuvo diseñado para capturar imágenes estáticas, fue necesario modificarlo para permitir una clasificación automática y continua de los granos conforme ingresan al sistema.

La Figura 54 muestra la interfaz final del algoritmo, donde los granos de cacao aparecen etiquetados según su grado de tostado. En la esquina superior derecha, se presenta un recuento total de los granos, en la zona inferior se presentan tres histogramas que resumen la distribución de características relevantes.

El primero muestra la distribución porcentual de los grados de tostado, mientras que los otros dos representan la distribución del tamaño en largo y ancho. Esta visualización permite una evaluación más detallada del proceso y ayuda a identificar patrones en la clasificación. La imagen corresponde al minuto 20 del tostado; para consultar las imágenes capturadas en otros momentos del proceso, remitirse al Apéndice F.

Figura 54

Clasificación de granos de cacao tostado – Minuto 20.




La Figura 55 muestra la evolución de la distribución del grado de tostado de los granos de cacao a lo largo del tiempo. Cada subgráfico representa un histograma obtenido cada dos minutos, donde los valores en el eje x corresponden a los grados de tostado desde el 1 hasta el 5, y el eje y muestra la cantidad de granos en cada categoría.

Inicialmente, la mayoría de los granos se encuentran en los grados 1 y 2, indicando que el proceso de tostado apenas comienza. A medida que avanza el tiempo, se observa un desplazamiento progresivo de la distribución hacia los grados 3 y 4, reflejando un incremento en la cantidad de granos con mayor grado de tostado.

En las últimas mediciones, la presencia de granos en el grado 5 (quemado) se vuelve más notable, lo que indica que el proceso ha alcanzado una fase donde algunos granos comienzan a sobrecalentarse.

Figura 55

Evolución de la distribución de grado de tostado de granos de cacao a lo largo del tiempo.




Para validar el rendimiento del modelo, se compararon sus predicciones con la clasificación de tres expertos en tostado de cacao. Estos especialistas participaron en la fase de segmentación y etiquetado inicial, asignando a los granos un grado de tostado del 1 (crudo) al 5 (quemado). Posteriormente, etiquetaron un nuevo conjunto de 140 muestras, generadas cada dos minutos durante 24 minutos de tostado, para contrastar su clasificación con la de la CNN.

En la Figura 56, se presenta un diagrama de barras que ilustra el porcentaje de semejanza entre la clasificación realizada por tres expertos tostadores y las predicciones del modelo Inception-V3 sobre imágenes de granos de cacao tostado (Para una revisión detallada de los formatos de validación, remítase al Apéndice G).

Figura 56

Porcentaje de semejanza entre clasificado de Inception-v3 y expertos.



El eje x representa las 14 muestras evaluadas, mientras que el eje y indica el porcentaje de semejanza (%) con las predicciones de la CNN, con un rango de 0% a 100%. Cada experto está representado con un color diferente: azul (Eval. 1), naranja (Eval. 2) y amarillo (Eval. 3). Los dos primeros expertos tienen experiencia en CHOCOMUSEO S.A.C., mientras que el tercero cuenta con 12 años de experiencia y es propietario de QORU CHOCOLATE ARTESANAL. Los resultados muestran discrepancias significativas entre los expertos. Los dos primeros (azul y naranja) presentan coincidencias relativamente bajas con la CNN, con valores en su mayoría por debajo del 50% y algunos casos tan bajos como 10%. En contraste, el tercer evaluador (amarillo) muestra una mayor coincidencia, con valores que en varias muestras superan el 70%, alcanzando hasta 89% en la muestra 14.

En términos generales, Eval. 1 y Eval. 2 lograron una coincidencia promedio del 30% con el modelo, mientras que Eval. 3 alcanzó un 70%. Aunque estos resultados podrían interpretarse como una limitación del modelo Inception-V3. Sin embargo, también exponen la variabilidad en la percepción humana del color en los granos tostados, lo que podría deberse a diferencias en la experiencia.

CONCLUSIONES

1. El sistema de adquisición de imágenes (SAI) desarrollado permitió la captura de los granos de cacao tostados, asegurando condiciones controladas de iluminación y minimizando distorsiones ópticas. La implementación de luz blanca fría resultó ser la más adecuada para garantizar un contraste en la segmentación de los granos. Además, la calibración de la cámara web Full HD 1080P Teraware mediante un patrón de tablero de ajedrez corrigió la distorsión de ojo de pez, logrando un error de reproyección aceptable de 1.01 píxeles. La fabricación del prototipo en MDF, permitió una estructura funcional y precisa para la captura de imágenes.
2. Se implementaron algoritmos de pre procesamiento de imágenes en MATLAB para identificar y segmentar los granos de cacao en distintos grados de tostado. Se aplicó una máscara RGB con los límites [R: 0-150, G: 0-80, B: 0-51] para eliminar el fondo y aislar los granos con mayor precisión. A partir de imágenes binarias, se identificaron las regiones de interés y se establecieron tres categorías de tamaño: granos pequeños (≈ 8500 píxeles), medianos (≈ 9000 píxeles) y grandes (≈ 26000 píxeles). Para diferenciar granos superpuestos, se emplearon los métodos K-means y ajuste de elipses, permitiendo una segmentación más precisa. El algoritmo final logró identificar granos individuales, clasificar su tamaño y asignar una etiqueta de tostado basada en colorimetría.
3. Se realizó el reajuste de los hiper parámetros para el entrenamiento de cinco arquitecturas de Redes Neuronales Convolucionales (CNN) con el fin de clasificar

los granos de cacao según su grado de tostado. Se utilizó el método de descenso de gradiente estocástico (SGD) con una tasa de aprendizaje de 0.0001 y 30 épocas de entrenamiento. *ResNet-50* y *ResNet-101* mostraron los mejores resultados, alcanzando precisiones del 91% y 97-98%, respectivamente. *MobileNet-v2* y *ResNet-18* tuvieron menor precisión (82% y 84%), mientras que *Inception-v3* obtuvo un 87%, aunque con un tiempo de entrenamiento mayor. Todas las redes presentaron dificultades en la clasificación de los grados intermedios de tostado (especialmente entre los grados 2, 3 y 4), pero las redes más profundas como *ResNet-101* e *Inception-v3* redujeron estos errores.

