

UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD DEL CUSCO
FACULTAD DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA,
INFORMÁTICA Y MECÁNICA
ESCUELA PROFESIONAL DE INGENIERÍA INFORMÁTICA
Y DE SISTEMAS



TESIS

**SISTEMA DE CONTROL DE CALIDAD DE LA FIBRA
DE ALPACA BASADO EN VISIÓN COMPUTACIONAL
PARA LA DETECCIÓN DE NEPS, HOMOGENEIDAD
Y PAJILLAS EN EL PROCESO DE CARDADO**

PRESENTADO POR:

Br. JOHANA MARIA MAMANI MEZA

**PARA OPTAR AL TÍTULO PROFESIONAL
DE INGENIERO INFORMÁTICO Y DE
SISTEMAS**

ASESOR:

Dr. HARLEY VERA OLIVERA

CO-ASESOR:

Dr. CARLOS FERNANDO MONTOYA CUBAS

CUSCO - PERÚ

2026



Universidad Nacional de San Antonio Abad del Cusco

INFORME DE SIMILITUD

(Aprobado por Resolución Nro.CU-321-2025-UNSAAC)

El que suscribe, el **Asesor** Harley Vera Olivera
..... quien aplica el software de detección de similitud al
trabajo de investigación/tesis titulada: SISTEMA DE CONTROL DE CALIDAD.....
DE LA FIBRA DE ALPACA BASADO EN VISIÓN COMPUTACIONAL
PARA LA DETECCIÓN DE NEPS, HOMOGENEIDAD Y PAJILLAS
EN EL PROCESO DE CARDADO

Presentado por: JOHANA MARIA HAMANI MEZA DNI N° 74244030
presentado por: DNI N°:
Para optar el título Profesional/Grado Académico de INGENIERO INFORMATICA
Y DE SISTEMAS

Informo que el trabajo de investigación ha sido sometido a revisión por 03 veces, mediante el
Software de Similitud, conforme al Art. 6° del **Reglamento para Uso del Sistema Detección de**
Similitud en la UNSAAC y de la evaluación de originalidad se tiene un porcentaje de 8 %.

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 sobrepasa el porcentaje aceptado de similitud.	<u>X</u>
Del 11 al 30 %	Devolver al usuario para las subsanaciones.	
Mayor a 31%	El responsable de la revisión del documento emite un informe al inmediato jerárquico, conforme al reglamento, quien a su vez eleva el informe al Vicerrectorado de Investigación 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 de Detección de Similitud.

Cusco, 20 de agosto de 2026.....


.....
Firma

Post firma Dr. Harley Vera Olivera

Nro. de DNI 42542815

ORCID del Asesor 0000-0003-2011-8797

Se adjunta:

1. Reporte generado por el Sistema Antiplagio.
2. Enlace del Reporte Generado por el Sistema de Detección de Similitud: **oid:** 27259:615567159

JOHANA MARIA MAMANI MEZA

SISTEMA DE CONTROL DE CALIDAD DE LA FIBRA ´ DE ALPACA BASADO EN VISI ON COMPUTACIONAL ´ PARA LA D...

 Universidad Nacional San Antonio Abad del Cusco

Detalles del documento

Identificador de la entrega

trn:oid:::27259:615567159

Fecha de entrega

19 ago 2026, 6:59 p.m. GMT-5

Fecha de descarga

19 ago 2026, 7:41 p.m. GMT-5

Nombre del archivo

TESIS-FINAL-FINAL.pdf

Tamaño del archivo

64.3 MB

159 páginas

33.017 palabras

185.607 caracteres

8% 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 8 palabras)

Exclusiones

- N.º de coincidencias excluidas

Fuentes principales

- 5%  Fuentes de Internet
- 1%  Publicaciones
- 6%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

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.

Acrónimos

CNN: Convolutional Neural Network

YOLO: You Only Look Once

FPS: Frames Per Second

mAP: Mean Average Precision

Recall: Métrica que mide la recuperación de las detecciones correctas

Precision: Precisión en las detecciones correctas

F1-Score: Medida combinada de la precisión y el recall

MDF: Medium Density Fiberboard

GLCM: Gray-Level Co-occurrence Matrix

GPU: Graphics Processing Unit

RAM: Random Access Memory

VRAM: Video Random Access Memory

TFLite: TensorFlow Lite

NTP: Norma Técnica Peruana

SPPF: Spatial Pyramid Pooling Fast

CBAM: Convolutional Block Attention Module

A mi familia, por acompañarme siempre y apoyarme en cada uno de mis proyectos; a mi madre, mi padre, mi hermana y mis hermanos, por ser parte fundamental de este camino y de mi vida. A mis amigos más cercanos, que a pesar del tiempo y la distancia siempre están presentes, alentándome a continuar. Y, finalmente, a Salem, Sami y Inmo.

Agradecimientos

La elaboración de esta tesis no hubiera sido posible sin el apoyo de diversas personas e instituciones que acompañaron este proceso de distintas maneras.

A mis asesores, Dr. Harley Vera Olivera y Dr. Carlos Fernando Montoya Cubas, les expreso mi sincero agradecimiento por la paciencia, las correcciones y las preguntas que permitieron mejorar este trabajo. Su experiencia académica e investigativa fue fundamental en cada etapa.

A los especialistas Raúl Valdivia Saravia y Lita Esther Castillo Yepes, así como al CITE Textil Camélidos Cusco del Ministerio de la Producción, les expreso mi sincero agradecimiento por la orientación técnica, el apoyo en la validación de criterios, las facilidades otorgadas y el acceso al contexto técnico productivo necesario para el análisis de la fibra de alpaca durante el proceso de cardado.

A mis compañeros y amigos, que andaban igual que yo, cada uno enfrentándose con su propio proyecto. Eso de saber que no eras el único en esta etapa ayudó más de lo que parece. Las conversaciones, los momentos de desahogo y también los de motivación hicieron que todo fuera más llevadero.

Y a mi familia, gracias por estar siempre. Por el apoyo, por la confianza y por creer que esto era posible.

Resumen

El cardado es una etapa inicial de la transformación textil de la fibra de alpaca: las fibras se abren, individualizan y ordenan en una cinta destinada al hilado, favoreciendo la separación de impurezas. La calidad depende de la distribución uniforme de las fibras y de la presencia de impurezas (pajillas y partículas) e imperfecciones (falta de homogeneidad y neps), pero se controla mediante inspección visual, lo que limita su objetividad y reproducibilidad. El objetivo fue implementar un sistema de visión computacional para identificar impurezas, evaluar imperfecciones de homogeneidad y analizar la viabilidad de detectar neps. El estudio, desarrollado con el CITE Textil Camélidos Cusco, comprendió la adquisición y depuración de imágenes, validación de clases, etiquetado y entrenamiento de modelos. La muestra incluyó 1105 imágenes: 575 para impurezas y 530 para imperfecciones de homogeneidad. Para detectar pajillas y partículas se compararon YOLOv8l, YOLO11s y YOLO26n; YOLO11s obtuvo el mejor desempeño (mAP@0.5 de 0.883, F1 promedio de 0.821). La homogeneidad se evaluó mediante indicadores de intensidad, entropía local, perfil transversal, textura GLCM y variación por bloques, integrados por votación; esta clasificación se contrastó con el criterio experto, mostrando coherencia parcial. Los resultados se integraron en una aplicación móvil con inferencia local para el análisis y diagnóstico. Se concluyó que el sistema es viable para identificar impurezas y evaluar imperfecciones de homogeneidad; la detección de neps no resultó viable por su reducido tamaño y bajo contraste, y requerirá mejores condiciones ópticas y validación instrumental.

Palabras clave: Visión computacional, Fibra de alpaca, Cardado, Imperfecciones, Impurezas.

Abstract

Carding is an initial stage in the textile transformation of alpaca fiber: the fibers are opened, individualized, and aligned into a sliver intended for spinning, favoring the separation of impurities. Quality depends on the uniform distribution of the fibers and on the presence of impurities (straw fragments and particles) and imperfections (lack of homogeneity and neps), but control is performed through visual inspection, which limits its objectivity and reproducibility. The objective was to implement a computer vision system to identify impurities, evaluate homogeneity imperfections, and analyze the feasibility of detecting neps. The study, conducted with CITE Textil Camélidos Cusco, comprised image acquisition and cleaning, class validation, labeling, and model training. The sample included 1105 images: 575 for impurities and 530 for homogeneity imperfections. To detect straw fragments and particles, YOLOv8l, YOLO11s, and YOLO26n were compared; YOLO11s achieved the best performance (mAP@0.5 of 0.883, mean F1 of 0.821). Homogeneity was evaluated using intensity, local entropy, transverse profile, GLCM texture, and block variation indicators, integrated through voting; this classification was contrasted with expert judgment, showing partial consistency. The results were integrated into a mobile application with local inference for analysis and diagnosis. It was concluded that the system is feasible for identifying impurities and evaluating homogeneity imperfections; nep detection was not feasible due to their small size and low contrast, and will require improved optical conditions and instrumental validation.

Keywords: Computer vision, Alpaca fiber, Carding, Imperfections, Impurities.

Índice general

Lista de Acrónimos	II
Agradecimientos	IV
Resumen	V
Abstract	VI
Lista de Tablas	XIII
Lista de Figuras	XIV
1. Introducción	1
1.1. Generalidades	1
1.2. Justificación	1
1.3. Planteamiento del problema de investigación	3
1.3.1. Descripción del problema	3
1.3.2. Problema general	5
1.3.3. Problemas específicos	5
1.4. Alcances y limitaciones	5
1.4.1. Alcances	5
1.4.2. Limitaciones	6
1.5. Objetivos	7
1.5.1. Objetivo general	7
1.5.2. Objetivos específicos	7
1.6. Antecedentes	7
1.6.1. Antecedentes relacionados con fibras animales	8

1.6.2.	Antecedentes relacionados con fibras vegetales	9
1.6.3.	Síntesis y brecha de investigación	14
2.	Marco teórico	16
2.1.	Herramientas	16
2.1.1.	Python	16
2.1.2.	Conda	16
2.1.3.	Ultralytics YOLO	16
2.2.	Visión computacional	17
2.2.1.	Redes neuronales convolucionales	17
2.2.2.	YOLO	19
2.2.2.1.	Arquitectura general: <i>Backbone</i> , <i>Neck</i> y <i>Head</i>	21
2.2.3.	Aprendizaje por transferencia profunda	23
2.2.4.	Escala de grises	23
2.2.5.	Segmentación de imágenes	24
2.3.	Fibra de alpaca	24
2.3.1.	Características de la fibra de alpaca	26
2.3.2.	Proceso de cardado en la industria textil	27
2.3.2.1.	Desperdicios en el proceso de cardado de alpaca	29
2.3.3.	Control de calidad en la fibra de alpaca	29
2.3.3.1.	Métodos de control de neps	30
2.3.3.2.	Densidad lineal de los materiales textiles	32
2.3.3.3.	Norma técnica peruana 231.309:2005 sobre fibra carda- da de alpaca	34
3.	Metodología de la investigación	36
3.1.	Tipo y nivel de investigación	36
3.2.	Enfoque de investigación	36
3.3.	Diseño de investigación	37

3.4. Población y muestra	37
3.5. Unidad de análisis	38
3.6. Justificación de la cantidad de datos	38
3.7. Metodológico de visión computacional	39
3.8. Preparación del entorno controlado	41
3.8.1. Entorno controlado para detección de impurezas	42
3.8.2. Entorno controlado para capturar la cinta cardada	43
3.9. Adquisición de imágenes	44
3.9.1. Análisis de impurezas e imperfecciones existentes en la cinta cardada	45
3.9.2. Materiales	46
3.9.2.1. Justificación de la selección de fibra de alpaca blanca	46
3.9.3. Captura de imágenes	48
3.10. Preparación del <i>dataset</i>	53
3.10.1. Preprocesamiento de datos	53
3.10.2. Selección y depuración del <i>dataset</i>	55
3.10.3. Definición de clases	56
3.10.3.1. Pajillas y partículas	57
3.10.3.2. Neps	57
3.10.3.3. Homogeneidad	58
3.10.3.4. Validación de clases mediante juicio de experta	59
3.10.4. Etiquetado y segmentación de datos	61
3.10.4.1. Primera etapa: etiquetado de pajillas y partículas	61
3.10.4.2. Segunda etapa: segmentación de la cinta cardada	64
3.10.5. División del <i>dataset</i>	66
3.10.6. Métricas y criterios de evaluación	67
3.10.7. Relación con la NTP 231.309:2005 (revisada el 2021)	69
3.11. Extracción de características	70

3.11.1. Descripción de los modelos	71
3.11.1.1. Modelo YOLOv8	73
3.11.1.2. Modelo YOLOv11	75
3.11.1.3. Modelo YOLO26	76
3.11.2. Aumento de datos	78
3.11.2.1. Aumento de datos para detección de impurezas	79
3.11.2.2. Aumento de datos para segmentación por instancias	80
3.11.3. Evaluación de la homogeneidad	83
3.11.3.1. Segmentación de la cinta	84
3.11.3.2. Calibración de umbrales	85
3.11.3.3. Método 1: Análisis de intensidad y entropía local	86
3.11.3.4. Método 2: Análisis del perfil transversal del velo	87
3.11.3.5. Método 3: Análisis de textura mediante matriz GLCM	88
3.11.3.6. Método 4: Análisis de variación por bloques	89
3.11.3.7. Justificación del enfoque multicriterio	90
3.11.3.8. Sistema de integración por votación	91
4. Resultados y discusión	92
4.1. Construcción y validación del <i>dataset</i>	92
4.2. Hardware	93
4.3. Configuración de entrenamiento	94
4.3.1. Detección de impurezas	94
4.3.1.1. Definición de hiperparámetros	94
4.3.2. Segmentación de cinta cardada	95
4.3.2.1. Definición de hiperparámetros	95
4.4. Aplicación y evaluación de técnicas	96
4.4.1. Detección de pajillas y partículas	96
4.4.1.1. YOLOv8l	96
4.4.1.2. YOLO11s	98

4.4.1.3.	YOLO26n	100
4.4.1.4.	Análisis de desempeño	103
4.4.2.	Segmentación de cinta cardada	105
4.4.2.1.	YOLOv8n-seg	105
4.4.2.2.	YOLO11n-seg	107
4.4.2.3.	YOLO26n-seg	108
4.4.2.4.	Análisis de desempeño	109
4.4.2.5.	Evaluación de la homogeneidad	111
4.5.	Comparación global de modelos	116
4.5.1.	Detección de impurezas	116
4.5.2.	Segmentación de cinta cardada	117
4.6.	Implementación de la aplicación móvil	117
4.6.1.	Arquitectura de la aplicación	118
4.6.2.	Flujo de funcionamiento	119
4.6.3.	Integración con el modelo de visión computacional	120
4.6.4.	Interfaz de usuario	122
4.6.5.	Generación del diagnóstico de calidad	126
4.7.	Discusión	127
4.7.1.	Construcción y viabilidad del <i>dataset</i>	127
4.7.2.	Aplicación y evaluación de técnicas de reconocimiento	128
4.7.2.1.	Interpretación comparativa y selección de modelos	128
4.7.2.2.	Generalización y alcance de la evaluación	129
4.7.3.	Implementación de la herramienta de usuario final	129
4.7.4.	Síntesis general	130
5.	Conclusiones y recomendaciones	131
5.1.	Conclusiones	131
5.2.	Recomendaciones	133
5.2.1.	Líneas de trabajo futuro	133

Bibliografía	135
---------------------	------------

Apéndices y anexos	139
---------------------------	------------

Anexo A. Resolución de exención de aspectos bioéticos	140
---	-----

Anexo B. Orden de servicio – CITE Textil Camélidos Cusco	141
--	-----

Índice de cuadros

1.	Comparación de las características del vellón de alpaca <i>Suri</i> y <i>Huacaya</i> .	27
2.	Clasificación del nivel de neps por 100 pulgadas cuadradas.	32
3.	Requisitos para la cinta cardada continua según la NTP 231.309:2005. .	35
4.	Características técnicas de la cámara y grabación de video del dispositivo Xiaomi 11T	48
5.	Definición de clases analíticas del <i>dataset</i>	54
6.	Resumen del conjunto de imágenes adquiridas	54
7.	División del <i>dataset</i> en entrenamiento, validación y prueba	67
8.	Relación entre la NTP 231.309:2005 (revisada el 2021) y el alcance del sistema.	70
9.	Comparación de las arquitecturas YOLO utilizadas en la investigación .	78
10.	Umrales de clasificación – Método 1 (Intensidad + Entropía)	87
11.	Umrales de clasificación – Método 2 (Perfil del velo)	88
12.	Umrales de clasificación – Método 3 (GLCM)	89
13.	Umrales de clasificación – Método 4 (Variación por bloques)	90
14.	Dimensiones evaluadas por cada método de análisis de homogeneidad .	91
15.	Hiperparámetros de entrenamiento – Detección de impurezas	95
16.	Hiperparámetros de entrenamiento – Segmentación de cinta cardada . .	95
17.	Métricas sobre el conjunto de prueba – YOLOv8l	97
18.	Métricas sobre el conjunto de prueba – YOLO11s	99
19.	Métricas sobre el conjunto de prueba – YOLO26n	102
20.	Comparación de métricas sobre prueba por clase y modelo	104
21.	Comparación de métricas de validación – modelos de segmentación . .	110

Índice de figuras

1.	Esquema general de una red neuronal convolucional, integrada por capas convolucionales, capas de agrupamiento y capas completamente conectadas.	18
2.	Proceso de convolución y generación de mapas de activación mediante filtros aplicados sobre la imagen de entrada.	19
3.	Funcionamiento general del sistema de detección YOLO: la imagen completa se procesa en un solo paso a través de la red neuronal convolucional.	20
4.	División de la imagen de entrada en una cuadrícula $S \times S$ utilizada por YOLO para la predicción de cajas delimitadoras, valores de confianza y probabilidades de clase.	21
5.	Estructura general de los detectores modernos basados en YOLO, compuesta por el <i>backbone</i> , el <i>neck</i> y el <i>head</i> . El <i>backbone</i> extrae características jerárquicas; el <i>neck</i> las refina a múltiples escalas; y el <i>head</i> genera las predicciones finales de detección.	23
6.	Diagrama de clasificación de las familias de camélidos.	26
7.	Máquina industrial utilizada en el proceso de cardado.	28
8.	Conjunto de fibras a la salida de los cilindros desmenuzadores.	31
9.	Conjunto de fibras entre las plantillas. Se deben contar las celdas que contienen al menos un nep.	32
10.	Pipeline metodológico de ocho etapas adaptado de CRISP-ML(Q). . . .	41
11.	Entorno controlado Maxti MAX 11-CIIC.	43
12.	Entorno controlado construido en MDF.	44
13.	Etapas del proceso de cardado de la fibra de alpaca registradas durante la adquisición de imágenes.	45