4. Se comparó el rendimiento de cinco arquitecturas de Redes Neuronales Convolucionales para clasificar los grados de tostado de los granos de cacao, evaluando F1-score, AUC-ROC y tiempo de entrenamiento. *Inception-v3* obtuvo el mejor desempeño, con los valores más altos en precisión (0.928), Recall (0.920), F1-score (0.924) y AUC-ROC (0.995), lo que indica una alta capacidad de clasificación y buen balance entre sensibilidad y especificidad. Sin embargo, su entrenamiento fue el más largo (más de 3 horas). *MobileNet-v2* y *ResNet-50* también lograron buenos resultados con F1-score de 0.887 y 0.881, respectivamente, lo que los posiciona como opciones viables con menor costo computacional. Se seleccionó a *Inception-v3* como la mejor opción, seguida de *MobileNet-v2* y *ResNet-50*.

5. Se validó la clasificación del tostado de granos de cacao con *Inception-v3*, adaptando el algoritmo para análisis continuo. La comparación de la predicción de la CNN con expertos mostró discrepancias: dos coincidieron solo en 30% y el

tercero en 70%, evidenciando la subjetividad en la evaluación humana. La falta de consenso entre los expertos sugiere que la clasificación manual del tostado es subjetiva y depende de factores como el tipo de grano, temperatura, tiempo de tostado y la experiencia previa de cada especialista. En este sentido, la CNN no solo proporciona un método objetivo y reproducible, sino que también destaca la necesidad de establecer criterios más uniformes en la evaluación del tostado de cacao.

RECOMENDACIONES

- Explorar estrategias de control de temperatura en el proceso de tostado para mejorar la homogeneidad y reproducibilidad de los experimentos.
- Realizar pruebas con muestras de cacao de distintas regiones y variedades para validar la aplicabilidad del sistema desarrollado.
- Desarrollar una interfaz más accesible y portátil para la implementación del modelo en la industria del cacao, facilitando su uso en plantas de procesamiento.
- Crear un repositorio digital o una base de datos abierta con las imágenes generadas a partir de investigaciones relacionadas a los temas de Inteligencia Artificial y *Machine Learning*.

REFERENCIAS BIBLIOGRÁFICAS

- Adhitya, Y., Prakosa, S. W., Köppen, M., & Leu, J. S. (2020). Feature extraction for cocoa bean digital image classification prediction for smart farming application. *Agronomy*, 10(11), 1642.
- Afoakwa, E. O. (2000). Chocolate and cocoa, flavor and quality. *Kirk-Othmer Encyclopedia of Chemical Technology*, 1, 1–19.
- Afoakwa, E. O. (2014). *Cocoa production and processing technology*. CRC Press.
- Afoakwa, E. O., Paterson, A., Fowler, M., & Ryan, A. (2013). Flavor formation and character in cocoa and chocolate: A critical review. *Critical Reviews in Food Science and Nutrition*, 53(6), 740–757.
- Akay, M., Du, Y., Serksen, C. L., Wu, M., Chen, T. Y., Assassi, S., & Akay, Y. M. (2021). Deep learning classification of systemic sclerosis skin using the MobileNet-v2 model. *IEEE Open Journal of Engineering in Medicine and Biology*, 2, 104–110.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53.
- Aprotosoaie, A. C., Luca, S. V., & Miron, A. (2016). Flavor chemistry of cocoa and cocoa products—An overview. *Comprehensive Reviews in Food Science and Food Safety*, 15(1), 73–91.
- Arana, C. (2021). *Redes neuronales recurrentes: Análisis de los modelos especializados en datos secuenciales* (No. 797). Serie Documentos de Trabajo.
- Areni, I. S. (2020). Mobile image processing application for cacao's fruits pest and disease attack using deep learning algorithm. *ICIC Express Letters*, 14, 1025–1032.
- Artola Moreno, Á. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python*.
- Asefi, N., Ebrahimzadegan, S., Maleki, R., & Seiedlou-Heris, S. S. (2023). Effects of roasting on alkylpyrazin compounds and properties of cocoa powder. *Journal of Food Science and Technology*, 60(2), 572–580.

- Asefi, S., Malekjani, N., & Jafari, S. M. (2023). Cocoa processing and by-products: Antioxidant properties and functional applications. *Trends in Food Science & Technology*, 132, 138–152.
- Beckett, S. T. (2008). *The science of chocolate* (2nd ed.). RSC Publishing.
- Bekkar, M., Djemaa, D., & Alitouche, T. (2013). Evaluation measures for models. *International Journal of Computer Applications*, 69(10), 1–6.
- Berrocal Gonzales, E. C., & Pacheco Tello, L. (2023). *Estudio de factibilidad para la instalación de una planta de producción de chocolate fortificado con harina de coca (Erythroxylum coca) en la región de Ayacucho* [Tesis de licenciatura, Universidad Nacional de San Cristóbal de Huamanga]. Repositorio Institucional UNSCH. <https://repositorio.unsch.edu.pe/server/api/core/bitstreams/e1548fe1-bee7-4be5-afcd-fb13662d426d/content>
- Bioversity International. (2021). *Glosario de términos para la evaluación sensorial del cacao* (Versión en español). Cacao of Excellence.
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4). Springer.
- Borja-Robalino, R., Monleon-Getino, A., & Rodellar, J. (2020). Estandarización de métricas de rendimiento para clasificadores machine y deep learning. *Revista Ibérica de Sistemas e Tecnologías de Informação*, (E30), 184–196.
- Burkov, A. (2019). *The hundred-page machine learning book* (Vol. 1). Andriy Burkov.
- Cano Ortega, C., & Pineda Molina, J. (s.f.). Desarrollo de una aplicación móvil para la detección de enfermedades en los frutos de cacao.
- Centro de Ciencias de la Complejidad, UNAM. (s.f.). *Manual para la calibración de cámaras fotográficas*.
- Chavez Espinoza, W., Morante Dávila, M. A., Cueva Vega, E., Cruz Caro, O., & Chavez Espinoza, O. (2022). Factores que influyen en el ingreso de las familias agricultoras en Amazonas, Perú. *Comunicación*, 13(4), 291–300.
- Costilla Sanz, C. (2017). Aplicación práctica para cámara IR (Infrarrojos).