14.	Dispositivo móvil Xiaomi 11T utilizado.	48
15.	Entorno de captura para la identificación de impurezas en la cinta cardada.	49
16.	Entorno de captura para el análisis de la homogeneidad de la cinta cardada.	50
17.	Arquitectura jerárquica del <i>dataset</i> principal.	51
18.	Organización general de directorios por clase.	52
19.	Distribución por fechas y organización interna de las muestras de cinta cardada (homogeneidad).	52
20.	Estructura detallada del <i>dataset</i> correspondiente a la clase neps.	52
21.	Detalle de la organización interna del <i>dataset</i> de pajillas y partículas, incluyendo la relación entre directorios principales y subdirectorios.	53
22.	Fotografía de una muestra que contiene partículas y pajillas.	57
23.	Morfología característica de un nep en algodón.	58
24.	Ejemplo de cinta cardada con distribución homogénea de la fibra.	59
25.	Visualización de la cinta cardada mediante iluminación a contraluz bajo distintas condiciones de densidad de fibra.	60
26.	Creación y configuración del primer proyecto.	62
27.	Etiquetado manual mediante Bounding Boxes para las clases pajilla y partícula.	63
28.	Muestras ampliadas de las clases: partícula y pajillas.	64
29.	Creación y configuración inicial del proyecto en Roboflow para la tarea de <i>Instance Segmentation</i>	65
30.	Proceso de segmentación manual y resultado final del etiquetado mediante máscaras aplicado a la cinta cardada.	66
31.	Evolución de los modelos YOLO mantenidos por Ultralytics, mostrando la progresión desde YOLOv5 hasta YOLOv8 y la expansión de capacidades hacia múltiples tareas de visión computacional.	72
32.	Estructura del modelo YOLOv8, compuesta por el backbone basado en bloques C2f, el neck PANet y el head desacoplado <i>anchor-free</i>	74

33.	Módulos arquitectónicos clave de YOLOv11: bloques C3k2 para extracción eficiente de características, SPPF para agregación multi-escala y C2PSA para atención espacial.	75
34.	Diagrama simplificado de la arquitectura de YOLO26, mostrando el pipeline de preprocesamiento, extracción de características, fusión de características multi-escala, cabeza de regresión directa y predicciones sin NMS.	77
35.	Flujo de aumento de datos empleado sobre el conjunto de entrenamiento para la detección de impurezas.	80
36.	Ejemplo de imágenes generadas mediante aumento de datos a partir de una muestra original.	80
37.	Pipeline de aumento de datos aplicado al conjunto de entrenamiento para la segmentación por instancias del vellón cardado.	82
38.	Ejemplos de imágenes generadas mediante aumento de datos a partir de una muestra original de cinta cardada.	83
39.	Pipeline de evaluación de homogeneidad del velo.	84
40.	Evaluación física de la cinta cardada: medición del ancho y pesaje de porciones de la zona central con participación de la especialista.	85
41.	Evolución de las pérdidas de caja, clasificación y DFL, así como de las métricas de precisión, recall, mAP@0.5 y mAP@0.5:0.95, durante el entrenamiento y la validación del modelo YOLOv8l para la detección de impurezas.	97
42.	Matriz de confusión obtenida para el modelo YOLOv8l sobre el conjunto independiente de prueba (filas: clases predichas; columnas: clases verdaderas).	98

43.	Curvas de entrenamiento y validación del modelo YOLO11s aplicado a la detección de impurezas, con el comportamiento por época de las pérdidas de caja, clasificación y DFL y de las métricas de precisión, recall, mAP@0.5 y mAP@0.5:0.95.	99
44.	Matriz de confusión del modelo YOLO11s evaluado sobre el conjunto independiente de prueba; las filas corresponden a las clases predichas y las columnas a las clases verdaderas.	100
45.	Desempeño del modelo YOLO26n durante el entrenamiento y la validación para la detección de impurezas: pérdidas de caja, clasificación y DFL, junto con precisión, recall, mAP@0.5 y mAP@0.5:0.95 registrados en cada época.	101
46.	Resultados de clasificación del modelo YOLO26n sobre el conjunto independiente de prueba, expresados como matriz de confusión (filas: clases predichas; columnas: clases verdaderas).	103
47.	Curvas de pérdida y métricas de entrenamiento y validación del modelo YOLOv8n-seg.	106
48.	Matriz de confusión de la segmentación obtenida con YOLOv8n-seg. . .	106
49.	Comportamiento de las pérdidas y métricas de validación del modelo YOLO11n-seg a lo largo del entrenamiento.	107
50.	Resultados de segmentación del modelo YOLO11n-seg expresados como matriz de confusión.	108
51.	Evolución de las pérdidas y métricas de validación durante el entrenamiento del modelo YOLO26n-seg.	108
52.	Matriz de confusión correspondiente a la segmentación con el modelo YOLO26n-seg.	109
53.	Imagen evaluada y región de interés segmentada.	111
54.	Mapa de entropía local superpuesto sobre el velo segmentado ($\overline{H} = 4,0833$, $CV = 0,0783$).	112

55.	Análisis del perfil transversal del velo (M2).	113
56.	Matriz GLCM en escala logarítmica ($d = 5$, $\theta = 0^\circ$, 64 niveles).	114
57.	Variación espacial por bloques (4×4 , $CV = 0,0796$).	115
58.	Resultado final por votación mayoritaria: media homogeneidad (Altas: 1, Medias: 2, Bajas: 1).	116
59.	Pipeline general de funcionamiento de la aplicación móvil.	120
60.	Opciones de ingreso de imágenes en la aplicación móvil.	122
61.	Pantalla principal de la aplicación móvil.	123
62.	Resultados de los módulos de análisis de la aplicación móvil.	124
63.	Historial local y registro de opinión del especialista.	125
64.	Exportación y visualización de informes generados por la aplicación móvil.126	
65.	Oficio Virtual N° 014-2025-CBI-VRIN-UNSAAC.	140
66.	Orden de servicio de asesoramiento de tesis emitida por el CITE Textil Camélidos Cusco.	141

Capítulo 1

Introducción

1.1. Generalidades

La fibra de alpaca constituye uno de los recursos textiles más representativos del Perú y posee especial relevancia económica, productiva y cultural en la región del Cusco. Su transformación comprende distintas etapas, entre ellas el cardado, proceso en el que las fibras son abiertas, individualizadas, limpiadas y dispuestas en forma de cinta para facilitar las operaciones posteriores de hilado. La calidad obtenida en esta etapa depende, entre otros factores, de la presencia de impurezas visibles y de la regularidad con la que se distribuye la fibra.

En la práctica, la inspección de la cinta cardada se realiza principalmente de manera visual y depende de la experiencia del operario, así como de las condiciones de iluminación, color y textura de la muestra. En este contexto, la visión computacional ofrece recursos para obtener mediciones reproducibles y brindar información objetiva como apoyo al control de calidad. La presente investigación aborda esta necesidad mediante la construcción de un *dataset*, la evaluación de modelos de detección y segmentación, el análisis multicriterio de la homogeneidad y la implementación de una aplicación móvil con inferencia local.

1.2. Justificación

Este estudio responde a la importancia de respaldar el control de calidad durante el cardado de la fibra de alpaca, etapa decisiva dentro de la cadena textil andina.

Hoy en día, dicho proceso se basa principalmente en la revisión visual realizada por operarios, situación que genera subjetividad, poca consistencia entre evaluaciones y dificultades para identificar defectos de manera oportuna, lo cual repercute en la calidad, uniformidad y competitividad del producto final.

Desde el ámbito tecnológico, incorporar sistemas de visión computacional junto con técnicas de aprendizaje automático constituye un salto importante en comparación con los métodos convencionales. Esta propuesta busca apoyar el reconocimiento de pajillas y partículas perceptibles, valorar el grado de homogeneidad de la cinta cardada y examinar desde un enfoque técnico la posibilidad de identificar neps a lo largo del cardado, brindando datos más objetivos y prácticamente inmediatos como soporte al proceso de producción.

En el plano científico y tecnológico, se observa una carencia clara en los estudios existentes sobre el uso de visión computacional para evaluar la calidad de la fibra de alpaca en su etapa de cardado. Aunque existen trabajos enfocados en identificar automáticamente impurezas en fibras como el algodón mediante aprendizaje profundo, como muestran Hu et al. (2024) y J. Lin y Du (2025), no se han hallado investigaciones que traten puntualmente el análisis de impurezas e imperfecciones en la fibra de alpaca, cuyas propiedades físicas y estructurales se distinguen notablemente de las de otras fibras textiles.

Frente a este panorama, la presente investigación adapta y valida técnicas de visión computacional para un insumo de alto valor como la fibra de alpaca, generando un aporte tecnológico para la industria textil regional y sentando las bases para futuros sistemas de inspección automatizada en etapas tempranas de producción. Adicionalmente, el sistema propuesto contribuiría a reducir desperdicios y optimizar recursos, fortaleciendo la competitividad de los productores locales y su acceso a mercados internacionales exigentes en calidad, además de impulsar el desarrollo tecnológico del sector textil cusqueño.

1.3. Planteamiento del problema de investigación

1.3.1 Descripción del problema

En el Perú, el sector textil tiene una gran importancia tanto económica como cultural. Según el Ministerio de Producción (Ministerio de Producción del Perú, 2025), en 2024 el sector textil y confecciones aportó el 0.9 % al PBI nacional, equivalente a S/ 5,246 millones, y generó más de 448 mil puestos de trabajo, lo que representó el 2.5 % de la PEA ocupada nacional. Las cifras de exportación del sector en ese año totalizaron US\$ 1,635 millones, mostrando así un crecimiento de 10.1 % en relación con el año anterior. En particular, la región del Cusco concentra el 2.3 % de las empresas formales del sector textil a nivel nacional, y la fibra de alpaca constituye uno de sus principales recursos productivos, reconocido por su finura, valor comercial y demanda en mercados especializados. Sin embargo, a pesar de este potencial, el sector enfrenta limitaciones tecnológicas en el proceso de transformación de la fibra, especialmente en etapas críticas como el cardado, donde se condiciona la calidad del material destinado al hilado.

En este contexto, el CITE Textil Camélidos Cusco, perteneciente al Instituto Tecnológico de la Producción del Ministerio de la Producción, brinda transferencia tecnológica, asistencia técnica, soporte productivo y servicios de evaluación de calidad para fortalecer la cadena textil de camélidos. Su oferta comprende actividades vinculadas con la clasificación, el escarmenado, el cardado y el hilado de fibra de alpaca, además de ensayos especializados de laboratorio (Instituto Tecnológico de la Producción, 2023).

La investigación se desarrolló en coordinación con esta institución, donde se tuvo acceso al proceso de cardado, a la máquina cardadora, a muestras de fibra de alpaca y al acompañamiento de especialistas textiles. Durante la adquisición de datos se identificó que la inspección de pajillas, partículas y homogeneidad dependía principalmente de la apreciación visual y del criterio técnico del personal. Asimismo, la disponibilidad irregular de muestras y las diferencias de iluminación, color y textura dificultaban la de-

finición de criterios reproducibles. Estas condiciones delimitaron el problema estudiado y motivaron el desarrollo de una herramienta de apoyo basada en visión computacional.

El cardado forma parte del proceso de transformación textil posterior al escarmenado, etapa en la que se busca abrir y separar la fibra. Durante el cardado, la fibra es ordenada y convertida en una cinta cuya uniformidad resulta fundamental para obtener hilados de calidad. En el caso de la fibra de alpaca, esta puede clasificarse en categorías como *Medium Fleece*, *Fleece*, *Baby Alpaca* y *Super Baby Alpaca*, las cuales presentan diferencias en finura, longitud y uniformidad. No obstante, el control de calidad durante esta etapa se realiza principalmente mediante inspección visual manual, un método que depende de la experiencia del operario y que presenta limitaciones en términos de precisión, consistencia y eficiencia (Ministerio de Producción del Perú, 2024).

Asimismo, la presencia de impurezas, como pajillas y partículas, y de imperfecciones, como neps y pérdida de homogeneidad, junto con la variabilidad cromática de la fibra de color blanco, beige, negro, entre otros, dificulta la evaluación objetiva del material procesado, especialmente en fibras de tonalidades oscuras o con bajo contraste visual. Esta situación se agrava en un contexto donde el 95.4 % de las empresas del sector son microempresas (Ministerio de Producción del Perú, 2025), las cuales suelen contar con recursos limitados para implementar sistemas especializados de control de calidad. Como consecuencia, se reduce la disponibilidad de información objetiva y confiable sobre el estado de la fibra cardada, afectando la toma de decisiones durante el proceso productivo.

En consecuencia, el problema de investigación se concentró en la ausencia de una herramienta accesible y reproducible que apoyara la inspección visual de la cinta cardada mediante imágenes digitales. Esta necesidad comprendió tres aspectos: la identificación de pajillas y partículas visibles, la evaluación de la homogeneidad aparente y el análisis de la viabilidad técnica de detectar neps bajo condiciones controladas. Por ello, se planteó implementar y evaluar un sistema de visión computacional integrado en una aplicación móvil, sin pretender sustituir el criterio del especialista ni los ensayos

instrumentales de calidad textil.

1.3.2 Problema general

Por consiguiente, se formula la siguiente pregunta de investigación:

¿Cómo implementar un sistema de control de calidad de la fibra de alpaca basado en visión computacional que permita analizar la viabilidad técnica de detección de neps, evaluar la homogeneidad de la cinta cardada e identificar pajillas y partículas durante el proceso de cardado?

1.3.3 Problemas específicos

El estudio aborda los siguientes problemas específicos:

- ¿Cómo construir un *dataset* representativo para neps, homogeneidad, pajillas y partículas, determinando su viabilidad de etiquetado?
- ¿Cómo aplicar técnicas de reconocimiento de patrones para analizar la viabilidad técnica de detección de neps, evaluar la homogeneidad de la cinta cardada e identificar pajillas y partículas visibles durante el proceso de cardado?
- ¿Cómo implementar una herramienta de usuario final que asista a los operarios en la identificación de pajillas y partículas, así como en la evaluación de la homogeneidad de la cinta cardada, permitiendo obtener un diagnóstico de apoyo sobre el nivel de calidad?

1.4. Alcances y limitaciones

1.4.1 Alcances

La investigación comprende el diseño de entornos controlados de captura, la adquisición y depuración de imágenes de fibra de alpaca durante el cardado, la construcción y el etiquetado de *datasets* para pajillas, partículas y cinta cardada, y la evaluación

comparativa de modelos de la familia YOLO. El sistema permite detectar pajillas y partículas visibles, segmentar la región correspondiente a la cinta cardada y estimar su homogeneidad mediante indicadores de intensidad, entropía local, perfil transversal, textura GLCM y variación espacial por bloques. Asimismo, incluye una aplicación móvil que ejecuta inferencia local mediante modelos en formato TFLite y registra los resultados como apoyo para la inspección del material.

El alcance experimental se circunscribe a las imágenes obtenidas con las muestras, dispositivos y configuraciones de captura descritos en la metodología. Por tanto, las métricas reportadas representan el desempeño de los modelos dentro de esas condiciones y no constituyen una certificación instrumental de la calidad textil ni sustituyen el criterio de un especialista.

1.4.2 Limitaciones

El estudio se desarrolló con fibra de alpaca blanca, que fue la muestra disponible en cantidad suficiente durante la adquisición coordinada con el CITE Textil Camélidos Cusco. Esta selección permitió controlar la variabilidad cromática y obtener mayor contraste visual para el etiquetado de pajillas y partículas y el análisis de la distribución aparente de la cinta. Las muestras de otros colores fueron insuficientes para construir conjuntos representativos de entrenamiento, validación y prueba; además, bajo las condiciones de captura utilizadas, las muestras oscuras presentaron menor contraste para algunas impurezas. Por ello, no se evaluó la generalización del sistema frente a todos los colores, categorías, densidades y lotes comerciales de fibra de alpaca.

Los neps no presentaron contraste, tamaño ni nitidez suficientes para efectuar un etiquetado visual consistente con los equipos empleados; en consecuencia, no se entrenó un detector específico para esta imperfección y su análisis se limitó a determinar la viabilidad técnica bajo las condiciones de captura establecidas. Además, la clasificación de homogeneidad se basa en indicadores obtenidos de imágenes y en umbrales experimentales, por lo que requiere una validación posterior con más especialistas y con

mediciones textiles instrumentales. La evaluación en escenarios no controlados también se encuentra condicionada por cambios de iluminación, distancia, orientación, fondo y características de la cámara del dispositivo móvil.

1.5. Objetivos

1.5.1 *Objetivo general*

Implementar un sistema de control de calidad de la fibra de alpaca basado en visión computacional para analizar la viabilidad técnica de detección de neps, evaluar la homogeneidad de la cinta cardada e identificar pajillas y partículas visibles durante el proceso de cardado.

1.5.2 *Objetivos específicos*

- Construir un *dataset* representativo para neps, homogeneidad, pajillas y partículas, determinando su viabilidad de etiquetado.
- Aplicar y evaluar técnicas de reconocimiento de patrones para analizar la viabilidad técnica de detección de neps, evaluar la homogeneidad de la cinta cardada e identificar pajillas y partículas visibles durante el proceso de cardado.
- Implementar una herramienta de usuario final que asista a los operarios en la identificación de pajillas y partículas, así como en la evaluación de la homogeneidad de la cinta cardada, permitiendo obtener un diagnóstico de apoyo sobre el nivel de calidad.

1.6. Antecedentes

Los antecedentes se organizaron según el origen de la fibra principal estudiada. La alpaca es una fibra natural animal de naturaleza proteica, mientras que el algodón

y el yute son fibras naturales vegetales de naturaleza celulósica. Esta diferencia no es únicamente taxonómica: determina propiedades como la morfología superficial, el diámetro, la ondulación, la medulación, el color natural y la forma en que las fibras se agrupan durante el procesamiento (Ingle & Jasper, 2024; Wang et al., 2003).

En visión computacional, estas propiedades modifican el dominio de las imágenes. Los estudios con algodón suelen analizar una fibra clara y contaminantes definidos, como hojas, ramas, películas, cabello o fibras sintéticas. En la alpaca, la ondulación, la densidad del velo y la diversidad de tonalidades pueden cambiar el contraste, ocultar parcialmente las impurezas y generar patrones de textura diferentes. Además, los neps corresponden a enredos de la propia fibra y no a objetos externos, por lo que su apariencia depende del material y de las condiciones de captura. En consecuencia, un modelo entrenado con algodón puede aportar criterios arquitectónicos y metodológicos, pero sus parámetros y resultados no pueden transferirse directamente a la alpaca sin construir y validar un *dataset* específico. En los trabajos sobre algodón, la expresión *fibra extraña* designa un contaminante incorporado al material y no modifica el origen vegetal de la fibra principal.

1.6.1 Antecedentes relacionados con fibras animales

Ingle y Jasper (2024). Una revisión del aprendizaje profundo para mejorar la calidad de fibras e hilos.

Objetivo y metodología: los autores revisaron aplicaciones de inteligencia artificial destinadas a evaluar propiedades de fibras e hilos y a reducir la dependencia de ensayos manuales. Analizaron técnicas como análisis de componentes principales, máquinas de soporte vectorial, redes neuronales, redes convolucionales y modelos YOLO. La revisión incluyó fibras vegetales, principalmente algodón y yute, y fibra animal de alpaca. En esta última, los trabajos recopilados emplearon imágenes especializadas y redes neuronales para medir el diámetro e identificar tipos de medulación en fibras individuales.

Resultados: la revisión mostró que los modelos pueden apoyar tareas de clasificación, medición y detección de defectos, además de predecir propiedades de los hilos. Para la alpaca, reportó resultados favorables en mediciones microscópicas de diámetro y medulación. Sin embargo, también señaló que el desempeño y la generalización dependen de *datasets* diversos, representativos y correctamente etiquetados, cuya disponibilidad continúa siendo limitada en varios dominios textiles.

Limitación: el artículo sintetiza investigaciones previas y no presenta un *dataset* ni una validación experimental propia. La evidencia sobre alpaca se restringe al análisis de fibras individuales bajo condiciones especializadas; no comprende cinta cardada ni evalúa pajillas, partículas, neps u homogeneidad mediante imágenes convencionales.

Aporte y brecha: este antecedente confirma que la visión computacional puede emplearse para evaluar características de una fibra animal. No obstante, evidencia que la investigación en alpaca se ha concentrado en propiedades microscópicas y no en el control de calidad durante el cardado. La presente tesis amplía ese alcance hacia la inspección macroscópica de la cinta cardada y la implementación de una herramienta de apoyo para el proceso productivo.

1.6.2 *Antecedentes relacionados con fibras vegetales*

Los trabajos de este grupo estudian algodón, una fibra natural vegetal. Sus métodos de adquisición y detección constituyen referencias técnicas relevantes, pero sus métricas no pueden extrapolarse directamente a la alpaca debido a las diferencias del material, las clases de contaminantes y las condiciones de captura.

Han et al. (2024). Predicción de la calidad del proceso de cardado mediante gemelo digital.

Objetivo y metodología: el estudio buscó predecir la tasa de eliminación de neps en cinta de algodón a partir de la calidad de la materia prima y de variables operativas de la cardadora, como velocidades, producción, galgas y características de las guarniciones. Los autores construyeron un gemelo digital que combinó un modelo mecanicista

del proceso con modelos basados en datos. Debido a la escasez de registros, ampliaron 50 observaciones reales con 150 registros generados mediante una red generativa adversarial y posteriormente integraron diferentes predictores mediante *stacking*.

Resultados: el modelo integrado reprodujo la tendencia de la tasa de eliminación de neps y obtuvo un error promedio de 5.7 %. La combinación del conocimiento físico con los datos redujo la dependencia de grandes volúmenes de entrenamiento y presentó mejor estabilidad que el empleo aislado de una red neuronal.

Limitación: los autores observaron desviaciones y oscilaciones en algunas predicciones, atribuidas principalmente al reducido número de registros reales. Además, el método requiere mediciones de neps y parámetros de la máquina; no utiliza imágenes como entrada ni plantea una inspección visual del material.

Aporte y brecha: el trabajo demuestra que la presencia y eliminación de neps están relacionadas con la materia prima y la configuración de la cardadora. Este resultado ayuda a explicar por qué los neps no necesariamente pueden evaluarse de forma confiable con una fotografía convencional. La brecha permanece en determinar, específicamente para alpaca, hasta qué punto una imagen permite reconocerlos y cuándo se requieren mediciones físicas u operacionales complementarias.

Hu et al. (2024). Detección de impurezas del algodón mediante GBM-YOLOv5.

Objetivo y metodología: los autores propusieron un detector ligero para identificar impurezas pequeñas y dispersas en imágenes de algodón adquiridas con cámaras industriales. Construyeron un conjunto de 4850 imágenes y etiquetaron cuatro tipos de impurezas. A partir de YOLOv5, reemplazaron componentes por bloques GhostBottleneck para reducir el costo computacional, incorporaron atención CBAM para resaltar regiones relevantes y utilizaron SoftPool para conservar características finas durante la reducción espacial.

Resultados: GBM-YOLOv5 alcanzó un mAP de 88.72 % y redujo el número de parámetros y las operaciones respecto del modelo base. Los experimentos mostraron que la combinación de una estructura ligera con atención permitió mantener un desempe-

no competitivo en objetos pequeños, con posibilidades de integración en dispositivos industriales de recursos limitados.

Limitación: los autores reconocieron que determinados escenarios pueden requerir modelos más pequeños, mayor velocidad o una precisión especializada por tarea. Asimismo, la evaluación se efectuó sobre algodón y con un sistema industrial de captura, por lo que no demuestra su desempeño frente a la textura y variabilidad cromática de la alpaca.

Aporte y brecha: aporta criterios para seleccionar arquitecturas capaces de conservar información de impurezas pequeñas y dispersas, características compartidas por las pajillas y partículas del presente estudio. Sin embargo, no aborda la homogeneidad, los neps ni la integración de diferentes funciones de control de calidad en un solo sistema para fibra animal.

J. Lin y Du (2025). Identificación de fibras extrañas en algodón mediante CAF-YOLO.

Objetivo y metodología: la investigación tuvo como propósito mejorar la localización y clasificación de fibras extrañas presentes en algodón. Los autores modificaron YOLOv7 mediante un módulo de atención eficiente de canal y una red piramidal destinada a reforzar la fusión de características a distintas escalas. El conjunto incluyó contaminantes como fibras sintéticas, tela, cabello, plumas y materiales químicos, cuyas variaciones de tamaño y forma dificultaban su identificación.

Resultados: CAF-YOLO obtuvo 97.5 % de precisión, 96.4 % de mAP@0.5 y una velocidad de 154 FPS. En las comparaciones realizadas bajo las mismas particiones y condiciones experimentales, superó a los demás detectores considerados, especialmente en precisión y velocidad.

Limitación: el *dataset* no se encuentra disponible públicamente, lo que restringe la reproducción independiente de los resultados. Además, las clases corresponden a fibras extrañas en algodón y no a los tipos de impurezas observados en la cinta cardada de alpaca; tampoco se analizaron neps u homogeneidad.

Aporte y brecha: el estudio evidencia que la atención por canales y la fusión multiescala pueden mejorar la detección rápida de contaminantes heterogéneos. Su aporte para esta tesis es arquitectónico y comparativo; la brecha consiste en comprobar si esos principios mantienen su utilidad sobre un *dataset* propio de alpaca y con objetos de menor contraste.

Xu et al. (2023). Detección de impurezas blancas y de color similar al algodón mediante WFF-YOLO.

Objetivo y metodología: los autores buscaron mejorar el reconocimiento de impurezas blancas o cromáticamente semejantes al algodón bajo una fuente de luz visible. Desarrollaron WFF-YOLO a partir de YOLOv4-tiny, incorporando fusión ponderada de características, una cabeza desacoplada y un mecanismo de detección sin anclas. El *dataset* propio reunió 1119 imágenes de seis tipos de impurezas, de las cuales 894 se destinaron al entrenamiento y 225 a la prueba.

Resultados: el modelo alcanzó 95.43 % de mAP y 243.18 FPS. Para las impurezas blancas y las de color cercano al algodón obtuvo precisiones de 98.78 % y 98.00 %, respectivamente. Estos resultados mostraron que la combinación de información multiescala y tareas desacopladas favoreció la identificación de objetos con poco contraste sin comprometer la velocidad.

Limitación: la precisión descendió en objetos alargados que aparecían parcialmente en la zona de captura, como el cordel. Los autores también indicaron la necesidad de ampliar la diversidad del *dataset*. La evaluación se limitó a algodón crudo bajo iluminación controlada y no estudió la respuesta del modelo ante fibras de distintos colores.

Aporte y brecha: es relevante porque aborda una dificultad semejante a la de las pajillas y partículas que se confunden con el fondo fibroso. No obstante, queda pendiente evaluar estas estrategias en alpaca blanca y, posteriormente, en tonalidades oscuras donde cambia la relación de contraste entre la fibra y las impurezas.

Q. Li et al. (2024). Detección rápida de fibras extrañas en algodón en rama

mediante Cotton-YOLO.

Objetivo y metodología: el estudio desarrolló un sistema integral para detectar cinco clases de fibras extrañas en algodón en rama: plumas, fibras químicas, película residual, cabello y tela. Incluyó la preparación del material, un entorno de captura con cámara de alta resolución, etiquetado manual y división de los datos. El detector modificó YOLOv7 mediante componentes ConvNeXt y Swin Transformer para reforzar la extracción de características y acelerar la inferencia.

Resultados: Cotton-YOLO alcanzó 99.12 % de precisión, 96.92 % de mAP@0.5 y 132.2 FPS, equivalentes a 7.6 ms por imagen. Frente a YOLOv7, conservó métricas elevadas y aumentó de manera importante la velocidad, lo que respaldó su uso potencial en inspección en línea.

Limitación: el algodón debía abrirse antes de la captura; cuando los contaminantes permanecían envueltos por la fibra podían ocultarse y no ser detectados. Los autores tampoco publicaron el *dataset*. El sistema se concentró en contaminantes externos y no evaluó atributos globales de la cinta producida durante el cardado.

Aporte y brecha: este trabajo aporta un flujo completo que relaciona preparación de muestras, captura, anotación, entrenamiento y evaluación de eficiencia. Sirve como referencia para estructurar el pipeline de la tesis, pero deja sin resolver la evaluación simultánea de impurezas y homogeneidad en cinta cardada de alpaca y su despliegue en un dispositivo móvil.

J. Li et al. (2025). Detección ligera de impurezas en algodón de caída mediante Cotton-YOLO.

Objetivo y metodología: los autores propusieron un sistema ligero para detectar sustancias no fibrosas, como hojas, ramas y tierra, en algodón procedente de una zona de caída de la cardadora. Adquirieron 1000 imágenes, divididas en 800 para entrenamiento y 200 para prueba. El modelo partió de YOLOv8 e incorporó atención CBAM, el bloque ligero C2f_DSConv y la función Wise-IoU. Además, implementaron una interfaz para visualizar detecciones y estadísticas del conjunto evaluado.

Resultados: Cotton-YOLO obtuvo 86.5 % de precisión, 80.7 % de recall, 89.6 % de mAP@0.5 y 50.51 FPS. El número de parámetros se redujo a 2.71 millones, aproximadamente 12 % menos que YOLOv8, con un incremento de 3.5 % en velocidad.

Limitación: el modelo presentó menor robustez ante iluminación extrema, sombras e impurezas en movimiento. Su salida detectó la presencia general de impurezas, pero no distinguió categorías específicas como tierra o ramas, lo que restringe una clasificación más detallada.

Aporte y brecha: es el antecedente vegetal más próximo a la tesis porque estudia hojas y ramas visualmente relacionadas con las pajillas, utiliza YOLOv8 y considera tanto eficiencia como presentación de resultados. Sin embargo, no diferencia las clases requeridas en alpaca, no analiza homogeneidad ni neps y no valida inferencia local en una aplicación móvil.

1.6.3 Síntesis y brecha de investigación

Los antecedentes evidencian una diferencia marcada según el origen de la fibra. En alpaca, la evidencia disponible se concentra en imágenes especializadas de fibras individuales para medir diámetro y medulación. En algodón, por el contrario, existen sistemas experimentales de adquisición y modelos YOLO orientados a localizar impurezas o fibras extrañas bajo condiciones controladas. Aunque estos últimos demuestran la viabilidad de la inspección automática, sus métricas responden a una fibra vegetal celulósica, generalmente clara, y a contaminantes diferentes. La alpaca presenta una estructura proteica, ondulación, medulación y mayor diversidad cromática; por ello, cambia la relación visual entre la fibra, las impurezas y las imperfecciones. Esta diferencia de dominio impide asumir que el desempeño obtenido en algodón se conservará en cinta cardada de alpaca.

También se identificaron dos vacíos funcionales. Primero, los trabajos de detección se enfocan en objetos localizados y no integran una evaluación visual de la distribución global de la fibra. Segundo, el estudio de los neps suele apoyarse en mediciones físicas o

variables del proceso, mientras que no se encontró una validación de su reconocimiento mediante imágenes convencionales de alpaca cardada.

En consecuencia, en los documentos revisados no se identificó un sistema que reúna la detección diferenciada de pajillas y partículas, la evaluación visual de homogeneidad, el análisis de viabilidad de los neps y la ejecución local mediante una aplicación móvil para fibra de alpaca cardada. Esta brecha delimita el aporte de la tesis: adaptar y comparar técnicas de visión computacional sobre un *dataset* propio de fibra animal, establecer qué atributos pueden evaluarse mediante imágenes y reconocer aquellos que requieren medición física o instrumental.

Capítulo 2

Marco teórico

2.1. Herramientas

2.1.1 *Python*

De acuerdo con Raschka et al. (2020), Python se ha consolidado como el lenguaje más utilizado en el ámbito del cómputo científico, la ciencia de datos y el aprendizaje automático, gracias a su sintaxis legible, su amplia comunidad y la disponibilidad de bibliotecas especializadas que facilitan el desarrollo de aplicaciones complejas. En el marco de las tecnologías de visión por computadora y aprendizaje automático, Python ofrece un ecosistema robusto compuesto por librerías como *NumPy*, *Pandas*, *Scikit-learn*, *TensorFlow* y *PyTorch*, las cuales permiten la manipulación eficiente de grandes volúmenes de datos, el entrenamiento de modelos de redes neuronales profundas y la integración con hardware acelerado mediante GPU.

2.1.2 *Conda*

Según El Pythonista (2024), *Conda* funciona como la herramienta de *Anaconda* encargada de gestionar paquetes y entornos virtuales, permitiendo instalar, actualizar y mantener librerías de Python de manera eficiente.

2.1.3 *Ultralytics YOLO*

Ultralytics YOLO es una familia de detectores de objetos en tiempo real que ha evolucionado desde su primera versión en 2016 hasta modelos avanzados como YO-

LOv8, YOLO11 y YOLO26. Estos modelos se caracterizan por combinar alta precisión con baja latencia, lo que los hace ideales para aplicaciones de visión computacional en áreas como robótica, agricultura, manufactura y vigilancia. La versión YOLOv8 introdujo una arquitectura con cabeza desacoplada y predicciones sin anclas, mejorando la precisión en objetos pequeños y la estabilidad del entrenamiento. Posteriormente, YOLO26 consolidó un enfoque de inferencia libre de NMS (Non-Maximum Suppression) y eliminó la pérdida DFL (Distribution Focal Loss), logrando una mayor eficiencia y compatibilidad con dispositivos de borde. Gracias a su diseño modular en PyTorch y a su soporte para detección, segmentación y clasificación, YOLO representa actualmente una de las soluciones más robustas y versátiles en visión computacional (Sapkota & Karkee, 2025).

2.2. Visión computacional

2.2.1 *Redes neuronales convolucionales*

Las redes neuronales convolucionales (CNN) aparecieron como respuesta a las restricciones de los enfoques clásicos de visión por computadora, que requerían diseñar manualmente los descriptores de características. Tal como señala Ajit et al. (2020), este tipo de red es capaz de aprender por sí misma representaciones útiles a partir de los datos visuales, lo que se traduce en mayor eficiencia y precisión al abordar tareas como el reconocimiento de imágenes o la detección de patrones.


En cuanto a su arquitectura, una CNN se construye a partir de varias capas especializadas dispuestas en secuencia, encargadas de procesar la información visual de forma jerárquica. O'Shea y Nash (2015) identifica tres componentes principales dentro de esta arquitectura: las capas convolucionales, las capas de *pooling* (o agrupamiento) y las capas totalmente conectadas; la combinación de estas permite convertir la imagen de entrada en una representación adecuada para su clasificación.

En la Figura 1 se ilustra un esquema general de una red convolucional orientada a

la clasificación de imágenes. El flujo de procesamiento inicia con capas convolucionales combinadas con activaciones ReLU; a continuación intervienen capas de agrupamiento que disminuyen la dimensionalidad espacial de los mapas de características, y por último las capas completamente conectadas generan la salida asociada a cada clase posible (O'Shea & Nash, 2015).

Figura 1

Esquema general de una red neuronal convolucional, integrada por capas convolucionales, capas de agrupamiento y capas completamente conectadas.



Nota. Adaptado de O'Shea & Nash (2015).


Las capas convolucionales se encargan de extraer características locales mediante el uso de filtros o kernels que se desplazan sobre regiones pequeñas de la imagen. Este proceso consiste en la aplicación de una operación de convolución que calcula el producto escalar entre los valores de los píxeles y los pesos del filtro, generando mapas de activación que resaltan patrones relevantes como bordes, formas y texturas, preservando la estructura espacial de los datos (O'Shea & Nash, 2015).

La Figura 2 ilustra el proceso de convolución, en el cual un filtro se desplaza sobre la imagen de entrada para producir un mapa de activación. Este mecanismo permite a la red aprender automáticamente características discriminativas en diferentes niveles de abstracción. Para introducir no linealidad en el modelo y mejorar el proceso de aprendizaje, comúnmente se emplea la función de activación ReLU, la cual elimina

valores negativos y acelera la convergencia del entrenamiento (Ajit et al., 2020).

Figura 2

Proceso de convolución y generación de mapas de activación mediante filtros aplicados sobre la imagen de entrada.



Nota. Adaptado de Ajit et al. (2020).

Posteriormente, las capas de agrupamiento permiten reducir las dimensiones espaciales de los mapas de activación, contribuyendo a disminuir tanto el costo computacional como el riesgo de sobreajuste, sin perder la información más significativa. Finalmente, las capas completamente conectadas integran las características extraídas por las capas anteriores y producen la salida final del modelo, correspondiente a la clasificación o predicción deseada (O'Shea & Nash, 2015).


2.2.2 YOLO

YOLO (You Only Look Once) es un sistema de detección de objetos en tiempo real que aborda la localización y la clasificación dentro de un único proceso unificado. A partir de una sola pasada de la imagen completa por una red neuronal convolucional, el modelo genera simultáneamente las cajas delimitadoras junto con las probabilidades de clase asociadas. Esto lo distingue de los enfoques tradicionales de múltiples etapas: YOLO plantea la detección como un problema de regresión directa, que va desde los píxeles de entrada hasta las salidas finales, logrando así reducir considerablemente el tiempo de inferencia (Redmon et al., 2016).