- De la Cruz, R., Gutiérrez, J., & Pérez, M. (2020). Impacto de la variabilidad del tostado en la calidad del cacao peruano. *Revista Agroindustrial*, 15(2), 55–67.
- Drzewiecki, W. (2017). Thorough statistical comparison of machine learning regression models and their ensembles for sub-pixel imperviousness and imperviousness change mapping. *Geodesy and Cartography*, 66(2), 171–209.
- Essah, R., Anand, D., & Singh, S. (2022). An intelligent cocoa quality testing framework based on deep learning techniques. *Measurement: Sensors*, 24, 100466.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.
- Febrianto, N. A., Wang, S., & Zhu, F. (2021). Chemical and biological properties of cocoa beans affected by processing: A review. *Critical Reviews in Food Science and Nutrition*. <https://doi.org/10.1080/10408398.2021.1928597>
- Fossi, C. S., & Ambrosio, A. C. D. (2004). Uso de las máquinas de vectores de soporte para la estimación del potencial de acción celular. *Revista INGENIERÍA UC*, 11(1), 56–61.
- Frauendorfer, F., & Schieberle, P. (2008). Changes in key aroma compounds of Criollo cocoa beans during roasting. *Journal of Agricultural and Food Chemistry*, 56(21), 10244–10251.
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: An overview. *arXiv*. <https://arxiv.org/abs/2008.05756>
- Guillen-Guerrero, K. M., & de la Rosa-Millan, J. (2025). Effects of fermentation temperature on the physicochemical properties, bioactive compounds, and in vitro digestive profile of cacao (*Theobroma cacao* L.) seeds. *Fermentation*, 11(4), 167.
- Gutiérrez, T. J. (2017). State-of-the-art chocolate manufacture: A review. *Comprehensive Reviews in Food Science and Food Safety*, 16(6), 1313–1344.
- Hakim, M., Djatna, T., & Yuliasih, I. (2020, October). Deep learning for roasting coffee bean quality assessment using computer vision in mobile environment. In *2020*

International Conference on Advanced Computer Science and Information Systems (ICACSIS) (pp. 363–370). IEEE.

Hand, D., & Till, R. (2001). A simple generalisation of the area under the ROC curve. *Machine Learning*, 45(2), 171–186.

Hartley, R., & Zisserman, A. (2003). *Multiple view geometry in computer vision*. (2.^a ed.). Cambridge University Press (pp. 16).

Harvyanti, A. F. M., Baihaki, R. I., Ridlo, Z. R., & Agustin, I. H. (2023, May). Application of convolutional neural network for identifying cocoa leaf disease. In *1st International Conference on Neural Networks and Machine Learning 2022 (ICONNSMAL 2022)* (pp. 283–304). Atlantis Press.

Hashim, W., Eng, L. S., Alkawsi, G., Ismail, R., Alkahtani, A. A., Dzulkifly, S., & Hussain, A. (2021). A hybrid vegetation detection framework: Integrating vegetation indices and convolutional neural network. *Symmetry*, 13(11), 2190.

Hemamalini, V., Rajarajeswari, S., Nachiyappan, S., Sambath, M., Devi, T., Singh, B. K., & Raghuvanshi, A. (2022). Food quality inspection and grading using efficient image segmentation and machine learning-based system. *Journal of Food Quality*, 2022(1), 5262294.

Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la investigación* (6.^a ed.). McGraw-Hill.

Holst, G. C., & Lomheim, T. S. (2011). CCD fundamentals. En *CMOS/CCD sensors and camera systems* (2.^a ed., Cap. 3). SPIE.

Hortinela, C. C., & Tupas, K. J. R. (2022). Classification of cacao beans based on their external physical features using convolutional neural network. In *2022 IEEE Region 10 Symposium (TENSyMP)* (pp. 1–5). IEEE.

Hossain, M. S., Al-Hammadi, M., & Muhammad, G. (2018). Automatic fruit classification using deep learning for industrial applications. *IEEE Transactions on Industrial Informatics*, 15(2), 1027–1034.

Hossin, M., & Sulaiman, M. (2015). A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining and Knowledge Management Process*, 5(2), 1–11.

- Hurtado Soria, J., & Mamani Aguilar, W. (2018). *Cacao Chuncho del Cusco*. Ministerio de Agricultura y Riego – Dirección de Competitividad Agraria.
- International Cocoa Organization. (2021). *The cacao tree*. <https://www.icco.org/our-work/cocoa-production/the-cocoa-tree>
- Inyang, U. E., Oboh, I. O., & Etuk, B. R. (2018). Kinetic models for drying techniques—Food materials. *Advances in Chemical Engineering and Science*, 8(2), 27–48. <https://doi.org/10.4236/aces.2018.82003>
- Jinap, S., Dimick, P. S., & Hollender, R. (1998). Flavour evaluation of chocolate formulated from cocoa beans from different countries. *Food Control*, 9(2–3), 105–110.
- Johnson, O., & Johnson, A. (1996). Matsigenka. In *Encyclopedia of world cultures*. Retrieved from <https://www.encyclopedia.com/humanities/encyclopedias-almanacs-transcripts-and-maps/matsigenka-0>
- Kerr, W. L. (2019). Food drying and evaporation processing operations. En B. Smith & D. M. Nielsen (Eds.), *Food Process Engineering* (Cap. 14). Academic Press. <https://doi.org/10.1016/B978-0-12-814803-7.00014-2>
- Kongor, J. E., Hinneh, M., de Walle, D. V., Afoakwa, E. O., Boeckx, P., & Dewettinck, K. (2016). Factors influencing quality variation in cocoa (*Theobroma cacao* L.) bean flavour profile—A review. *Food Research International*, 82, 44–52.
- Koonce, B. (2021). ResNet 50. In *Convolutional neural networks with Swift for TensorFlow: Image recognition and dataset categorization* (pp. 63–72).
- Kumi, S., Kelly, D., Woodstuff, J., Lomotey, R. K., Orji, R., & Deters, R. (2022). Cocoa companion: Deep learning-based smartphone application for cocoa disease detection. *Procedia Computer Science*, 203, 87–94.
- Lee, D. S., Yoo, M. J., Lee, D. S., Kwon, Y. J., & Pyun, Y. R. (2001). Color and texture analysis of roasted coffee beans using image processing techniques. *Korean Journal of Food Science and Technology*, 33(3), 353–356.
- Leme, D. S., da Silva, S. A., Barbosa, B. H. G., Borém, F. M., & Pereira, R. G. F. A. (2019). Recognition of coffee roasting degree using a computer vision system. *Computers and Electronics in Agriculture*, 156, 312–317.

- Liu, K. (2023). Comparison of different convolutional neural network models on Fruit 360 Dataset. *Highlights in Science, Engineering and Technology*, 34, 85–94.
- Liu, X., Lu, D., Zhang, A., Liu, Q., & Jiang, G. (2022). Data-driven machine learning in environmental pollution: Gains and problems. *Environmental Science & Technology*, 56(4), 2124–2133.
- Lopes, J. F., da Costa, V. G. T., Barbin, D. F., Cruz-Tirado, L. J. P., Baeten, V., & Barbon Junior, S. (2022). Deep computer vision system for cocoa classification. *Multimedia Tools and Applications*, 81(28), 41059–41077.
- Martínez, G. R. S., & Mejía, J. A. S. (2011). Árboles de decisiones en el diagnóstico de enfermedades cardiovasculares. *Scientia et Technica*, 16(49), 104–109.
- MINAGRI. (2022). *Informe sobre la producción de cacao en el Perú*. Ministerio de Agricultura y Riego.
- Misnawi, Jinap, S., Jamilah, B., & Nazamid, S. (2004). Effects of polyphenol concentration on reduced cocoa astringency and bitterness. *Food Chemistry*, 85(1), 65–71.
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.
- Nakamura, J. (2016). *Image sensors and signal processing for digital still cameras*. CRC Press.
- Nehir, M., Frank, C., Aßmann, S., & Achterberg, E. P. (2019). Improving optical measurements: Non-linearity compensation of compact charge-coupled device (CCD) spectrometers. *Sensors*, 19(12), 2833.
- Nurhayati, N., Setyabudi, F. M. C. S., Marseno, D. W., & Supriyanto, S. (2019). The effects of roasting time of unfermented cocoa liquor using the oil bath methods on physicochemical properties and volatile compound profiles. *AgriTECH*, 39(1), 36–47.
- Oliveira, M. M., Cerqueira, B. V., Barbon Jr, S., & Barbin, D. F. (2021). Classification of fermented cocoa beans (cut test) using computer vision. *Journal of Food Composition and Analysis*, 97, 103771.

- Palga Mejía, S. J. (2023). *Propuesta del manual de inocuidad y control estadístico para el proceso de elaboración de chocolate en barra* [Tesis de licenciatura, Universidad Nacional Agraria La Molina]. Repositorio UNALM.
- Peña, R. F., Ataç Mogol, B., Van Boekel, M., & Fogliano, V. (2022). La tostación en lecho fluidizado de semillas de cacao acelera el procesamiento y favorece la formación de pirazinas. *Innovative Food Science and Emerging Technologies*, 79, 103062.
- Pumacahua, A., Vega, S., Gonzales R., Marconi W., & Carrión. M. (2022). Uso de sensores para modelamiento matemático durante el tostado de granos de cacao (*Theobroma cacao*) de la variedad Chuncho / Use of sensors for mathematical modeling during the roasting of cocoa beans (*Theobroma cacao*) of the Chuncho variety. *Revista Investigación Agraria*, 24(2). <https://doi.org/10.18271/ria.2022.419>
- Qing, K., Huang, R., & Hong, K. S. (2021). Decoding three different preference levels of consumers using convolutional neural network: A functional near-infrared spectroscopy study. *Frontiers in Human Neuroscience*, 14, 597864.
- Quiroz-Reyes, C. N., & Fogliano, V. (2018). Design cocoa processing towards healthy cocoa products: The role of phenolics and melanoidins. *Journal of Functional Foods*, 45, 480–490.
- Sánchez, M., Suazo, G., Araya, V., & Villavicencio, G. (2022). Estudio de la relación entre la reflexión de luz y el contenido de humedad superficial en muestras de relave utilizando imágenes hiperespectrales. *Obras y Proyectos*, (31), 77–84.
- Sanz Sardina, M. Á. (2014). Sistema de reconocimiento y clasificación de objetos usando cámaras RGB-D para manipulación robótica.
- Singh, R. P., & Heldman, D. R. (2009). *Introduction to food engineering* (5th ed.). Academic Press.
- Stockman, G., & Shapiro, L. G. (2001). *Computer vision*. Prentice Hall PTR.
- Sutaji, D., & Yıldız, O. (2022). LEMOXINET: Lite ensemble MobileNet-v2 and Xception models to predict plant disease. *Ecological Informatics*, 70, 101698.
- Szeliski, R. (2022). *Computer vision: Algorithms and applications* (2.^a ed.). Springer.