El funcionamiento general se ilustra en la Figura 3, donde puede verse que la red procesa la imagen de entrada de forma completa e integral, lo que le permite captar el contexto global de la escena. Al considerar toda la información disponible en conjunto, el modelo logra predicciones espacialmente más coherentes y disminuye los falsos positivos generados en regiones de fondo, a diferencia de aquellos métodos que analizan cada región por separado.

Figura 3

Funcionamiento general del sistema de detección YOLO: la imagen completa se procesa en un solo paso a través de la red neuronal convolucional.




Nota. Adaptado de Redmon et al. (2016).

Para llevar a cabo la detección, YOLO divide la imagen de entrada en una cuadrícula de $S \times S$ celdas, tal como se muestra en la Figura 4. Cada una de estas celdas produce un conjunto de cajas delimitadoras junto con un valor de confianza que expresa tanto la probabilidad de que haya un objeto presente como la precisión estimada de su ubicación. Además, cada celda estima las probabilidades condicionales de clase, y la detección se asigna a la celda dentro de la cual cae el centro del objeto (Redmon et al., 2016).

Figura 4

División de la imagen de entrada en una cuadrícula $S \times S$ utilizada por YOLO para la predicción de cajas delimitadoras, valores de confianza y probabilidades de clase.



Nota. Adaptado de Redmon et al. (2016).

Este enfoque permite a YOLO realizar detecciones de manera eficiente, manteniendo un equilibrio adecuado entre velocidad y precisión. Debido a estas características, YOLO se ha consolidado como una arquitectura base para numerosos sistemas modernos de detección de objetos y constituye el método principal empleado en la presente investigación.

2.2.2.1 Arquitectura general: Backbone, Neck y Head

La arquitectura de los detectores modernos basados en YOLO se organiza en tres componentes funcionales: el *backbone*, el *neck* y el *head*. Esta organización modular fue adoptada a partir de **YOLOv4**, versión en la que se consolidó formalmente esta descripción arquitectónica, y ha sido mantenida en todas las versiones posteriores del framework (Terven et al., 2023).

El *backbone* corresponde a la red neuronal convolucional que se encarga de obtener representaciones jerárquicas de las características presentes en la imagen de entrada. En las primeras capas se identifican rasgos elementales, tales como bordes y texturas, en tanto que las capas de mayor profundidad capturan información semántica más

compleja, relacionada con formas y estructuras de alto nivel. En los modelos YOLO recientes, se emplean *backbones* como CSPDarkNet53, C2f o variantes basadas en bloques de agregación cruzada que optimizan el flujo de gradientes durante el entrenamiento (Ali & Zhang, 2024).


El *neck* cumple la función de enlace entre el *backbone* y el *head*, encargándose de combinar y refinar los mapas de características obtenidos en diferentes escalas espaciales, integrando así los rasgos semánticos provenientes de las capas profundas con la información espacial propia de las capas más superficiales. Para ello, se emplean mecanismos como las redes de pirámide de características (*Feature Pyramid Network*, FPN) y redes de agregación de caminos (*Path Aggregation Network*, PANet), que permiten mejorar la detección de objetos de distintos tamaños (Terven et al., 2023).

El *head* es el componente final de la arquitectura y se encarga de generar las predicciones a partir de las características proporcionadas por el *neck*. Para cada candidato de objeto, el *head* produce simultáneamente las coordenadas de la caja delimitadora, el valor de confianza de detección y las probabilidades de clase. Finalmente, se aplica la supresión de no máximos (*Non-Maximum Suppression*, NMS) para eliminar detecciones redundantes y retener únicamente las predicciones de mayor confianza (Ali & Zhang, 2024).

En la Figura 5 se ilustra la estructura general de estos tres componentes. Esta organización modular ha facilitado el desarrollo incremental de las distintas versiones de YOLO, permitiendo incorporar mejoras específicas en cada componente sin modificar la arquitectura global del sistema.

Figura 5

Estructura general de los detectores modernos basados en YOLO, compuesta por el backbone, el neck y el head. El backbone extrae características jerárquicas; el neck las refina a múltiples escalas; y el head genera las predicciones finales de detección.



Nota. Adaptado de Terven et al. (2023).

2.2.3 Aprendizaje por transferencia profunda

Como señalan Iman et al. (2023), el aprendizaje por transferencia profunda se fundamenta en la reutilización del conocimiento adquirido por un modelo en una tarea o *dataset* previo, incluso cuando no existe una relación estrecha con la nueva tarea objetivo. Este enfoque permite disminuir significativamente los costos de entrenamiento y mitigar la necesidad de contar con grandes volúmenes de datos etiquetados, un requisito habitual en los modelos de aprendizaje profundo.

2.2.4 Escala de grises

Según Huang et al. (2018), convertir una imagen a escala de grises implica transformar una imagen a color en una representación monocromática, en la cual cada píxel expresa exclusivamente el nivel de intensidad luminosa. Dicho proceso favorece el análisis de rasgos visuales, simplificando la complejidad de los datos y conservando los

elementos esenciales relativos al contraste y la forma. En el contexto del aprendizaje profundo y las redes convolucionales, la escala de grises resulta fundamental, ya que simplifica el entrenamiento de modelos y mejora la extracción de características relevantes al eliminar la redundancia cromática.

2.2.5 Segmentación de imágenes

La segmentación de imágenes es el proceso de dividir una imagen en múltiples regiones o partes que pertenecen a la misma clase, mediante criterios como color, textura u otras características visuales. Este procedimiento, también denominado clasificación a nivel de píxel, asigna a cada píxel una categoría específica para delimitar objetos o áreas de interés dentro de la escena (Klingler, 2023).

2.3. Fibra de alpaca

La fibra textil constituye una estructura cilíndrica, delgada y flexible empleada en la fabricación de materiales textiles. De acuerdo con su origen, las fibras se clasifican en naturales y químicas. Las fibras naturales provienen de fuentes animales, vegetales o minerales, mientras que las fibras químicas son obtenidas mediante transformación industrial de polímeros. Dentro de las fibras animales destacan la lana, los pelos finos y la seda; en el caso de las vegetales, estas pueden obtenerse de semillas, tallos, hojas o frutos. La única fibra mineral tradicionalmente reconocida es el amianto. Por su parte, las fibras químicas pueden subdividirse en orgánicas —artificiales o sintéticas— e inorgánicas. A partir de estas fibras se produce el hilo textil mediante procesos de torsión, alineamiento y cohesión mecánica.

Dentro de las fibras animales de alto valor, la fibra de alpaca ocupa un lugar destacado por sus propiedades físicas, su relevancia histórica y su importancia económica en la industria textil de lujo. Proveniente de la alpaca (*Vicugna pacos*), especie domesticada de camélido sudamericano, esta fibra ha sido utilizada por más de 3000 años en

la región andina y representa uno de los recursos textiles más emblemáticos del Perú. Su reconocimiento internacional se debe a características altamente valoradas como suavidad, capacidad térmica, ligereza, resistencia mecánica y una amplia variedad de tonalidades naturales, atributos que la posicionan como una fibra premium dentro del mercado global (Wang et al., 2003).

Desde una perspectiva zoológica y productiva, la alpaca pertenece a la familia de los camélidos sudamericanos, grupo que incluye especies domésticas y silvestres adaptadas a ecosistemas altoandinos. La Figura 6 presenta la clasificación taxonómica general de las familias de camélidos, permitiendo contextualizar biológicamente la posición de la alpaca dentro de este grupo.


Se reconocen principalmente dos variedades fenotípicas de alpaca, diferenciadas por la morfología de su vellón y por las propiedades textiles de su fibra:

1. **Huacaya:** Caracterizada por producir vellones densos, voluminosos y con estructura ondulada o crimpada. Esta conformación genera una apariencia esponjosa y mayor elasticidad, siendo utilizada frecuentemente en mezclas con otras fibras finas como la lana Merino.
2. **Suri:** Produce fibras largas, lisas, sedosas y con menor ondulación. Se distingue por su brillo, caída y suavidad superior, siendo altamente valorada en productos textiles de mayor exclusividad.

Estas diferencias estructurales no solo influyen en el comportamiento textil del material, sino también en los procesos de clasificación, transformación industrial y evaluación de calidad, aspectos fundamentales para el desarrollo de sistemas automatizados de análisis de fibra.

Figura 6

Diagrama de clasificación de las familias de camélidos.



Nota. Adaptado de Wang et al. (2003).

2.3.1 Características de la fibra de alpaca

La fibra de alpaca se caracteriza por su delicadeza, con un grosor que oscila entre 16 y 31.5 micras. La longitud suele superar los 7 cm, y aunque su resistencia es menor que la de la lana ovina, supera en este aspecto a la fibra de Cashmere. Una de las características más interesantes de esta fibra es su amplia paleta de colores naturales, que incluye más de 17 tonos diferentes, que van desde el blanco puro hasta hermosos matices de café y gris. Se utiliza principalmente en la creación de fibras largas, lo que permite producir hilos peinados más uniformes para la confección de prendas de calidad superior. Esta fibra destaca particularmente por su suavidad, su ligereza y sus propiedades térmicas. Además, es resistente al agua y no se inflama fácilmente (Alpaca del Perú, 2024).

Características del vellón de alpaca

El vellón de alpaca se clasifica en dos tipos principales: Suri y Huacaya, que presentan diferencias notables en sus características físicas. Seguidamente, se presenta una tabla comparativa con dichas características:

Tabla 1*Comparación de las características del vellón de alpaca Suri y Huacaya.*

Características del vellón	Suri	Huacaya
Tipo de vellón	Dividido, se expande hacia el dorso	Envolvente, cubre todo el cuerpo
Longitud de la fibra	Longitud mayor	Longitud menor
Densidad	Menor densidad	Mayor densidad
Forma de las fibras	Largas y onduladas	Cortas y gruesas
Rizos	Escasos, fibras lisas	Tendencia a rizos
Finura de la fibra	Promedio de 26.8 μm , más uniforme	Promedio de 27.7 μm , menos uniforme
Brillo	Brillante, con características capilares	Brillo reducido, similar a la lana
Suavidad	Más suave al tacto	Menos suave al tacto
Elasticidad	Más elástica	Menos elástica
Capacidad de filtración	Mayor capacidad de filtración	Menor capacidad de filtración
Rendimiento en peso	Mayor rendimiento	Menor rendimiento

En términos generales, el Suri se caracteriza por su mayor longitud, suavidad y finura, mientras que el Huacaya es más denso y tiene una textura menos suave (Alpaca del Perú, 2024).

2.3.2 Proceso de cardado en la industria textil

Según Lockuán Lavado (2012), el cardado constituye una fase esencial en el proceso de hilado, considerada el núcleo de este proceso, ya que influye directamente en las características finales del hilo. Su finalidad principal en el caso de la fibra de alpaca es la limpieza e individualización de las fibras, garantizando que queden libres de impurezas y listas para las siguientes fases de producción textil. La *máquina cardadora* empleada en esta etapa se muestra en la Figura 7.

Figura 7

Máquina industrial utilizada en el proceso de cardado.



Nota. Tomado de Lockuán Lavado (2012).

Los principales objetivos del cardado incluyen:

- Desagregación de los copos de fibra y separación de las fibras individuales.
- Eliminación de residuos de impurezas que no fueron eliminados en los pasos de limpieza previos.
- Clasificación de las fibras según su longitud, descartando las más cortas.
- Alineación y alargamiento de las fibras.
- Formación de una cinta, es decir, una masa de fibras dispuestas sin torsión.

El proceso de cardado está compuesto por órganos móviles (como el tambo delantero, el gran tambor, chapones, trabajadores y limpiadores) con puntos de acero elástico y dientes de sierra. Se mueven a diferentes velocidades y a corta distancia, facilitando la apertura y alineación eficiente de las fibras (Lockuán Lavado, 2012).

El principio del cardado se basa en los siguientes factores:

- La acción de las fuerzas centrífugas entre las piezas que están en contacto.

- La dirección en que las piezas giran respecto a su relación entre ellas.
- La orientación de dos revestimientos opuestos.
- La separación entre las guarniciones.

2.3.2.1 Desperdicios en el proceso de cardado de alpaca

Durante el proceso de cardado, se generan tres tipos esenciales de desperdicios:

- **Bajo carda:** Se genera principalmente en la zona situada debajo de la rejilla del abridor y, de manera general, debajo de la carda. Este tipo de residuo suele contener muchas impurezas y tiene poco valor para su aprovechamiento.
- **Chapones:** Desperdicio de mejor calidad que, en ciertos casos, puede aprovecharse para mezclar con otras fibras y producir hilados más gruesos.
- **Cintas:** Restos de fibra que quedan cuando se desgarran el velo o las cintas antes de ser plegadas. Estos desperdicios pueden ser reutilizados en el proceso.

Además de los controles comunes, como la **densidad lineal** y la **irregularidad**, en el proceso de cardado de alpaca se realizan los siguientes controles específicos:

- **Contenido de Neps:** Control que permite medir la cantidad de acumulaciones de fibras no deseadas, las cuales afectan la calidad del producto final.
- **Control de Mermas:** Evaluación del porcentaje de fibra perdida durante el proceso de cardado, lo cual es fundamental para garantizar la eficiencia del proceso y minimizar el desperdicio.

2.3.3 Control de calidad en la fibra de alpaca

Según Lockuán Lavado (2012), controlar adecuadamente la calidad a lo largo del cardado resulta esencial para asegurar tanto la uniformidad como la calidad del conjunto de fibras. Un aspecto clave a tener en cuenta es la presencia de neps, que son

acumulaciones de fibras no deseadas que afectan negativamente la calidad del producto final.

Cuando la regulación del proceso no es la adecuada, puede favorecerse la aparición de neps en el velo de cardado; estos también pueden originarse debido al empleo de componentes inadecuados o a velocidades de operación incorrectas. La zona de transferencia entre el abridor y el gran tambor constituye un punto especialmente sensible para la formación de neps.

2.3.3.1 Métodos de control de neps

Existen tres métodos principales para el control de neps mencionados en Lockuán Lavado (2012):

- **Método Shirley:** Se basa en contar las celdas con neps y calcular su proyección en neps por pulgada cuadrada, utilizando una distribución de Poisson.
- **Comparación con Imágenes de Referencia:** Se determina el nivel de nepabilidad del velo utilizando imágenes de referencia, lo cual implica una evaluación subjetiva.
- **Evaluación con el equipo Uster AFIS:** Este método mide el contenido de neps por gramo de cinta y permite monitorear este parámetro a lo largo de todo el proceso de preparación.

Descripción del método Shirley

El método Shirley se desarrolla mediante los siguientes pasos:

1. Insertar la plantilla debajo del velo y elevarla con cuidado para que las fibras se adhieran a su superficie.
2. Posicionar la plantilla de referencia para contar neps sobre la muestra.
3. Retirar cuidadosamente el exceso de velo alrededor del borde de la plantilla.

4. Contabilizar la cantidad de celdas de la plantilla que contienen neps.

El número de neps por 100 pulgadas cuadradas se determina mediante la siguiente fórmula:

$$\text{neps}/100 \text{ pulg}^2 = \frac{1,531 - \log(34 - x)}{0,434} \cdot 100 \quad (2.1)$$

Donde:

- x : Cantidad de celdas que contienen neps.
- 1,531: Logaritmo de 34 (número de celdas de la plantilla).
- 0,434: Valor constante.

Figura 8

Conjunto de fibras a la salida de los cilindros desmenuzadores.



Nota. Adaptado de Lockuán Lavado (2012).

Figura 9

Conjunto de fibras entre las plantillas. Se deben contar las celdas que contienen al menos un nep.



Nota. Adaptado de Lockuán Lavado (2012).

Clasificación del nivel de neps

El resultado final puede clasificarse según el siguiente criterio:

Tabla 2

Clasificación del nivel de neps por 100 pulgadas cuadradas.

Neps por 100 pulg ²	Nivel
1 – 15	Bajo
16 – 30	Promedio
31 – 45	Alto
>46	Muy alto

2.3.3.2 Densidad lineal de los materiales textiles

La densidad lineal constituye un parámetro fundamental dentro del control de calidad aplicado al cardado, dado que permite establecer cómo se relacionan el largo y el peso de la fibra o cinta textil. Aunque este concepto se aplica principalmente al hilo, también resulta útil para estimar la densidad en la cinta cardada, garantizando la uniformidad del material procesado (Lockuán Lavado, 2012).

Definición de densidad lineal

La densidad lineal es una medida numérica que refleja la relación entre el peso y la longitud, o viceversa, de los materiales textiles (Lockuán Lavado, 2012).

Métodos de medición de la densidad lineal

Existen dos sistemas principales para la medición de la densidad lineal:

- **Sistemas Directos:** En este método, denominado *títulos*, la longitud se mantiene constante mientras que el peso varía. La fórmula general es:

$$T = \frac{P}{L} \cdot K \quad (2.2)$$

Donde:

- T : Título de la fibra o cinta.
- P : Masa o peso.
- L : Longitud.
- K : Factor de conversión.

En este sistema, se establece que:

- A menor título del material, menor diámetro (material más delgado).
 - A mayor título del material, mayor diámetro (material más grueso).
- **Sistemas Indirectos (Inversos):** También llamados *títulos*, en este sistema la masa se mantiene constante y la longitud varía. La fórmula general es:

$$N = \frac{L}{P} \cdot K \quad (2.3)$$

Donde:

- N : Cantidad de la fibra o cinta.
- L : Longitud.
- P : Peso.

- K : Constante de conversión.

En este sistema, se establece que:

- A mayor valor del material, menor diámetro (más delgado).
- A menor valor del material, mayor diámetro (más grueso).

Importancia en la cinta cardada

La aplicación de estos sistemas en la cinta cardada de alpaca resulta relevante para garantizar la uniformidad y calidad del material antes del proceso de hilado. El control de la densidad lineal permite identificar variaciones en el grosor y peso de la cinta, lo cual es fundamental para la eficiencia en los procesos posteriores.

2.3.3.3 Norma técnica peruana 231.309:2005 sobre fibra cardada de alpaca

La Norma Técnica Peruana NTP 231.309:2005 (revisada el 2021) establece las definiciones, requisitos, clasificación y rotulado de la fibra cardada de alpaca. Esta norma es importante para garantizar la calidad y estandarización del producto en la industria textil peruana (Instituto Nacional de Calidad, 2021).

Definiciones

De acuerdo con Instituto Nacional de Calidad (2021), las definiciones principales de la fibra cardada de alpaca son las siguientes:

1. **Velo cardado continuo:** Es la fibra de alpaca cardada, obtenida de la máquina carda del sistema de peinado, en forma de velo continuo.
2. **Cinta cardada trozada:** Es la fibra de alpaca cardada en forma de cinta y trozada en pedazos de longitud variable.
3. **Cinta cardada y cortada:** Es la fibra de alpaca cardada en forma de cinta y cortada a máquina en pedazos de longitud regular.