- Taipe, C. (2019). Aplicación del software MATLAB en el aprendizaje de la cinemática lineal de una partícula en estudiantes universitarios de ingeniería. *Revista Innova Educación*, 1(3), 281–287.
- Tan, J., Balasubramanian, B., Sukha, D., Ramkissoon, S., & Umaharan, P. (2019). Sensing fermentation degree of cocoa (*Theobroma cacao* L.) beans by machine learning classification models based electronic nose system. *Journal of Food Process Engineering*, 42(6), e13175.
- Ticona Apaza, A. Z. (2024). *Proceso de elaboración de gotas de chocolate con 70 % cacao (Theobroma cacao L.) en calibre 260* [Tesis de licenciatura, Universidad Nacional San Luis Gonzaga]. Repositorio UNICA. <https://hdl.handle.net/20.500.13028/5457>
- Tripathi, M. K., & Maktedar, D. D. (2021). Detection of various categories of fruits and vegetables through various descriptors using machine learning techniques. *International Journal of Computational Intelligence Studies*, 10(1), 36–73.
- Valero, Q., & Anderson, P. (2020). Aplicación web para clasificar los granos de la quinua según la norma técnica peruana aplicando machine learning. Universidad Peruana Unión.
- Vecteezy. (2025). Cocoa beans and cocoa fruits. <https://www.vecteezy.com/photo/1241344-cocoa-beans-and-cocoa-fruits>
- Vieira, S., Pinaya, W. H. L., & Mechelli, A. (2020). Introduction to machine learning. In *Machine Learning* (pp. 1–20). Academic Press.
- Villanueva, O., Guevara-Ponce, V., Paredes, O. R., Sierra-Liñan, F., Zapata-Paulini, J., & Cabanillas-Carbonell, M. (2022). Convolutional neural networks with transfer learning for pneumonia detection. *International Journal of Advanced Computer Science and Applications*, 13(9), 544–551. <https://doi.org/10.14569/IJACSA.2022.0130963>
- Yacoubby, R., & Axman, D. (2020). Probabilistic extension of precision, recall, and F1 score for more thorough evaluation of classification models. In *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems* (pp. 79–91).

- Yang, Y., Darwish, A. G., El-Sharkawy, I., Zhu, Q., Sun, S., & Tan, J. (2022). Rapid determination of the roasting degree of cocoa beans by extreme learning machine (ELM)-based imaging analysis. *Journal of Agriculture and Food Research*, 10, 100437.
- Zerouaoui, H., & Idri, A. (2021). Reviewing machine learning and image processing-based decision-making systems for breast cancer imaging. *Journal of Medical Systems*, 45(1), 8.
- Zhang, Z. (2000). A flexible new technique for camera calibration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(11), 1330–1344.
- Zou, T., Pan, T., Taylor, M., & Stern, H. (2020). Recognition of overlapping elliptical objects in a binary image. *Pattern Analysis and Applications*, 23(4), 1401–1415. <https://doi.org/10.1007/s10044-019-00859-0>
- Żyżelewicz, D., Krysiak, W., Nebesny, E., & Budryn, G. (2014). Application of various methods for determination of the color of cocoa beans roasted under variable process parameters. *European Food Research and Technology*, 238(4), 549–563.
- Zzaman, W., & Yang, T. A. (2013). Effect of superheated steam and convection roasting on changes in physical properties of cocoa bean (*Theobroma cacao* L.). *Food Science and Technology Research*, 19(2), 181–186.

APÉNDICES

APÉNDICE A

Figura A1. *Plano de tostadora de cacao de manufactura local.*



VISTA ISOMETRICA
ESCALA 1 / 4

DRAWN	30/12/2024	TITLE		
User				
CHECKED		TOSTADORA		
QA				
MFG		DWG NO		
APPROVED				
		SCALE	1 / 4	REV

APÉNDICE B

Figura A2.

Fotos de granos de cacao de la corrida 4 obtenidas por el sistema de adquisición de imágenes.




Figura A3.

Fotos de granos de cacao de la corrida 5 obtenidas por el sistema de adquisición de imágenes.




Figura A4.

Fotos de granos de cacao de la corrida 6 obtenidas por el sistema de adquisición de imágenes.





Figura A5.

Fotos de granos de cacao de la corrida 7 obtenidas por el sistema de adquisición de imágenes.



APÉNDICE C

En la Tabla C1 se presenta el cálculo del factor de conversión de píxeles a milímetros, obtenido al comparar las dimensiones (largo y ancho) en milímetros —medidas con Vernier— y en píxeles —obtenidas con el SAI— para granos de distintos tamaños. El promedio de las conversiones individuales dio como resultado un factor de 0.1099 mm/px. En la Tabla C2 se muestra el cálculo del error asociado: las dimensiones en píxeles fueron convertidas a milímetros utilizando dicho factor y comparadas con las medidas reales. El promedio del error de conversión obtenido fue de aproximadamente 0.3 mm por grano.

Tabla C1. *Cálculo de Factor de conversión de milímetros a pixeles para aplicación con SAI.*

Tamaño	Largo (mm)	Ancho (mm)	Largo(px)	Ancho(px)	Largo (mm/px)	Ancho (mm/px)
Pequeño	16.2	10.2	143.4807	93.6257	0.1129	0.1089
Medio	22.0	13.15	199.6346	119.1531	0.1102	0.1104
Grande	25.3	12.25	232.1839	113.1237	0.1090	0.1083
Factor de conversión (mm/px)						0.1099

Tabla C2. *Cálculo de error de factor de conversión de milímetros a pixeles*

	Medición por realizada por el SAI		Medición usando Factor de conversión (mm/px)		Medición Real		Error Largo	Error Ancho
	Largo (px)	Ancho (px)	Largo (mm)	Ancho (mm)	Largo (mm)	Ancho (mm)		
Prueba 1	198.571	116.054	21.832	12.760	21.450	12.150	0.382	0.610
Prueba 2	179.229	100.372	19.705	11.035	20.050	11.200	0.345	0.165
Prueba 3	223.194	116.442	24.539	12.802	23.700	12.750	0.839	0.052
Prueba 4	163.657	101.101	17.993	11.115	18.150	11.000	0.157	0.115
Prueba 5	198.355	118.992	21.808	13.083	21.500	13.000	0.308	0.083
Error Promedio (%)							0.306	

APÉNDICE D

Figura A6

Distribución de tamaños de los granos de cacao de la corrida 2.