4. **Cinta cardada continua:** Es la fibra de alpaca cardada en forma de cinta continua, sin torsión o con falsa torsión. Se presenta en bobinas o en *bumps*.
5. **Longitud:** El material utilizado para la cinta de alpaca cardada, compuesto por fibras cortas.
6. **Humedad:** Es el contenido de agua, en porcentaje, presente en la cinta cardada, en condiciones normales.
7. **Grasa:** Es el contenido de grasa que puede tener la cinta peinada, incluyendo el ensimaje, lista para su comercialización.
8. **Elementos extraños:** Son contaminantes constituidos por elementos ajenos al hábitat de la alpaca, como fibras de arpillera o yute, provenientes de los envases y otros.

Requisitos para la cinta cardada continua

Los requisitos establecidos en la norma para la cinta cardada continua se presentan en la siguiente tabla:

Tabla 3

Requisitos para la cinta cardada continua según la NTP 231.309:2005.

Requisitos	Baby	Fleece	Medium Fleece	Huarizo	Gruesa	Corta
Finura (μm)	Hasta 23	23.1–26.5	26.6–29.0	29.1–31.5	>31.5	–
Longitud (mm)	60–65	60–65	60–65	60–65	60–65	20–50
Humedad (%)	18.25	18.25	18.25	18.25	18.25	18.25
Grasa con ensimaje (% máx.)	1	1	1	1	1	1

Nota: Esta clase no se deberá usar para cinta cardada continua.

Capítulo 3

Metodología de la investigación

3.1. Tipo y nivel de investigación

La investigación fue de tipo **aplicada y de desarrollo tecnológico**, pues abordó una necesidad concreta del proceso de cardado, apoyar la inspección de pajillas, partículas y variaciones visibles en la distribución de la cinta. Para ello, se desarrolló una solución computacional destinada a complementar la evaluación del personal textil mediante resultados visuales y cuantitativos reproducibles.

La investigación correspondió al **nivel aplicativo**, porque buscó mejorar el control de calidad de la fibra de alpaca durante el cardado mediante una solución tecnológica. Según Supo (2014), este nivel comprende la intervención ante un problema concreto y la evaluación de los resultados obtenidos.

3.2. Enfoque de investigación

El enfoque fue **predominantemente cuantitativo**. La adquisición de imágenes se realizó bajo condiciones definidas; el desempeño de los modelos se expresó mediante precisión, recall, F1, mAP, matrices de confusión y tiempo de inferencia; y la homogeneidad aparente se analizó mediante indicadores numéricos de intensidad, entropía, perfil transversal, textura y variación por bloques. De manera complementaria se utilizó juicio experto cualitativo para revisar la pertinencia de las clases visuales, descartar la clase neps cuando no fue posible reconocerla de forma reproducible y contrastar la interpretación de la homogeneidad. El juicio experto apoyó la interpretación y calibración,

pero no sustituyó las métricas cuantitativas.

3.3. Diseño de investigación

Se adoptó un **diseño tecnológico y comparativo**. El componente tecnológico comprendió la construcción, integración y verificación de una herramienta compuesta por modelos de visión computacional y una aplicación móvil. El componente comparativo permitió contrastar las arquitecturas seleccionadas bajo condiciones equivalentes.

La arquitectura constituyó el elemento de comparación, mientras que las métricas predictivas y de eficiencia computacional fueron las variables de respuesta. Se mantuvieron constantes las clases, las particiones de datos, el protocolo de evaluación y las condiciones de captura y etiquetado. Por tanto, no se realizó un experimento causal, sino una evaluación comparativa de modelos sobre conjuntos de imágenes. El procedimiento se detalla en la sección *Pipeline metodológico de visión computacional*.

3.4. Población y muestra

La **población objetivo** comprendió las muestras de cinta cardada de alpaca susceptibles de inspección durante el cardado. La **población accesible** estuvo conformada por las muestras de fibra blanca recibidas en el CITE Textil Camélidos Cusco durante aproximadamente un año y tres meses y fotografiadas en los entornos de captura disponibles. Por ello, los resultados se limitan a este color de fibra y a condiciones similares a las del estudio.

La **muestra inicial** comprendió 1397 imágenes originales. Tras aplicar los criterios de selección, la **muestra analítica final** quedó conformada por 1105 imágenes: 575 para la detección de impurezas y 530 para el análisis de homogeneidad aparente.

3.5. Unidad de análisis

La unidad de análisis fue una imagen original obtenida de una muestra física diferenciada de cinta cardada. Se registró una sola fotografía por muestra; por tanto, imágenes repetidas de una misma porción de fibra no fueron tratadas como observaciones independientes.

3.6. Justificación de la cantidad de datos

No existe una cantidad mínima de imágenes aplicable a todos los problemas de aprendizaje automático. Beleites et al. (2013) señalan que las curvas de aprendizaje permiten analizar cómo cambia el rendimiento al incrementar las muestras de entrenamiento. También advierten que un conjunto de prueba reducido aumenta la incertidumbre de la evaluación. En el problema de clasificación estudiado por estos autores, se estimaron entre 75 y 100 muestras independientes para evaluar con precisión razonable un clasificador con buen desempeño. Este intervalo es referencial y no constituye una regla para los modelos YOLO ni para la detección de objetos.

En esta investigación se reservaron 111 imágenes originales para la prueba: 58 para la detección de impurezas y 53 para el análisis de homogeneidad. Debido a que corresponden a tareas diferentes, no se consideraron conjuntamente para demostrar la suficiencia de los datos. Por ello, los resultados se interpretaron según el alcance de cada conjunto y no como evidencia de un tamaño óptimo.

Por su parte, Figueroa et al. (2012) proponen estimar la cantidad necesaria de datos mediante curvas de aprendizaje construidas con conjuntos de entrenamiento de tamaño creciente. A partir de estas curvas, se puede proyectar el número de muestras requerido para alcanzar un desempeño determinado. Este procedimiento no se aplicó en la investigación; por tanto, no se afirma haber calculado una cantidad ideal. La muestra final estuvo determinada por las imágenes disponibles que cumplieron los criterios de

selección y por su distribución independiente en entrenamiento, validación y prueba.

Ante la disponibilidad limitada de datos, se emplearon modelos preentrenados, transferencia de aprendizaje y aumento de imágenes. Yosinski et al. (2014) demostraron que inicializar una red con características aprendidas previamente puede mejorar su generalización frente a una inicialización aleatoria. Asimismo, Brigato y Iocchi (2021) identificaron la complejidad del modelo como un factor relevante en escenarios con pocos datos y observaron mejoras mediante técnicas de aumento.

En este estudio, el aumento se aplicó exclusivamente al conjunto de entrenamiento. Las imágenes generadas se consideraron variaciones de las originales y no muestras independientes; por ello, no se contabilizaron dentro de las 1105 imágenes ni se incorporaron a los conjuntos de validación y prueba.

3.7. Metodológico de visión computacional

Como marco de referencia para estructurar el pipeline se adoptó CRISP-ML(Q), un proceso propuesto por Studer et al. (2021) orientado al desarrollo de soluciones de aprendizaje automático bajo criterios de calidad. Dicho marco organiza el trabajo en seis grandes fases —entender el negocio y los datos, prepararlos, construir el modelo, evaluarlo, ponerlo en producción y, finalmente, monitorearlo y mantenerlo—, con el aseguramiento de la calidad presente de forma transversal en todas ellas. Dado que esta descripción es de carácter general, en la presente investigación se desglosó en ocho etapas operativas concretas, pensadas para documentar y hacer reproducible el trabajo experimental realizado con imágenes de fibra de alpaca.

Esta adaptación estableció la siguiente equivalencia entre ambos esquemas: la etapa de *definición del problema visual* correspondió a la comprensión del negocio y de los datos del modelo original; las etapas de *preparación del entorno controlado*, *adquisición de imágenes* y *comprensión y depuración de los datos* cubrieron, en conjunto, la obtención y preparación inicial de los datos; la *definición y validación de clases* junto


con el *etiquetado y división del conjunto* cerraron esa preparación; el *entrenamiento y evaluación de modelos* agrupó las fases de modelado y evaluación; y la *implementación del sistema* representó el despliegue del prototipo desarrollado. A lo largo de la captura, depuración, etiquetado, separación y evaluación de los datos y modelos se mantuvo presente el criterio de calidad. La fase de monitoreo y mantenimiento continuo, en cambio, no formó parte del alcance de la tesis, puesto que la solución no llegó a desplegarse en un entorno productivo real.

Las ocho etapas no constituyen una metodología universal ni fueron establecidas literalmente por Studer et al. (2021); representan una adaptación operativa de CRISP-ML(Q) a las necesidades de esta investigación. La adaptación se complementó con la documentación del *dataset* propuesta por Gebru et al. (2021), los principios de construcción de conjuntos de detección y segmentación de T.-Y. Lin et al. (2014), la evaluación de detectores de Everingham et al. (2010) y la transferencia de aprendizaje estudiada por Yosinski et al. (2014).

La adaptación operativa y la secuencia de sus ocho etapas se resumen en la Figura 10.

Figura 10

Pipeline metodológico de ocho etapas adaptado de CRISP-ML(Q).



3.8. Preparación del entorno controlado

En la preparación del entorno controlado se construyeron y configuraron dos entornos para la adquisición de imágenes del proceso de cardado en la institución CITE Textil Camélidos Cusco. El primer entorno se utilizó para capturar muestras de fibra orientadas a la identificación de impurezas específicas, como pajillas y partículas. El segundo entorno se diseñó para obtener imágenes con un enfoque frontal que permita visualizar la cinta cardada de manera completa. En ambos entornos se controlaron las condiciones de iluminación y ambientales con el fin de asegurar la calidad y consistencia de las imágenes capturadas.

3.8.1 Entorno controlado para detección de impurezas

- a) **Definir el entorno controlado.** Se utilizó un entorno diseñado para la captura de imágenes a corta distancia, con el fin de visualizar impurezas de pequeño tamaño en la fibra cardada. Para ello, se empleó una cabina de iluminación *Maxti MAX 11-CIIC*, que permitió mantener condiciones controladas y repetibles durante la adquisición de las imágenes (ver Figura 11).
- b) **Establecer el sistema de captura.** El sistema de captura se configuró mediante un dispositivo móvil montado sobre un soporte estable, permitiendo ajustar el ángulo de inclinación de la cámara hacia la superficie de la muestra. Esta disposición garantizó un enfoque adecuado y una geometría constante en todas las imágenes adquiridas.
- c) **Configurar la iluminación uniforme.** La cabina *Maxti MAX 11-CIIC* dispone de múltiples fuentes de iluminación, incluyendo lámparas Philips ZS de 40 W y lámparas Philips Lifemax TLD de 18 W en distintas configuraciones espectrales (840, 33-640 y 830), además de una lámpara Sylvania Standard F20T12/D65 y una lámpara Philips TL-D de 18 W BLB. Para el proceso de adquisición de imágenes se utilizó exclusivamente iluminación de luz blanca, con el fin de asegurar una distribución homogénea de la luz y evitar alteraciones cromáticas en la fibra cardada.

Figura 11*Entorno controlado Marti MAX 11-CIIC.*

(a) Entorno sin muestra.



(b) Entorno con muestra.


3.8.2 Entorno controlado para capturar la cinta cardada

- a) **Definir el entorno controlado.** Se construyó un entorno rígido en MDF con dimensiones de 60 cm de ancho por 60 cm de alto, concebido para registrar imágenes de la cinta cardada bajo condiciones controladas. La base se elevó 7.5 cm para permitir el desplazamiento continuo de la cinta. En la parte superior central se incorporó una abertura de 3.5 cm de alto por 5 cm de ancho destinada a ubicar la cámara, mientras que una puerta abatible facilita el acceso a la zona de captura, tal como puede observarse en la Figura 12.
- b) **Establecer el sistema de captura.** Para la captura de imágenes, la cámara se ubicó de manera frontal respecto a la cinta cardada, manteniendo una distancia constante entre el sensor y la superficie de la muestra, con el fin de asegurar una visualización uniforme durante la adquisición de imágenes.
- c) **Configurar la iluminación uniforme.** La iluminación se implementó mediante una cinta LED de 220 V, con luz de tonalidad blanca a una temperatura de color de 6500 K y una eficiencia luminosa cercana a los 66 lm/W. La distribución uniforme de la iluminación permitió obtener imágenes con iluminación homogénea,

minimizando sombras y variaciones de intensidad.

Figura 12

Entorno controlado construido en MDF.



(a) Entorno abierto.



(b) Entorno cerrado.

3.9. Adquisición de imágenes

Dentro del desarrollo de un modelo de inteligencia artificial, la etapa de adquisición de imágenes resulta determinante, pues de la calidad y representatividad de los datos capturados depende en gran medida el desempeño final que alcance el modelo. Para esta investigación, el CITE Textil Camélidos Cusco brindó acceso a su laboratorio, espacio en el que se llevó a cabo la captura de las imágenes de fibra de alpaca a lo largo de las distintas etapas del cardado.

La institución también puso a disposición la máquina cardadora utilizada para generar las muestras, lo que hizo posible observar y registrar cada una de las fases del proceso. Al no encontrarse un *dataset* previamente disponible que documentara este proceso en particular, se optó por construir uno propio, capturando de manera sistemática imágenes de la alimentación de la fibra, el cardado propiamente dicho y la obtención final de la cinta, tal como se ilustra en la Figura 13.

Figura 13

Etapas del proceso de cardado de la fibra de alpaca registradas durante la adquisición de imágenes.



(a) Alimentación inicial de la fibra



(b) Proceso de cardado



(c) Obtención de la cinta cardada

3.9.1 Análisis de impurezas e imperfecciones existentes en la cinta cardada

En la cinta cardada de fibra de alpaca se identifican impurezas que influyen en su calidad, entre las que destacan las *pajillas*, correspondientes a fragmentos vegetales visibles, así como las *partículas*. Las partículas presentan un tamaño reducido y difícilmente distinguible de forma individual.

Asimismo, se consideran los *neps*, definidos como acumulaciones de fibra generadas durante el proceso de cardado, cuya detección visual directa es limitada debido a su reducido tamaño y bajo contraste en imágenes convencionales.

Finalmente, se evalúa la *homogeneidad* de la cinta cardada, entendida como la

distribución uniforme de la fibra, mediante el análisis de la densidad y continuidad visual, con el fin de identificar irregularidades asociadas a defectos del proceso.

3.9.2 Materiales

Para llevar a cabo la adquisición de datos se utilizaron los dos entornos controlados descritos anteriormente. El primer entorno, mostrado en la Figura 11, se empleó para capturar imágenes a corta distancia, con el propósito de identificar impurezas, como pajillas y partículas, y explorar la visualización de la imperfección denominada nep. En este entorno, el dispositivo de captura fue montado sobre un trípode fijo, con el fin de asegurar estabilidad y evitar variaciones en el encuadre entre las distintas tomas.

El segundo entorno, mostrado en la Figura 12, hizo posible obtener una toma frontal de la cinta cardada en su totalidad, lo que facilitó analizar tanto su forma como su homogeneidad.

3.9.2.1 Justificación de la selección de fibra de alpaca blanca

La adquisición experimental se realizó con fibra de alpaca blanca por razones de disponibilidad y viabilidad técnica. Durante el periodo de recolección, esta fue la muestra de cinta cardada disponible en cantidad suficiente en el CITE Textil Camélidos Cusco para efectuar capturas repetidas y construir los conjuntos de entrenamiento, validación y prueba. Las muestras disponibles de otros colores y tonalidades fueron insuficientes para conformar subconjuntos representativos que permitieran entrenar y comparar los modelos de visión computacional bajo condiciones equivalentes.

Además, en las observaciones preliminares realizadas con el entorno de captura empleado, la fibra blanca proporcionó mayor contraste visual para delimitar pajillas y partículas y permitió apreciar con mayor claridad variaciones en la distribución aparente de la cinta asociadas con el análisis de homogeneidad. En muestras oscuras, particularmente en fibra negra, algunas impurezas y variaciones de textura presentaron menor contraste respecto del material de fondo bajo las condiciones de iluminación

y la cámara utilizadas, lo que dificultó su identificación y etiquetado consistente.

Por estas razones, se optó por controlar la variable cromática y establecer una primera línea base experimental con fibra blanca. Esta decisión no implica que el sistema sea directamente generalizable a todos los colores naturales de la fibra de alpaca. La evaluación de fibras negras, marrones, grises y de otras tonalidades requerirá recopilar un número suficiente de muestras por color, ajustar las condiciones de iluminación y contraste y construir *datasets* independientes o balanceados para su entrenamiento y validación.

La adquisición de imágenes y videos se realizó utilizando un dispositivo móvil *Xiaomi 11T*, cuyas principales características técnicas de interés para esta investigación se detallan en la Tabla 4.

Justificación de la selección del dispositivo móvil. Durante la recolección de datos, el CITE Textil Camélidos Cusco no disponía de una cámara dedicada que pudiera asignarse a la investigación. Por esta razón, se utilizó el Xiaomi 11T de propiedad de la investigadora, seleccionado por su disponibilidad y porque su cámara permitía obtener imágenes con la resolución, el enfoque y el nivel de detalle requeridos para las condiciones de captura establecidas. El uso del mismo dispositivo, montado sobre un trípode y bajo iluminación controlada, también permitió mantener constantes el encuadre y las características de adquisición.

La elección de un teléfono móvil respondió, además, al propósito de plantear una solución que no dependiera de una cámara industrial ni de infraestructura especializada para capturar y analizar las imágenes. Esto favorece su posible uso como herramienta de apoyo por especialistas y operarios que dispongan de un dispositivo compatible. Sin embargo, el desempeño fue verificado únicamente con el Xiaomi 11T y bajo las condiciones descritas; por tanto, no se presupone el mismo resultado en cualquier teléfono. El uso en otros modelos, especialmente en equipos con cámaras o capacidad de procesamiento inferiores, requiere comprobar previamente la calidad de captura, el tiempo de inferencia y la estabilidad de la aplicación.

Figura 14

Dispositivo móvil Xiaomi 11T utilizado.

**Tabla 4**

Características técnicas de la cámara y grabación de video del dispositivo Xiaomi 11T

Característica	Especificación
Cámara trasera principal	108 megapíxeles, apertura f/1.75
Cámara ultra gran angular	8 megapíxeles, apertura f/2.2, ángulo de visión de 120°
Cámara telemacro	5 megapíxeles, apertura f/2.4, enfoque entre 3 y 7 cm
Resolución máxima de video	4K
Frecuencia de grabación	Hasta 60 FPS

3.9.3 Captura de imágenes

Las imágenes utilizadas en esta investigación corresponden a fotografías estáticas adquiridas bajo condiciones controladas de iluminación constante, empleando los entornos de captura descritos previamente. Todas las imágenes se guardaron bajo formato JPG, con una resolución de 3840×2160 píxeles, lo que permitió preservar el detalle visual necesario para el análisis de impurezas e imperfecciones en la fibra cardada de alpaca.