Figura A7

Distribución de tamaños de los granos de cacao de la corrida 3.




Figura A8

Distribución de tamaños de los granos de cacao de la corrida 4.




Figura A9

Distribución de tamaños de los granos de cacao de la corrida 5.




Figura A10

Distribución de tamaños de los granos de cacao de la corrida 6





Figura A11

Distribución de tamaños de los granos de cacao de la corrida 7



APÉNDICE E

Pseudo algoritmo para la captura y preprocesamiento de imágenes de granos de cacao

```
1:  Cargar parámetros de la cámara (Parametros_camara).
2:  Capturar imagen con la cámara.
3:  Corregir distorsión (fisheye) de la imagen.
4:  Recortar la imagen solo al área de interés.
5:  Segmentar o umbralizar la imagen para obtener una máscara binaria (BW) de los
    granos.
6:  Rellenar huecos en la máscara.
7:  Convertir la imagen original a escala de grises.
8:  Etiquetar las regiones conectadas en la máscara.
9:  Obtener las propiedades de cada región (área, bounding box, centroide).
10: Inicializar estructuras para almacenar datos de los granos.
11: n = 1 (contador para numerar granos pequeños y medianos)
12: j = 1 (contador para numerar granos grandes)
13: for cada región etiquetada do
14:     Obtener el bounding box y el área de la región.
15:     if área > area_mediana and área < area_grande then
16:         Etiquetar la región como '1' (grano mediano).
17:         Dibujar un rectángulo rojo alrededor del grano.
18:         Numerar el grano.
19:         Almacenar la información del grano en boxesdata1.
20:         n = n + 1
21:     end if
22:     if área > area_grande then
23:         Etiquetar la región como '2' (grano grande).
24:         Almacenar el bounding box y el centroide del grano.
25:         Recortar el grano de la máscara binaria y la imagen en escala de grises.
26:         j = j + 1
27:     end if
28: end for
29: Extraer los bounding boxes de los granos medianos (boxesred).
30: if existen granos grandes then
31:     for cada grano grande do
32:         for cada grano mediano do
33:             Eliminar la intersección entre el grano grande y el mediano.
34:         end for
35:         Aplicar watershed para separar granos superpuestos dentro del grano grande.
36:         for cada región separada do
37:             if área > area_pequena and área < area_grande then
38:                 Dibujar un rectángulo amarillo alrededor del grano.
39:                 Numerar el grano.
40:                 Almacenar la información del grano en boxesdata1.
41:                 n = n + 1
42:             end if
43:             if área > area_grande then
44:                 Aplicar algoritmo de separación de granos (separaciongranos).
45:                 for cada grano separado do
46:                     Dibujar un rectángulo verde alrededor del grano.
47:                     Numerar el grano.
```

```

48:             Almacenar la información del grano en boxesdata1.
49:             n = n + 1
50:         end for
51:     end if
52: end for
53: end for
54: end if
55: for cada grano en boxesdata1 do
56:     Recortar el grano de la imagen original.
57:     Almacenar la etiqueta en boxesdata1.
58:     Mostrar la etiqueta en la imagen.
59: end for
60: Mostrar histograma de las etiquetas.
61: Calcular el largo y ancho de los granos.
62: Preguntar al usuario si desea guardar los datos.
63: if el usuario responde 'Sí' then
64:     Guardar la estructura boxesdata1 y la imagen imgr.
66: end if

```

Pseudo algoritmo de la función “separaciongranos” para la separación granos de cacao solapados en una imagen

- 1: Detectar bordes en la imagen del grano usando el algoritmo **Canny**.
- 2: Cerrar los bordes usando operaciones morfológicas.
- 3: Encontrar el contorno del grano.
- 4: Calcular la curvatura del contorno.
- 5: Encontrar los puntos cóncavos del contorno ($\text{curvatura} < \text{threshold}$).
- 6: Calcular la distancia de cada punto del contorno a la línea que une sus vecinos.
- 7: Seleccionar los puntos con distancia mayor a `threshold` (`superior_points`).
- 8: Identificar los puntos convexos y cóncavos en `superior_points`.
- 9: Eliminar puntos cóncavos consecutivos.
- 10: Dividir el contorno en segmentos basados en los puntos cóncavos restantes.
- 11: Seleccionar los tres segmentos más largos.
- 12: **for** cada segmento **do**
- 13: Ajustar una elipse al segmento.
- 14: **if** la elipse no es válida **then**
- 15: Continuar con el siguiente segmento.
- 16: **end if**
- 17: Optimizar el ángulo de la elipse para minimizar la distancia a los puntos del contorno.
- 18: Calcular el área de la elipse.
- 19: Encontrar el rectángulo circunscrito a la elipse.
- 20: Almacenar la posición del rectángulo y el área de la elipse.
- 21: **end for**

Pseudo algoritmo para el entrenamiento de la red neuronal convolucional con imágenes de granos tostados de cacao

- 1: Crear un `imageDatastore` con las imágenes de entrenamiento.
- 2: Dividir el `imageDatastore` en conjuntos de entrenamiento, validación y prueba.
- 3: Redimensionar las imágenes de prueba al tamaño de entrada de la red.
- 4: Obtener el tamaño de entrada de la red neuronal (`net1`).
- 5: (Opcional) Crear un `imageDataAugmenter` para aumentar los datos de entrenamiento.
- 6: Crear `augmentedImageDatastores` para entrenamiento y validación con el tamaño de entrada adecuado.
- 7: **if** se proporciona una red pre-entrenada (`net1`) **then**
- 8: Convertir la red pre-entrenada en un objeto `dlnetwork`.
- 9: **end if**
- 10: Definir las opciones de entrenamiento (optimizador, tamaño de mini-batch, épocas, etc.).
- 11: Entrenar la red neuronal utilizando los datos de entrenamiento y las opciones de entrenamiento.
- 12: Guardar los datos relacionados a la red neuronal entrenada `netTrained`.