La adquisición se desarrolló contemplando diferentes escenarios de captura, en los cuales se varió el encuadre, la distancia entre la cámara y la muestra, así como el nivel de zoom, con el objetivo de representar de manera adecuada las impurezas e

imperfecciones presentes en la cinta cardada.

En particular, el primer entorno de captura se utilizó para la adquisición de imágenes a corta distancia, orientadas a la identificación de impurezas locales tales como pajillas y partículas. En este entorno, el dispositivo de captura fue montado sobre un trípode fijo, garantizando estabilidad y consistencia en el encuadre de las imágenes, según puede apreciarse en la Figura 15.

Figura 15

Entorno de captura para la identificación de impurezas en la cinta cardada.



Por otro lado, el segundo entorno permitió obtener una vista frontal completa de la cinta cardada, conservando una separación de alrededor de 60 cm entre la cámara y la muestra. Esta configuración facilitó el análisis global de la homogeneidad de la fibra a lo largo de la cinta, según se observa en la Figura 16.

Figura 16

Entorno de captura para el análisis de la homogeneidad de la cinta cardada.



Finalizada la etapa de adquisición, las imágenes obtenidas fueron organizadas en una estructura jerárquica de carpetas con el fin de facilitar su manejo, trazabilidad y posterior análisis. Dicha organización se llevó a cabo tomando en cuenta el tipo de captura y el escenario de adquisición correspondiente, lo cual permitió un manejo ordenado y sistemático de los datos a lo largo de las fases posteriores de la investigación.

Tal como puede verse en la Figura 17, el conjunto de imágenes se organiza a partir de una carpeta raíz que agrupa las principales categorías del proceso de adquisición. A partir de esta estructura general, se definieron carpetas de segundo nivel que permiten clasificar las imágenes según condiciones experimentales, tales como el tipo de cinta cardada, el fondo utilizado, la presencia de impurezas, la homogeneidad de la fibra y la fecha de adquisición.

En la Figura 18 se exhibe la organización general por clases, en la cual pueden identificarse las categorías principales que componen el *dataset*. A su vez, cada una de

estas carpetas alberga subdirectorios mediante los cuales se logra una organización más precisa de la información.

En particular, la Figura 19 muestra cómo se distribuyen internamente las muestras vinculadas a este análisis, considerando además su organización en el tiempo. Por otro lado, la estructura exploratoria de las imágenes orientadas al análisis de neps puede verse en la Figura 20.

Finalmente, la Figura 21 ilustra la organización específica de los subdirectorios que contienen muestras de cinta cardada con pajillas y partículas, evidenciando la relación jerárquica entre carpetas principales y sus contenidos internos. Esta estructura organizada facilitó los procesos de preprocesamiento, etiquetado y entrenamiento del modelo de visión computacional.

Figura 17

Arquitectura jerárquica del dataset principal.






Figura 18

Organización general de directorios por clase.

**Figura 19**

Distribución por fechas y organización interna de las muestras de cinta cardada (homogeneidad).


**Figura 20**

Estructura detallada del dataset correspondiente a la clase neps.



Figura 21

Detalle de la organización interna del dataset de pajillas y partículas, incluyendo la relación entre directorios principales y subdirectorios.



3.10. Preparación del *dataset*

3.10.1 *Preprocesamiento de datos*

Durante esta fase se llevó a cabo un examen exploratorio del conjunto de imágenes recopiladas, con el propósito de evaluar su estructura, calidad y nivel de representatividad respecto al estudio realizado. Dada la heterogeneidad existente en las configuraciones de adquisición y en los propósitos analíticos planteados, en la Tabla 5 se establecieron tres categorías funcionales: **Clase A** (pajillas y partículas), **Clase B** (homogeneidad) y **Clase C** (neps). Con base en esta categorización, la Tabla 6 presenta cómo se distribuyen las imágenes considerando el tipo de captura empleado, la cantidad disponible, la configuración utilizada y la clase correspondiente.

De este examen se desprende que el conjunto de imágenes fue recopilado bajo condiciones de captura distintas entre sí, lo cual genera diferencias notables en aspectos como el encuadre, la iluminación y la escala de las tomas. Dicha diversidad se abordó de manera particular según el propósito de cada análisis, diferenciando entre las imágenes orientadas a detectar impurezas visibles (pajillas y partículas), las destinadas al estudio de neps y aquellas empleadas para valorar la homogeneidad de la cinta cardada.

De igual manera, la organización del *dataset* no respondió a una distribución independiente para cada categoría de análisis, sino que fue estructurada considerando el tipo de análisis a ejecutar. Esta forma de organización permitió disponer las imágenes

conforme a los objetivos particulares planteados en la investigación, constituyendo así la base para las fases siguientes correspondientes a la preparación de los datos y al entrenamiento del modelo.

Tabla 5

Definición de clases analíticas del dataset

Clase	Categoría principal	Objetivo de análisis
A	Pajillas y partículas	Detección de impurezas superficiales visibles en la fibra
B	Homogeneidad	Evaluación de uniformidad, densidad y distribución espacial del vellón cardado
C	Neps	Análisis exploratorio de acumulaciones internas mediante iluminación a contraluz

Tabla 6

Resumen del conjunto de imágenes adquiridas

Clase	Tipo de imagen		Cantidad	Configuración de captura	Justificación técnica
A	Cinta cardada con impurezas		575	Zoom 3×	Se priorizó el acercamiento para capturar con mayor detalle visual impurezas superficiales como pajillas y partículas, facilitando su identificación precisa.
B	Homogeneidad	fondo verde claro	176	Altura 60 cm, zoom 2×	La distancia permitió observar una mayor extensión de la cinta cardada, favoreciendo el análisis global de uniformidad y distribución espacial.
A	Cinta cardada blanco (Adquisición manual)		63	Zoom 1×	Configuración exploratoria inicial utilizada para registrar defectos visibles bajo condiciones manuales básicas.
C	Cinta cardada a contraluz		53	Iluminación a contraluz	La iluminación posterior buscó resaltar estructuras internas y posibles acumulaciones asociadas a neps no visibles en captura convencional.
B	Homogeneidad	fondo plomo	530	Zoom 3×	El mayor acercamiento y contraste del fondo permitieron evaluar con mayor precisión textura, densidad y distribución de la fibra.
Total	–		1397	–	–

Tras el análisis del conjunto de 1397 imágenes capturadas, se seleccionaron los subconjuntos con mayor relevancia técnica y consistencia visual. Para el conjunto analítico final se utilizaron exclusivamente las categorías *Cinta cardada con impurezas* y *Homogeneidad fondo plomo*. Las 53 imágenes de *Cinta cardada a contraluz* se conservaron únicamente como material exploratorio para estudiar la posible visualización de neps, pero fueron excluidas del entrenamiento y de la evaluación final porque no permitieron definir un criterio de etiquetado visual claro y reproducible.

Esta selección se fundamenta en que dichos entornos proporcionan condiciones de iluminación y contraste adecuadas para la identificación precisa de impurezas y la evaluación de las imperfecciones asociadas con neps y falta de homogeneidad.

Con el fin de garantizar la consistencia dimensional del *dataset* y facilitar su procesamiento en las etapas posteriores, las imágenes correspondientes a las categorías *Cinta cardada con impurezas* y *Cinta cardada a contraluz* fueron redimensionadas a una resolución uniforme de 900×600 píxeles. Este proceso permitió estandarizar la escala espacial de las imágenes, reducir la variabilidad asociada a las diferentes configuraciones de captura y optimizar el rendimiento computacional durante el entrenamiento del modelo.

Por otro lado, las imágenes del conjunto *Homogeneidad fondo plomo* se mantuvieron en su resolución original de 3840×2160 píxeles. Esta decisión se tomó con el objetivo de preservar el nivel de detalle espacial de la fibra para segmentar la cinta y analizar con mayor precisión la distribución del material en la evaluación de homogeneidad.

3.10.2 Selección y depuración del dataset

La recolección de muestras tomó alrededor de un año y tres meses, un plazo bastante condicionado por cómo llegaba la fibra desde la planta: en pequeñas cantidades, en momentos irregulares y sin un flujo constante. Eso hizo que muchas de las capturas iniciales correspondieran a porciones pequeñas de lotes distintos, con diferencias visibles en color, textura, densidad y composición que simplemente reflejaban la variabilidad

natural del material.

Mezclar todos esos subconjuntos en un único *dataset* de entrenamiento no resultaba metodológicamente adecuado. Incluir grupos con pocas muestras o provenientes de fibras muy distintas entre sí habría introducido sesgos no relacionados con las impurezas que se buscaba detectar, sino con diferencias propias de la materia prima. Por ello, se optó por conservar los subconjuntos más voluminosos, visualmente consistentes y con mejores condiciones de captura, trabajando finalmente con dos grupos: cinta cardada con impurezas A, conformado por 575 imágenes, y homogeneidad con fondo plomo B, conformado por 530 imágenes. Ambos reunían las condiciones técnicas necesarias para sostener un entrenamiento confiable.

Un caso aparte fue la Clase C, correspondiente a neps. En un principio se contempló analizarla mediante imágenes a contraluz, pero terminó descartándose. Aunque se ajustaron las condiciones de iluminación para intentar resaltar posibles acumulaciones internas, ni las imágenes obtenidas ni la evaluación de expertos permitieron distinguir los neps de otras variaciones naturales de la fibra con suficiente confianza. No se encontró un criterio visual claro y reproducible para identificarlos, lo que habría comprometido tanto el etiquetado como la calidad del aprendizaje.

En definitiva, la depuración no fue únicamente una cuestión de reducir la cantidad de imágenes, sino de cuidar la coherencia del conjunto: un *dataset* más pequeño, pero bien construido, aporta más que uno grande con alto nivel de ruido.

3.10.3 Definición de clases

En la presente investigación se definieron como parámetros de calidad clave en la cinta cardada la presencia de pajillas, partículas, neps y la homogeneidad de la fibra, debido a su influencia directa en la calidad del producto final y en los procesos de control textil.

3.10.3.1 Pajillas y partículas

Las pajillas corresponden a impurezas visibles de mayor tamaño presentes en la cinta cardada, generalmente asociadas a restos vegetales. Durante el análisis de las muestras adquiridas, también se identificó la presencia de partículas de menor tamaño, diferenciadas principalmente por su dimensión y forma. Debido a estas diferencias y a su recurrencia en las muestras, las partículas fueron consideradas como una clase independiente dentro del proceso de etiquetado. En la Figura 22 se presenta la muestra de manera general.

Figura 22

Fotografía de una muestra que contiene partículas y pajillas.



3.10.3.2 Neps


Los neps corresponden a pequeñas aglomeraciones de fibras que se forman en el proceso de cardado, caracterizadas por una estructura compacta y enredada que afecta la uniformidad del material textil. Estas formaciones se generan principalmente por la interacción mecánica entre fibras inmaduras, cortas o dañadas durante el procesamiento.

En la Figura 23 se presenta una imagen de referencia que ilustra la morfología característica de un nep, utilizada únicamente con fines descriptivos para la identificación visual de este tipo de imperfección, de acuerdo con lo reportado en la literatura

especializada (Nath et al., 2015).

Figura 23

Morfología característica de un nep en algodón.



Nota. Tomado de Nath et al. (2015).

3.10.3.3 Homogeneidad

La homogeneidad de la cinta cardada se define como la correcta y uniforme distribución de la fibra a lo largo de toda su extensión, manteniendo una densidad y espesor constantes en cada punto. A diferencia de las impurezas puntuales y de los neps, esta característica se evalúa de forma global, considerando la regularidad visual del material y la ausencia de zonas con acumulación o déficit de fibra.

En la Figura 24 se muestra un ejemplo representativo de una cinta cardada con una distribución homogénea de la fibra, utilizada como referencia durante el proceso de etiquetado.

Figura 24

Ejemplo de cinta cardada con distribución homogénea de la fibra.



3.10.3.4 Validación de clases mediante juicio de experta

La definición de las clases empleadas en el proceso de etiquetado fue validada mediante el juicio de una experta de la institución CITE Textil Camélidos Cusco, con el propósito de garantizar la coherencia técnica, la correcta interpretación visual de las impurezas e imperfecciones y la viabilidad de su identificación a partir de imágenes digitales. Dicha validación estuvo a cargo de la Ing. Lita Esther Castillo Yepes, especialista en procesos textiles y control de calidad de fibra, con amplia experiencia en la inspección de cinta cardada de alpaca.

Durante este proceso se analizaron las clases inicialmente propuestas pajillas, partículas, neps y homogeneidad considerando tanto los criterios técnicos establecidos en la literatura especializada como las limitaciones inherentes al análisis basado en visión computacional.

En el caso de las pajillas y las partículas, la experta confirmó que ambas corresponden a impurezas claramente distinguibles mediante inspección visual, diferenciándose principalmente por su tamaño, forma y frecuencia de aparición. Estas características permiten su identificación directa en imágenes digitales, lo que justifica su consideración como clases independientes dentro del proceso de etiquetado.

Por el contrario, en relación con los neps, se determinó que su evaluación cuantitativa no resulta viable a partir de las imágenes adquiridas. De acuerdo con lo reportado en la literatura (Lockuán Lavado, 2012), el control de neps se realiza mediante métodos manuales o instrumentales, tales como el método Shirley, la comparación con imágenes patrón o el uso de equipos especializados como el Uster AFIS. Dichos procedimientos requieren la manipulación física del velo o mediciones directas por unidad de masa, condiciones que no pueden ser replicadas mediante imágenes bidimensionales.

Asimismo, la experta indicó que la identificación visual de neps es altamente dependiente de las condiciones de iluminación. En el conjunto de imágenes analizado, los neps no lograron distinguirse de forma confiable, incluso al emplear iluminación a contraluz, como se muestra en la Figura 25. Esta limitación impidió su identificación consistente y, en consecuencia, su inclusión como clase dentro del proceso de etiquetado.

Figura 25

Visualización de la cinta cardada mediante iluminación a contraluz bajo distintas condiciones de densidad de fibra.



(a) Cinta cardada con mayor densidad de fibra.



(b) Cinta cardada con menor densidad de fibra.

En cuanto a la homogeneidad, la experta validó su consideración como atributo global de calidad de la cinta cardada. Esta característica se relaciona con la regularidad en la densidad, el grosor y la distribución de la fibra a lo largo de la cinta, aspectos fundamentales para garantizar la calidad del material previo a los procesos posteriores de hilado, tal como lo señalan Lockuán Lavado (2012) y la Norma Técnica Peruana NTP 231.309:2005.

La experta también participó en la evaluación física de las muestras y en la revisión

de los resultados generados por el sistema. El procedimiento empleado se describe en la sección de calibración de umbrales.

A partir de la referencia física y del criterio de la experta, se definió una estrategia de evaluación visual computacional multicriterio basada en indicadores cuantitativos extraídos de las imágenes. En este contexto, la homogeneidad se relacionó con la uniformidad de la intensidad luminosa, el perfil transversal, la textura y la variación espacial dentro de la región correspondiente al velo cardado. Una cinta correctamente procesada presenta una distribución relativamente uniforme de densidad y textura, características que pueden reflejarse en los valores de intensidad y en los patrones espaciales de la imagen. Estos criterios permitieron establecer umbrales operativos para generar el diagnóstico de homogeneidad en la aplicación móvil. Las mediciones físicas se utilizaron como referencia complementaria y no constituyeron variables de entrada del diagnóstico automático.

En consecuencia, la homogeneidad no se trató como una clase entrenada directamente por YOLO, sino como un atributo calculado después de segmentar la cinta cardada. Para ello, se etiquetó y entrenó la clase *Cinta*, y sobre la región segmentada se calcularon los indicadores empleados para generar el diagnóstico de homogeneidad.

Finalmente, para la detección de impurezas se definieron las clases *pajilla* y *partícula*; para la segmentación se definió la clase *Cinta*. La homogeneidad se evaluó posteriormente mediante indicadores visuales calculados sobre la región segmentada. La clase *nep* fue descartada del entrenamiento debido a las limitaciones técnicas para su identificación y etiquetado confiable mediante las imágenes adquiridas.

3.10.4 Etiquetado y segmentación de datos

3.10.4.1 Primera etapa: etiquetado de pajillas y partículas


En esta primera etapa se llevó a cabo el procedimiento de preparación y etiquetado manual de las imágenes correspondientes a la cinta cardada, con la finalidad de generar un *dataset* apropiado para entrenar un modelo de detección de objetos basado en redes

neuronales convolucionales. A continuación se describe el proceso seguido:

1. **Carga de las imágenes.** Se cargaron las imágenes originales desde sus respectivos directorios, organizados según las categorías definidas dentro del *dataset*, dando prioridad a aquellas correspondientes a la categoría *Cinta cardada con impurezas*, las cuales sirvieron como insumo principal para la identificación de impurezas presentes en la fibra.
2. **Redimensionamiento de las imágenes.** El conjunto completo de imágenes fue ajustado a una resolución uniforme de 900×600 píxeles, empleando para ello la librería *Pillow (PIL)* de Python a través de la función *resize*. Mediante este procedimiento se logró homogeneizar las dimensiones de las imágenes, lo que facilitó las etapas posteriores de procesamiento y etiquetado.
3. **Creación del proyecto en la plataforma Roboflow.** Las imágenes previamente redimensionadas fueron cargadas en la plataforma *Roboflow*, donde se crearon proyectos configurados para la tarea de *Object Detection*. Durante esta etapa se definieron el nombre del proyecto, tal como se muestra en la Figura 26.

Figura 26

Creación y configuración del primer proyecto.



4. **Definición de clases.** Se establecieron dos clases para el proceso de etiquetado:

- *Pajilla*
- *Partícula*

5. **Carga del *dataset*.** Se cargaron el subconjunto de imágenes en el proyecto de cinta cardada con impurezas, en las cuales se etiquetaron las clases *pajilla* y *partícula*.
6. **Etiquetado manual mediante Bounding Boxes.** El etiquetado de las imágenes se efectuó de forma manual en la plataforma *Roboflow*, mediante el uso de cajas delimitadoras (*Bounding Boxes*), con las cuales se determinó la ubicación de los objetos presentes y se les asignó la clase correspondiente. En la Figura 27 se muestran ejemplos representativos de este etiquetado, empleado posteriormente en la generación del *dataset* de entrenamiento.

Figura 27

Etiquetado manual mediante Bounding Boxes para las clases pajilla y partícula.




Figura 28

Muestras ampliadas de las clases: partícula y pajillas.



3.10.4.2 Segunda etapa: segmentación de la cinta cardada


En esta segunda etapa se llevó a cabo la preparación y el etiquetado de imágenes enfocado en la *segmentación por instancias* de la cinta cardada, con la finalidad de evaluar la homogeneidad presente en la cinta. A continuación se describe el procedimiento empleado:

1. **Selección del conjunto de imágenes.** Se seleccionó un subconjunto específico de imágenes de cinta cardada que permitía observar con claridad la forma, continuidad y distribución del vellón, características fundamentales para el análisis de la homogeneidad de la fibra.
2. **Redimensionamiento de las imágenes.** Las imágenes correspondientes al *dataset* de homogeneidad con fondo verde fueron redimensionadas a una resolución uniforme de 900×600 píxeles utilizando la librería *Pillow (PIL)* en Python. Por otro lado, el *dataset* de homogeneidad con fondo plomo se mantuvo en su resolución original de 3840×2160 píxeles con el fin de preservar el nivel de detalle necesario para el análisis de la homogeneidad de la fibra.
3. **Creación del proyecto en la plataforma Roboflow.** Las imágenes preprocesadas fueron cargadas en la plataforma *Roboflow*, donde se creó un proyecto configurado

para la tarea de *Instance Segmentation*. En esta etapa se definieron los parámetros generales del proyecto y el tipo de anotación requerido para el etiquetado de las imágenes (Figura 29).

Figura 29

Creación y configuración inicial del proyecto en Roboflow para la tarea de Instance Segmentation.



(a) Creación del proyecto en la plataforma Roboflow.

(b) Configuración del proyecto para la tarea de *Instance Segmentation*.


4. **Definición de la clase de interés.** Para esta etapa se definió una única clase de segmentación es la cinta cardada”
5. **Etiquetado manual mediante máscaras de segmentación.** Este etiquetado se llevó a cabo de manera manual en la plataforma *Roboflow*, empleando máscaras de segmentación que permitieron delimitar con precisión las regiones correspondientes a la cinta cardada. En la Figura 30 se presentan ejemplos del proceso de etiquetado realizado.

Figura 30

Proceso de segmentación manual y resultado final del etiquetado mediante máscaras aplicado a la cinta cardada.



(a) Ejemplo de segmentación manual aplicada a la cinta cardada.



(b) Resultado del proceso de etiquetado mediante máscaras de segmentación.

3.10.5 División del dataset

El proceso empleado para llevar a cabo la división del *dataset* se describe a continuación:

1. Obtención del conjunto de imágenes, previamente organizado y etiquetado, a partir de la plataforma Roboflow.
2. Desarrollo de un algoritmo automatizado destinado a generar la estructura de directorios correspondiente a los subconjuntos **train**, **validation** y **test**.
3. Asignación aleatoria y controlada de las imágenes hacia cada subconjunto, manteniendo la proporción definida de 70 % para entrenamiento, 20 % para validación y 10 % para prueba.
4. Comprobación de que los diferentes escenarios de captura y configuraciones de adquisición estuvieran representados en cada subconjunto, evitando así que un mismo tipo de imagen se concentrara en un solo grupo y disminuyendo el riesgo de sobreajuste.

Cada imagen correspondió a una muestra física diferente de cinta cardada y se registró una sola fotografía por muestra. Por ello, no existieron imágenes repetidas ni múltiples

capturas de una misma muestra distribuidas entre los subconjuntos de entrenamiento, validación y prueba.

En la Tabla 7 se detalla la distribución final de las imágenes para cada categoría contemplada en el estudio, especificando el número total de imágenes y su distribución correspondiente entre los conjuntos de entrenamiento, validación y prueba. Esta estrategia permitió contar con un *dataset* coherente y con representación de las dos categorías de análisis, que sirvió de base para las fases posteriores de entrenamiento, validación y evaluación del modelo propuesto.

Tabla 7

División del dataset en entrenamiento, validación y prueba

Tipo de imagen	Total	Entrenamiento	Validación	Prueba
Cinta cardada con impurezas	575	402	115	58
Homogeneidad fondo plomo	530	371	106	53
Total de imágenes	1105	773	221	111

3.10.6 Métricas y criterios de evaluación

La evaluación se definió de acuerdo con la tarea de visión computacional y se efectuó con datos no utilizados para ajustar los parámetros del modelo. Para la detección de pajillas y partículas, los modelos se compararon sobre el mismo conjunto independiente de prueba mediante las siguientes métricas, utilizadas habitualmente en la evaluación de detectores (Everingham et al., 2010; T.-Y. Lin et al., 2014):

En las expresiones siguientes, TP representa una detección correcta; FP , una detección informada por el modelo que no corresponde a una instancia real; y FN , una instancia real que el modelo no detectó. Una predicción se consideró concordante con una anotación cuando alcanzó el umbral de intersección sobre unión (IoU) definido para la evaluación.

- **Precisión (P):** proporción de detecciones positivas que correspondieron a una impureza real, $P = TP/(TP + FP)$. Una precisión alta implica menor presencia de falsas alarmas.

- **Recall o sensibilidad (R):** proporción de impurezas reales que fueron detectadas, $R = TP/(TP+FN)$. Un recall alto implica menor omisión de pajillas o partículas.
- **Puntaje F1:** media armónica entre precisión y recall, $F1 = 2PR/(P + R)$, empleada para valorar el equilibrio entre falsas alarmas y omisiones.
- **mAP@0.5:** para cada clase, la precisión media (AP) resume el área bajo la curva precisión–recall. El mAP promedia los valores AP de pajilla y partícula utilizando un umbral $IoU = 0,50$; mide simultáneamente capacidad de detección y localización con una tolerancia moderada.
- **mAP@0.5:0.95:** promedio de los valores mAP calculados para umbrales de IoU desde 0.50 hasta 0.95 en incrementos de 0.05. Al incluir umbrales más estrictos, penaliza cajas o máscaras cuyos límites se alejan de la anotación de referencia.
- **Matriz de confusión y tiempo de inferencia:** se emplearon para examinar aciertos, confusiones con el fondo, falsos positivos, falsos negativos y viabilidad computacional en milisegundos por imagen.

Para la segmentación de la cinta cardada se emplearon precisión, recall, mAP de cajas y mAP de máscaras, además de la matriz de confusión y el tiempo de inferencia. Estas métricas se reportaron sobre el conjunto de validación empleado para comparar las arquitecturas; las 53 imágenes de prueba permanecieron reservadas para verificaciones posteriores del sistema, por lo que no se presentan como una evaluación final independiente de segmentación.

La homogeneidad aparente no se expresó como cumplimiento de una especificación física, sino mediante indicadores computacionales complementarios calculados dentro de la máscara de la cinta: coeficiente de variación de intensidad, entropía local, variación del perfil transversal, propiedades de textura de la matriz de coocurrencia de niveles de gris y variación por bloques. La decisión final se obtuvo mediante una regla de integración por votación calibrada empíricamente y revisada con criterio experto.

Las pruebas funcionales de la aplicación verificaron, además, la captura o selección de imágenes, inferencia local, presentación y registro de resultados y exportación de información.

3.10.7 Relación con la NTP 231.309:2005 (revisada el 2021)

La norma técnica identificada oficialmente para este estudio es la **NTP 231.309:2005 (revisada el 2021)**, denominada *Fibra cardada de alpaca. Definiciones, requisitos, clasificación y rotulado*; no corresponde denominarla NTP 231.309:2025 (Instituto Nacional de Calidad, 2021). En la investigación se consideraron sus definiciones de las presentaciones de fibra cardada y su marco de requisitos y clasificación como referencia para contextualizar el control de calidad de la cinta cardada.

El alcance del sistema, sin embargo, se limita al análisis por visión computacional de características observables en imágenes: presencia y localización de pajillas y partículas, segmentación de la cinta y estimación de su homogeneidad aparente. La investigación no ejecutó todos los procedimientos físicos, químicos o instrumentales asociados con la determinación de propiedades textiles, tales como humedad, grasa, longitud, densidad lineal u otros ensayos normalizados; tampoco evaluó los requisitos de rotulado.

En consecuencia, los resultados no constituyen una certificación, declaración de conformidad ni demostración de cumplimiento integral de la NTP. El sistema se plantea como una herramienta complementaria de preinspección visual que puede ayudar a identificar irregularidades visibles y priorizar muestras para su evaluación convencional. Una validación normativa futura deberá correlacionar sus resultados con mediciones instrumentales realizadas mediante los métodos de ensayo aplicables y bajo un protocolo de muestreo definido por especialistas textiles.

La relación metodológica entre la norma y el sistema se resume en la Tabla 8.

Tabla 8*Relación entre la NTP 231.309:2005 (revisada el 2021) y el alcance del sistema.*

Aspecto de referencia	Forma en que se consideró	Límite de la investigación
Definiciones y presentación de fibra cardada	Permitieron contextualizar el material observado y el proceso de control de calidad.	El sistema no determina por sí solo la clasificación comercial o normativa del producto.
Elementos extraños e irregularidades visibles	Se relacionaron con la detección visual de pajillas y partículas y con el análisis de distribución aparente de la cinta.	Una detección en imagen no equivale a un resultado obtenido mediante un método de ensayo normativo.
Requisitos físicos o instrumentales	Se reconocieron como parte del control convencional con el cual la visión computacional podría complementarse.	No se determinaron normativamente humedad, grasa, longitud, densidad lineal ni otras propiedades instrumentales.
Clasificación y rotulado	Se utilizaron únicamente como contexto documental de la norma.	No fueron evaluados por la aplicación y no se emite declaración de conformidad.

3.11. Extracción de características

La extracción de características es una etapa fundamental en los sistemas de visión por computador, ya que permite representar la información visual de las imágenes mediante descriptores que capturan patrones espaciales, texturas y formas relevantes para la identificación de objetos. En el análisis de materiales textiles, estas características permiten reconocer impurezas, como pajillas y partículas, e imperfecciones, como neps y variaciones de homogeneidad en la estructura de la cinta cardada.

En esta investigación se empleó la técnica de *transfer learning*, que permite reutilizar los pesos de modelos previamente entrenados y adaptarlos a un problema específico con un *dataset* más reducido. Este enfoque facilita el aprovechamiento de representaciones visuales previamente aprendidas en tareas de visión por computador (Iman et al., 2023).

Para el desarrollo del sistema se utilizaron modelos de la familia YOLO, los cuales permiten realizar la detección de objetos y la extracción de características dentro de una misma arquitectura de red neuronal (Redmon et al., 2016). En particular, se emplearon los modelos *YOLOv8*, *YOLOv11* y *YOLO26*, versiones recientes que incorporan mejoras en eficiencia y precisión (Sapkota & Karkee, 2025; Terven et al., 2023).


Para la tarea de *segmentación por instancias* del vellón cardado se utilizaron los modelos *YOLOv8n-seg*, *YOLO11n-seg* y *YOLO26n-seg*, los cuales permiten delimitar regiones específicas mediante máscaras de segmentación. El uso de modelos preentrenados permitió adaptar las representaciones aprendidas al dominio de la fibra textil, facilitando la delimitación de la cinta y el posterior análisis de la imperfección asociada con la falta de homogeneidad.

3.11.1 Descripción de los modelos

La familia YOLO ha evolucionado progresivamente desde detectores de objetos orientados a velocidad hacia un framework de visión computacional capaz de abordar múltiples tareas como detección, segmentación por instancias, clasificación y estimación de pose. Las versiones recientes desarrolladas por Ultralytics han ampliado estas capacidades, manteniendo el enfoque en inferencia en tiempo real y eficiencia computacional. Como se observa en la Figura 31, esta evolución no solo refleja mejoras arquitectónicas entre versiones, sino también una expansión funcional hacia problemas más complejos de visión computacional (Sapkota & Karkee, 2025).

Figura 31

Evolución de los modelos YOLO mantenidos por Ultralytics, mostrando la progresión desde YOLOv5 hasta YOLO26 y la expansión de capacidades hacia múltiples tareas de visión computacional.



Nota. Adaptado de Sapkota & Karkee (2025).

En esta investigación se emplearon tres modelos de la familia YOLO en sus variantes de segmentación por instancias y detección de objetos: *YOLOv8*, *YOLOv11* y *YOLO26*. Todos comparten la arquitectura general de *backbone*, *neck* y *head* descrita anteriormente, pero incorporan innovaciones específicas que determinaron su selección para las tareas de control de calidad de la fibra de alpaca.

Cada arquitectura dispone de variantes de diferente escala, identificadas mediante las letras *n* (*nano*), *s* (*small*) y *l* (*large*). Estas variantes conservan los principios arquitectónicos de su respectiva versión, pero modifican la profundidad y el ancho de la red, la cantidad de parámetros y el costo computacional; en general, las configuraciones más grandes priorizan capacidad representativa, mientras que las compactas priorizan velocidad y facilidad de despliegue (Sapkota & Karkee, 2025). El sufijo *-seg* identifica las configuraciones que incorporan una salida para generar máscaras de segmentación

por instancias.


En este trabajo, la salida de segmentación se utilizó exclusivamente para separar la cinta cardada del fondo. La máscara resultante definió la región de interés sobre la cual se calcularon posteriormente los indicadores de intensidad, entropía local, perfil transversal, textura GLCM y variación por bloques. Por consiguiente, los modelos *-seg* no midieron directamente la homogeneidad ni constituyeron un objetivo independiente, sino que actuaron como una etapa auxiliar para delimitar el material analizado.

3.11.1.1 Modelo YOLOv8

YOLOv8, desarrollado por Ultralytics en 2023, introduce un backbone basado en el módulo C2f (*Cross Stage Partial with more gradient flow*), que reduce la redundancia computacional y mejora la reutilización de gradientes respecto a versiones anteriores (Yaseen, 2024). El neck emplea una versión mejorada de PANet (*Path Aggregation Network*) que optimiza el flujo de información multiescala desde el backbone hacia la cabeza de detección. El head adopta un diseño desacoplado (*decoupled head*) de tipo *anchor-free*, lo que elimina la dependencia de cajas ancla predefinidas y favorece la adaptación a objetos con distintas proporciones y escalas (Terven et al., 2023). Para la regresión de las cajas utiliza pérdidas basadas en CIoU y *Distribution Focal Loss* (DFL), mientras que el diseño desacoplado separa las salidas asociadas con clasificación y localización (Sapkota & Karkee, 2025). Como se muestra en la Figura 32, esta versión combina extracción jerárquica, fusión multiescala y predicción sin anclas.

Figura 32

Estructura del modelo YOLOv8, compuesta por el backbone basado en bloques C2f, el neck PANet y el head desacoplado anchor-free.




segmentación de una sola clase sobre fondo controlado (Yaseen, 2024).

3.11.1.2 Modelo YOLOv11

YOLOv11, presentado en la conferencia YOLO Vision 2024, extiende la arquitectura de YOLOv8 mediante el bloque C3k2 (*Cross Stage Partial with kernel size 2*), conserva el módulo SPPF (*Spatial Pyramid Pooling - Fast*) para la agregación multiescala e incorpora el bloque C2PSA (*Cross Stage Partial with Spatial Attention*) después de este (Khanam & Hussain, 2024). El bloque C3k2 reemplaza al C2f empleando dos convoluciones más pequeñas en lugar de una grande, lo que reduce la carga computacional manteniendo el rendimiento. El módulo C2PSA, incorporado tras el SPPF, introduce un mecanismo de atención espacial que permite al modelo concentrarse en regiones críticas de la imagen, mejorando la detección de objetos de distintos tamaños y posiciones (Khanam & Hussain, 2024). Como resultado, la variante YOLOv11m logra una precisión media (mAP) superior a su equivalente YOLOv8m utilizando un 22 % menos de parámetros (Khanam & Hussain, 2024).

Figura 33

Módulos arquitectónicos clave de YOLOv11: bloques C3k2 para extracción eficiente de características, SPPF para agregación multi-escala y C2PSA para atención espacial.



Nota. Adaptado de Khanam & Hussain (2024).

En este trabajo se emplearon *YOLO11s* para detectar pajillas y partículas y *YOLO11n-seg* para delimitar la cinta cardada. YOLO11 representó el perfil intermedio de la comparación: sus bloques de extracción más eficientes y el mecanismo de atención espacial


permitieron estudiar un equilibrio entre capacidad predictiva y costo computacional (Khanam & Hussain, 2024).

3.11.1.3 Modelo YOLO26

YOLO26, lanzado por Ultralytics en septiembre de 2025 y presentado en el evento YOLO Vision 2025, representa la versión más reciente de la familia YOLO, orientada especialmente a la inferencia eficiente en dispositivos de borde (*edge devices*) (Sapkota et al., 2025). Su arquitectura introduce cuatro innovaciones fundamentales respecto a versiones anteriores. En primer lugar, elimina la *Distribution Focal Loss* (DFL), simplificando la regresión de cajas delimitadoras y mejorando la compatibilidad de exportación hacia plataformas como ONNX, TensorRT y TFLite. En segundo lugar, adopta inferencia extremo a extremo sin *Non-Maximum Suppression* (NMS), lo que elimina el cuello de botella del postprocesamiento y reduce la latencia de inferencia en hasta un 43 % para la variante nano respecto a YOLOv11 (Sapkota et al., 2025). En tercer lugar, incorpora *ProgLoss* (balanceo progresivo de pérdidas) y STAL (*Small-Target-Aware Label Assignment*), que mejoran la estabilidad del entrenamiento y la detección de objetos pequeños u ocluidos. Finalmente, introduce el optimizador MuSGD, un híbrido entre SGD y el optimizador Muon que acelera la convergencia y mejora la estabilidad del entrenamiento (Sapkota et al., 2025).

Figura 34

Diagrama simplificado de la arquitectura de YOLO26, mostrando el pipeline de preprocesamiento, extracción de características, fusión de características multi-escala, cabeza de regresión directa y predicciones sin NMS.



Nota. Adaptado de Sapkota et al. (2025).

En este trabajo se emplearon *YOLO26n* para detectar pajillas y partículas y *YOLO26n-seg* para delimitar la cinta cardada. YOLO26 representó el perfil compacto y orientado al despliegue: ambas variantes *nano* permitieron evaluar si una arquitectura de menor complejidad podía mantener un desempeño competitivo y facilitar una futura ejecución en dispositivos con recursos limitados (Sapkota et al., 2025).

La Tabla 9 presenta una comparación directa entre las innovaciones de cada arquitectura y la razón por la cual fue incluida en la evaluación.

Tabla 9*Comparación de las arquitecturas YOLO utilizadas en la investigación*

Modelo	¿Qué lo diferencia?	¿Por qué se incluyó?
YOLOv8	Emplea bloques C2f, una cabeza desacoplada y predicción sin anclas. Utiliza CIoU y DFL para mejorar la localización de las cajas.	Actuó como arquitectura de referencia. La variante YOLOv8l permitió evaluar un perfil de alta capacidad representativa.
YOLO11	Sustituye bloques C2f por C3k2, conserva SPPF e incorpora atención espacial C2PSA para concentrar el procesamiento en regiones relevantes.	Representó una alternativa intermedia orientada al equilibrio entre capacidad predictiva y costo computacional.
YOLO26	Elimina DFL, permite inferencia extremo a extremo sin NMS e incorpora ProgLoss, STAL y MuSGD. Su diseño prioriza objetos pequeños y simplifica el despliegue.	Representó el perfil compacto, orientado a reducir el postprocesamiento y facilitar la ejecución en dispositivos con recursos limitados.