Pseudo algoritmo para la validación de la red neuronal convolucional para la clasificación de imágenes de granos tostados de cacao

- 1: Cargar la red neuronal entrenada (`netTrained`).
- 2: Crear un `imageDatastore` con las imágenes de prueba.
- 3: Extraer las etiquetas de los nombres de archivo de las imágenes de prueba.
- 4: Asignar las etiquetas al `imageDatastore`.
- 5: Crear un `augmentedImageDatastore` con las imágenes de prueba redimensionadas.
- 6: Realizar la predicción de las etiquetas utilizando la red neuronal entrenada.
- 7: Calcular la precisión de la red comparando las etiquetas predichas con las etiquetas reales.
- 8: Generar una matriz de confusión para visualizar el rendimiento de la clasificación.

APÉNDICE F

Figura A12

Clasificación de granos de cacao tostado – Minuto 2.




Figura A13

Clasificación de granos de cacao tostado – Minuto 4.




Figura A14

Clasificación de granos de cacao tostado – Minuto 6.




Figura A15

Clasificación de granos de cacao tostado – Minuto 8.




Figura A16

Clasificación de granos de cacao tostado – Minuto 10.




Figura A17

Clasificación de granos de cacao tostado – Minuto 11.




Figura A18

Clasificación de granos de cacao tostado – Minuto 14.




Figura A19

Clasificación de granos de cacao tostado – Minuto 16.




Figura A20

Clasificación de granos de cacao tostado – Minuto 18.




Figura A21

Clasificación de granos de cacao tostado – Minuto 22.




Figura A22

Clasificación de granos de cacao tostado – Minuto 24.




Figura A23

Clasificación de granos de cacao tostado – Minuto 26.





Figura A24

Clasificación de granos de cacao tostado – Minuto 28.



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

APÉNDICE G

Universidad Nacional de San Antonio Abad del Cusco - Escuela Profesional de Ingeniería Química

"Clasificación del grado de tostado de cacao (Theobroma cacao L.) en tiempo real mediante Redes Neuronales Convolucionales"

Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

INSTRUCCIONES PARA LA EVALUACIÓN SENSORIAL DEL TOSTADO DE GRANOS DE CACAO

Estimado jurado,

Le damos la bienvenida a esta evaluación sensorial por color del tostado de granos de cacao. Su experiencia y criterio serán fundamentales para clasificar el grado de tostado de los granos de acuerdo con la escala visual proporcionada.

OBJETIVO DE LA EVALUACIÓN

El propósito de esta evaluación es determinar, mediante percepción visual, el grado de tostado de los granos de cacao. Posteriormente, estos resultados serán comparados con un análisis colorimétrico computacional (*Machine Learning*) para validar la precisión de la evaluación sensorial de color.

PROCEDIMIENTO

1. Revisión de la Escala de Referencia
 - Se le proporciona una escala visual con cinco niveles de tostado (del Nivel 1 al Nivel 5) (**Figura 1**).
 - Observe detenidamente la variación de color en cada nivel de la escala antes de comenzar la evaluación.
2. Evaluación de los Granos de Cacao
 - Se le entrega una imagen con granos de cacao, cada uno señalado con un punto rojo. (**Figura 2**)
 - Asigne a cada grano una numeración del 1 al 5, según su grado de tostado percibido en comparación con la escala de referencia.
 - Anote la clasificación sobre la línea de color rojo de la imagen proporcionada.
3. Consideraciones Importantes
 - Realice la evaluación de forma individual, sin intercambiar opiniones con otros evaluadores.
 - Si tiene dudas con algún grano, tome el tiempo necesario para compararlo con la escala antes de asignarle un valor.

Agradecemos su participación en este proceso de evaluación, cuya información contribuirá al desarrollo de métodos más precisos para la caracterización del tostado de los granos de cacao.

Atentamente,
Ccahuaya Gutierrez, Paola Alexandra
Santi Quispe, Indira Reabel

Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados


CAMPOS DE IDENTIFICACIÓN DEL JURADO	
1. Nombre Completo	: JORSEF Quispe Goedillo
2. DNI	: 43863662
3. Experiencia en tostado de cacao (años)	: 5 años
4. Ocupación o cargo	: MAQUINAS
5. Fecha de Evaluación	: 22/02/25
6. Firma del Jurado	: 
7. Firma del Evaluador	:

Figura 1. Escala visual de niveles de tostados propuesto desde Nivel 1 (menor grado de tostado) hasta Nivel 5 (máximo grado de tostado)

Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5
				

Figura 2. Imagen de ejemplo para el llenado de niveles de tostado por cada grano de cacao.



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

Figura A25

Clasificación de granos de cacao tostado por el jurado 1– Minuto 2.




Figura A26

Clasificación de granos de cacao tostado por el jurado 1– Minuto 4.




Figura A27

Clasificación de granos de cacao tostado por el jurado 1– Minuto 6.



Figura A28

Clasificación de granos de cacao tostado por el jurado 1– Minuto 8.




Figura A29

Clasificación de granos de cacao tostado por el jurado 1– Minuto 10.



Figura A30

Clasificación de granos de cacao tostado por el jurado 1– Minuto 12.



Figura A31

Clasificación de granos de cacao tostado por el jurado 1– Minuto 14.




Figura A32

Clasificación de granos de cacao tostado por el jurado 1– Minuto 16.




Figura A33

Clasificación de granos de cacao tostado por el jurado 1– Minuto 18.



Figura A34

Clasificación de granos de cacao tostado por el jurado 1 a los 20 minutos.




Figura A35

Clasificación de granos de cacao tostado por el jurado 1– Minuto 22.




Figura A36

Clasificación de granos de cacao tostado por el jurado 1– Minuto 24




Figura A37

Clasificación de granos de cacao tostado por el jurado 1– Minuto 26





Figura A38

Clasificación de granos de cacao tostado por el jurado 1– Minuto 28



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

CAMPOS DE IDENTIFICACIÓN DEL JURADO



1. Nombre Completo	:	Sydney Jurely Blanco Lopez
2. DNI	:	76980946
3. Experiencia en tostado de cacao (años)	:	12
4. Ocupación o cargo	:	Producción Mochinos
5. Fecha de Evaluación	:	25 / 02 / 25
6. Firma del Jurado	:	
7. Firma del Evaluador	:	

Figura 1. Escala visual de niveles de tostados propuesto desde Nivel 1 (menor grado de tostado) hasta Nivel 5 (máximo grado de tostado)



Figura 2. Imagen de ejemplo para el llenado de niveles de tostado por cada grano de cacao.



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

Figura A39

Clasificación de granos de cacao tostado por el jurado 2– Minuto 2




Figura A40

Clasificación de granos de cacao tostado por el jurado 2– Minuto 4




Figura A41

Clasificación de granos de cacao tostado por el jurado 2– Minuto 6



Figura A42

Clasificación de granos de cacao tostado por el jurado 2– Minuto 8




Figura A43

Clasificación de granos de cacao tostado por el jurado 2– Minuto 10



Figura A44

Clasificación de granos de cacao tostado por el jurado 2– Minuto 12



Figura A45

Clasificación de granos de cacao tostado por el jurado 2– Minuto 14.





Figura A46

Clasificación de granos de cacao tostado por el jurado 2– Minuto 16.



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

Figura A47

Clasificación de granos de cacao tostado por el jurado 2– Minuto 18.



Figura A48

Clasificación de granos de cacao tostado por el jurado 2– Minuto 20.




Figura A49

Clasificación de granos de cacao tostado por el jurado 2– Minuto 22.





Figura A50

Clasificación de granos de cacao tostado por el jurado 2– Minuto 24



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

Figura A51

Clasificación de granos de cacao tostado por el jurado 2– Minuto 26





Figura A52

Clasificación de granos de cacao tostado por el jurado 2– Minuto 28



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

CAMPOS DE IDENTIFICACIÓN DEL JURADO



1. Nombre Completo	: José Carlos Moscoso Fernandez
2. DNI	: 40190010
3. Experiencia en tostado de cacao (años)	: 5 años
4. Ocupación o cargo	: Gerente
5. Fecha de Evaluación	: 25/02/2025
6. Firma del Jurado	: 
7. Firma del Evaluador	:

Figura 1. Escala visual de niveles de tostados propuesto desde Nivel 1 (menor grado de tostado) hasta Nivel 5 (máximo grado de tostado)



Figura 2. Imagen de ejemplo para el llenado de niveles de tostado por cada grano de cacao.



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

Figura A53

Clasificación de granos de cacao tostado por el jurado 3– Minuto 2




Figura A54

Clasificación de granos de cacao tostado por el jurado 3– Minuto 4




Figura A55

Clasificación de granos de cacao tostado por el jurado 3– Minuto 6



Figura A56

Clasificación de granos de cacao tostado por el jurado 3– Minuto 8





Figura A57

Clasificación de granos de cacao tostado por el jurado 3– Minuto 10



Figura A58

Clasificación de granos de cacao tostado por el jurado 3– Minuto 12



Ficha de Evaluación Sensorial – Color de Granos de Cacao Tostados

Figura A59

Clasificación de granos de cacao tostado por el jurado 3– Minuto 14




Figura A60

Clasificación de granos de cacao tostado por el jurado 3– Minuto 16




Figura A61

Clasificación de granos de cacao tostado por el jurado 3– Minuto 18




Figura A62

Clasificación de granos de cacao tostado por el jurado 3– Minuto 20




Figura A63

Clasificación de granos de cacao tostado por el jurado 3– Minuto 22




Figura A64

Clasificación de granos de cacao tostado por el jurado 3– Minuto 24




Figura A65

Clasificación de granos de cacao tostado por el jurado 3– Minuto 26






Figura A66

Clasificación de granos de cacao tostado por el jurado 3– Minuto 28



ANEXOS

ANEXO A: Resultados del análisis de humedad en la muestra inicial de granos de cacao mediante método gravimétrico (AOAC 934.01)



MC QUIMICALAB

De: Ing. Gury Manuel Cumpa Gutiérrez
LABORATORIO DE CIENCIAS NATURALES
AGUAS, SUELOS, MINERALES Y MEDIO AMBIENTE
RUC N° 10465897711 - COVIDUC A4 - SAN SEBASTIÁN Cel: 946887776 - 951562574

INFORME N° LQ 0137-25
ANÁLISIS FÍSICOQUÍMICO DE ALIMENTO

SOLICITA : INDIRA REABEL SANTI QUISPE.

PROYECTO : "DETERMINACIÓN DE GRADO DE TOSTADO DE CACAO MEDIANTE MACHINE LEARNING"

MUESTRA : M₁.- GRANOS DE CACAO.

DISTRITO : CUSCO.

PROVINCIA : CUSCO.

DEPARTAMENTO : CUSCO.

FECHA DE INFORME : 18/10/2024

RESULTADOS:

DETERMINACIONES	UNIDAD	M ₁	METODO
Humedad	%	8.3	Gravimetría (AOAC 2015, 934.01)

METODOS DE ANALISIS:

- OFFICIAL METHODS OF ANALYSIS – ASSOCIATION OF OFFICIAL ANALYTICAL CHEMISTS (AOAC).
- Harry Johnstone Fisher, PH.D., ANALISIS MODERNO DE LOS ALIMENTOS, Administración de Alimentos y Drogas. Distrito de Boston. Editorial Acribia Zaragoza, España.

NOTA:

- Los resultados son válidos únicamente para la muestra analizada.
- La muestra fue tomada por el solicitante.

COLEGIO DE INGENIEROS DEL PERÚ
CONSEJO DEPARTAMENTAL CUSCO

Ing. Gury Manuel Cumpa Gutiérrez
INGENIERO QUÍMICO
CIP 238338