Nota. Elaboración propia a partir de Yaseen (2024), Khanam & Hussain (2024) y Sapkota et al. (2025).

Para la detección de pajillas y partículas se evaluaron *YOLOv8l*, *YOLO11s* y *YOLO26n*. Para delimitar la cinta cardada se utilizaron sus variantes de segmentación *YOLOv8n-seg*, *YOLO11n-seg* y *YOLO26n-seg*; esta delimitación fue una etapa auxiliar previa al cálculo de los indicadores de homogeneidad.

Las configuraciones de detección pertenecen a escalas diferentes: *YOLOv8l* representó el perfil de alta capacidad, *YOLO11s* el perfil equilibrado y *YOLO26n* el perfil compacto. Por ello, la comparación se planteó entre soluciones candidatas completas y no como un estudio aislado del efecto de cada generación arquitectónica. Los tres modelos se entrenaron y evaluaron con las mismas clases, particiones de datos y métricas.

3.11.2 Aumento de datos

El aumento de datos (*data augmentation*) es una técnica que permite incrementar artificialmente el tamaño y la diversidad del conjunto de entrenamiento mediante la aplicación de transformaciones controladas sobre las imágenes originales, mejorando la capacidad de generalización del modelo ante condiciones no vistas durante el entrena-

miento (Iman et al., 2023). En esta investigación se aplicaron estrategias de aumento diferenciadas según la tarea: detección de impurezas y segmentación por instancias del vellón cardado, dado que cada tarea presenta distintos requerimientos en cuanto a la preservación de las anotaciones geométricas.

Para ambas tareas se empleó la biblioteca *Albumentations* (Buslaev et al., 2020), que permite aplicar transformaciones de forma eficiente garantizando la coherencia entre la imagen aumentada y sus anotaciones correspondientes, ya sean cajas delimitadoras en formato YOLO o polígonos de segmentación.

3.11.2.1 Aumento de datos para detección de impurezas

Para mejorar la capacidad de generalización del modelo en la detección de impurezas (pajillas y partículas), se aplicó una estrategia de aumento de datos sobre el conjunto de entrenamiento. En total se utilizaron siete transformaciones que modifican la geometría, la iluminación y el ruido de las imágenes. Durante este proceso se preservaron las cajas delimitadoras en formato YOLO mediante el parámetro `BboxParams`, estableciendo además un umbral mínimo de visibilidad de 0.3 para descartar aquellas cajas que quedaran mayormente fuera del encuadre después de una transformación.

Las transformaciones aplicadas incluyeron rotaciones discretas (`rot90`) y libres (`rot_free`), inversión horizontal (`hflip`), acercamiento espacial (`zoomin`), variaciones fotométricas de iluminación (`lighting`), adición de ruido (`noise`) y combinaciones de estas operaciones (`combo`). Cada imagen original generó hasta siete variantes aumentadas; sin embargo, aquellas imágenes en las que ninguna caja delimitadora superaba el umbral de visibilidad fueron descartadas. Asimismo, las imágenes que no contenían etiquetas no fueron consideradas en el proceso de aumento.

La Figura 35 muestra el flujo general del pipeline de aumento de datos aplicado en este trabajo, mientras que la Figura 36 presenta un ejemplo de las variaciones generadas a partir de una imagen original.

Figura 35

Flujo de aumento de datos empleado sobre el conjunto de entrenamiento para la detección de impurezas.

**Figura 36**

Ejemplo de imágenes generadas mediante aumento de datos a partir de una muestra original.



3.11.2.2 Aumento de datos para segmentación por instancias

Con el fin de abordar la tarea de segmentación por instancias del vellón cardado, se implementó una estrategia de aumento de datos aplicada al conjunto de entrenamiento, orientada a incrementar la variabilidad del *dataset* y a fortalecer la capacidad

de generalización del modelo. A lo largo de este proceso se mantuvieron los polígonos de segmentación en formato YOLOv8-seg, garantizando así la coherencia entre las imágenes sometidas a transformación y sus respectivas anotaciones.

Las transformaciones aplicadas incluyeron operaciones geométricas y fotométricas. En el caso de las transformaciones geométricas, se utilizaron volteo horizontal y volteo vertical, lo que implicó la conversión temporal de los vértices del polígono a coordenadas en píxeles antes de aplicar la transformación, seguida de su posterior renormalización con respecto a las dimensiones de la imagen resultante. Por otro lado, las transformaciones fotométricas consistieron en variaciones de brillo y contraste, las cuales modifican únicamente las propiedades de iluminación de la imagen sin alterar la geometría de las anotaciones, por lo que los polígonos originales se conservaron sin modificación.

El flujo general de aumento de datos empleado en este trabajo se ilustra en la Figura 37, la cual exhibe el procesamiento aplicado a cada imagen del conjunto de entrenamiento. De manera complementaria, la Figura 38 muestra ejemplos de las variaciones obtenidas a partir de una imagen original de cinta cardada, producto de las transformaciones anteriormente descritas. Es importante señalar que el aumento de datos se restringió únicamente al conjunto de entrenamiento (*train*), conservándose los conjuntos de validación y prueba sin alteraciones, con el propósito de asegurar una evaluación objetiva del desempeño del modelo.

Figura 37

Pipeline de aumento de datos aplicado al conjunto de entrenamiento para la segmentación por instancias del vellón cardado.

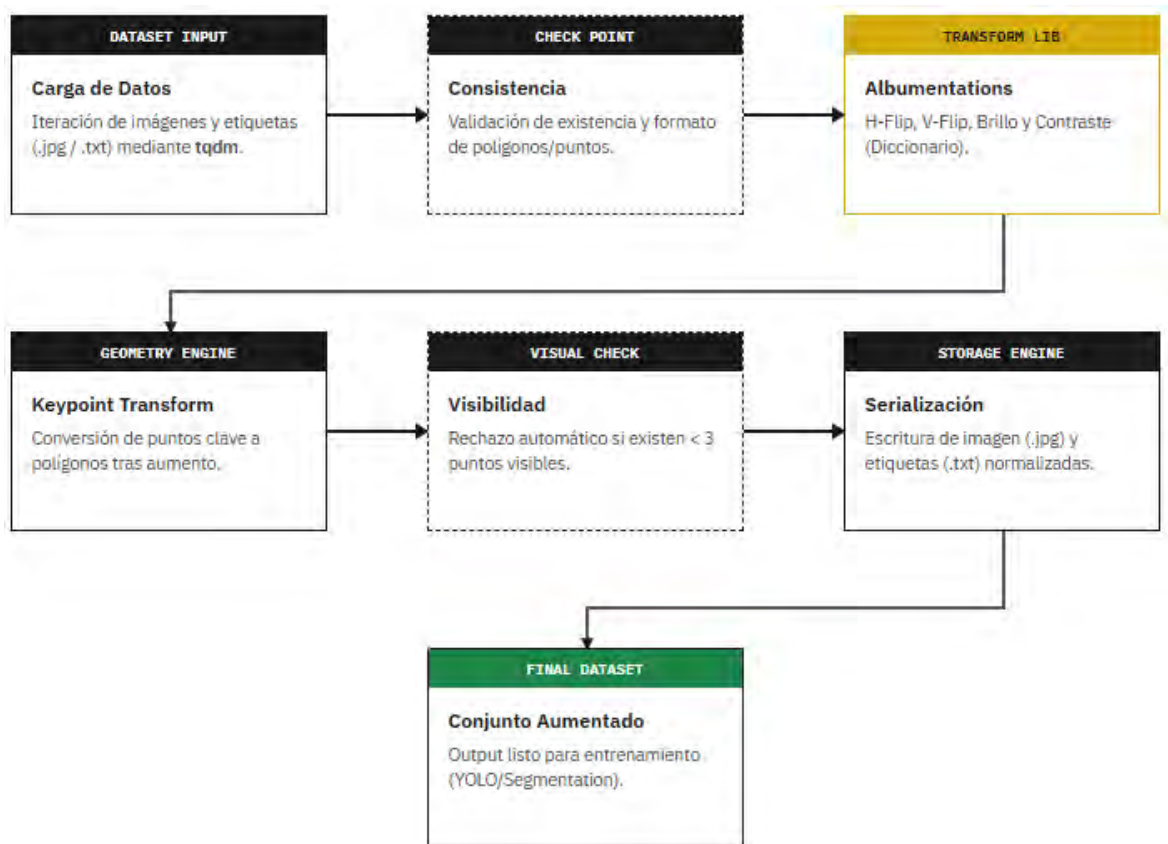



Figura 38

Ejemplos de imágenes generadas mediante aumento de datos a partir de una muestra original de cinta cardada.



3.11.3 Evaluación de la homogeneidad


La homogeneidad del velo de fibra de alpaca constituye uno de los indicadores más relevantes de la calidad del proceso de cardado. Un velo homogéneo se caracteriza por una distribución uniforme de las fibras, un espesor consistente a lo largo de su extensión y una textura interna regular. En contraste, deficiencias en el proceso de cardado producen zonas densas, agrupaciones irregulares de fibra, áreas delgadas o vacíos que comprometen la calidad del producto final.

Dado que la homogeneidad es un concepto multidimensional, no puede ser capturada de forma completa mediante un único indicador estadístico. Por ello, se propone un sistema de evaluación multicriterio que combina cuatro métodos complementarios

de análisis de imagen, cada uno orientado a caracterizar una dimensión específica de la homogeneidad. El proceso se estructura en tres etapas: (i) segmentación del velo mediante el modelo YOLO-Seg, (ii) análisis cuantitativo por los cuatro métodos, y (iii) integración de resultados mediante un sistema de votación. El flujo completo del sistema propuesto se ilustra en la Figura 39.

Figura 39

Pipeline de evaluación de homogeneidad del velo.



3.11.3.1 Segmentación de la cinta

Como paso previo al análisis de homogeneidad, se realiza la segmentación automática del velo en cada imagen mediante el modelo de segmentación de instancias descrito en la sección anterior. La segmentación produce una máscara binaria M de las mismas dimensiones que la imagen de entrada, donde:

$$M(x, y) = \begin{cases} 1 & \text{si el píxel } (x, y) \text{ pertenece al velo,} \\ 0 & \text{si pertenece al fondo.} \end{cases} \quad (3.1)$$

Esta máscara restringe todos los análisis posteriores exclusivamente a la región de interés, eliminando la influencia del fondo y mejorando la precisión de las mediciones. La Figura 40 muestra ejemplos del proceso de evaluación física empleado como referencia para la calibración del sistema.

Figura 40

Evaluación física de la cinta cardada: medición del ancho y pesaje de porciones de la zona central con participación de la especialista.



(a) Medición del ancho de la cinta cardada.



(b) Pesaje de la muestra.

3.11.3.2 Calibración de umbrales

Los umbrales de clasificación se definieron empíricamente y fueron revisados mediante criterio experto. Para ello, se tomaron porciones de la zona central de muestras de cinta cardada, las cuales fueron pesadas; además, se midió el ancho de la cinta y se examinó visualmente la distribución de la fibra. La especialista utilizó estas referencias para valorar la homogeneidad de las muestras y contrastar las clasificaciones generadas por el sistema.

Durante la revisión, varias respuestas fueron consideradas coherentes con la evaluación de la especialista, aunque también se presentaron discrepancias en determinados casos. Por tanto, este procedimiento constituyó una validación cualitativa inicial orien-

tada a evaluar la utilidad del sistema como herramienta de apoyo, y no una validación instrumental definitiva.

3.11.3.3 Método 1: Análisis de intensidad y entropía local

Coefficiente de variación de intensidad

En imágenes de fibra textil, la intensidad de cada píxel refleja directamente la densidad local del material: las zonas claras concentran más fibra, las oscuras tienen menos. Para cuantificar qué tan dispersas están estas intensidades dentro del velo, se extrae el conjunto de valores de gris $\mathcal{V} = \{I(x, y) : M(x, y) = 1\}$ y se calcula el coeficiente de variación:

$$CV = \frac{\sigma}{\mu} \quad (3.2)$$

Un CV bajo significa que la mayoría de píxeles tiene intensidades parecidas entre sí, lo cual es señal de que el material se distribuye de forma homogénea. Un CV alto, en cambio, delata zonas con densidades muy dispares.

Entropía local

El CV captura la dispersión global, pero no dice nada sobre la *distribución espacial* de esa variabilidad. Un velo podría tener CV moderado y aun así presentar zonas localmente caóticas. Para detectar esto, se calcula la entropía de Shannon en cada posición (x, y) sobre una ventana deslizante de $w \times w$ píxeles:

$$H(x, y) = - \sum_i p_i \log_2(p_i) \quad (3.3)$$

donde p_i es la frecuencia relativa del nivel de gris i dentro de la ventana. Como medida global se usa el promedio sobre todos los píxeles del velo:

$$\bar{H} = \frac{1}{|\mathcal{V}|} \sum_{\substack{x, y \\ M(x, y)=1}} H(x, y) \quad (3.4)$$

Una ventana sobre una zona uniforme concentra sus píxeles en pocos niveles de gris, lo que produce entropía baja. Una ventana sobre un grumo o una zona irregular abarca niveles muy distintos, elevando la entropía. Así, $\bar{H}$ alto es síntoma de textura desordenada aun cuando el promedio global parezca aceptable. La clasificación final combina ambas métricas según la Tabla 10.

Tabla 10

Umbrales de clasificación – Método 1 (Intensidad + Entropía)

Condición	Clasificación
$CV < 0,10$ y $\bar{H} < 4,0$	Alta homogeneidad
$CV < 0,15$ y $\bar{H} < 5,0$	Media homogeneidad
$CV \geq 0,15$ o $\bar{H} \geq 5,0$	Baja homogeneidad

3.11.3.4 Método 2: Análisis del perfil transversal del velo

Un velo bien cardado no solo debe tener densidad uniforme, sino también un espesor constante a lo largo de su extensión. Las variaciones de espesor, como los adelgazamientos o las acumulaciones locales, constituyen un defecto frecuente que no siempre queda reflejado en las métricas de intensidad. Este método las detecta directamente.

Para cada columna j de la imagen se cuenta cuántos píxeles pertenecen al velo según la máscara de segmentación:

$$P(j) = \sum_{i=1}^H M(i, j), \quad j = 1, 2, \dots, W \quad (3.5)$$

El vector resultante $\mathbf{P} = [P(1), P(2), \dots, P(W)]$ traza el perfil transversal del velo: si es plano, el espesor es constante; si oscila, hay irregularidades estructurales. La variabilidad de ese perfil se mide con:

$$CV_P = \frac{\sigma(\mathbf{P})}{\mu(\mathbf{P})} \quad (3.6)$$

La clasificación se detalla en la Tabla 11.

Tabla 11
Umbral de clasificación – Método 2 (Perfil del velo)

CV_P	Clasificación
$CV_P < 0,10$	Alta homogeneidad
$0,10 \leq CV_P < 0,20$	Media homogeneidad
$CV_P \geq 0,20$	Baja homogeneidad

3.11.3.5 Método 3: Análisis de textura mediante matriz GLCM

Los métodos anteriores trabajan con píxeles de forma individual: calculan promedios, suman conteos, comparan medias entre zonas. Lo que ninguno de ellos captura es la *relación entre píxeles vecinos*: si un píxel claro está rodeado de píxeles oscuros, o si las transiciones de intensidad son suaves o abruptas. Esa información es precisamente la que contiene la textura de una imagen, y es especialmente relevante para detectar cambios bruscos de densidad, grumos o zonas de textura irregular en el velo.

La Matriz de Co-ocurrencia de Niveles de Gris (*Gray-Level Co-occurrence Matrix*, GLCM) es una herramienta estadística de segundo orden diseñada para capturar exactamente eso (Haralick et al., 1973).

Construcción de la GLCM

La idea es sencilla: para cada par de píxeles separados por una distancia d en una dirección θ , se registra cuántas veces el primero tiene nivel de gris i y el segundo tiene nivel j . El resultado es una tabla de frecuencias $G(i, j)$ que resume cómo se relacionan los niveles de gris a esa escala espacial.

En la implementación presente, la imagen se cuantiza primero a 64 niveles de gris para reducir el tamaño de la matriz sin perder información relevante. La GLCM se construye con desplazamiento $d = 5$ píxeles y ángulo $\theta = 0^\circ$, con simetría y normalización activadas, de modo que $G(i, j)$ representa directamente la probabilidad de co-ocurrencia del par (i, j) .

Homogeneidad de Haralick

De los múltiples descriptores que pueden derivarse de la GLCM, se utiliza la homogeneidad de Haralick:

$$\text{HOM} = \sum_i \sum_j \frac{G(i, j)}{1 + |i - j|} \quad (3.7)$$

El denominador $1 + |i - j|$ es la clave de esta métrica: penaliza los pares cuyas intensidades difieren mucho y premia los que son similares. Si la mayor parte de la probabilidad está concentrada en la diagonal de la matriz —es decir, los píxeles se parecen a sus vecinos— el valor de HOM se acerca a 1. Si, por el contrario, la probabilidad se dispersa fuera de la diagonal vecinos con intensidades muy distintas, como ocurre en los bordes de neps o en zonas de densidad irregular HOM cae hacia 0.

Nótese la diferencia con los métodos anteriores: un velo podría tener intensidad media uniforme (CV bajo) y espesor constante (CV_P bajo), y aun así presentar una textura interna rugosa que solo HOM detectaría. La clasificación se realiza según la Tabla 12.

Tabla 12

Umbrales de clasificación – Método 3 (GLCM)

Homogeneidad HOM	Clasificación
$\text{HOM} > 0,85$	Alta homogeneidad
$0,70 < \text{HOM} \leq 0,85$	Media homogeneidad
$\text{HOM} \leq 0,70$	Baja homogeneidad

3.11.3.6 Método 4: Análisis de variación por bloques

Los tres métodos anteriores producen estimaciones globales del velo. Ninguno responde directamente a la pregunta: *¿dónde* está el problema? Un velo puede tener CV global moderado simplemente porque una zona muy densa compensa a otra muy escasa. Este método está diseñado para detectar ese tipo de asimetría espacial.

La región de interés se divide en una cuadrícula de $n \times n$ bloques —con $n = 4$ en

la presente implementación, lo que genera 16 subregiones— y se calcula la intensidad media de cada bloque: μ_{ij} . Si el material está bien distribuido, estas medias deberían ser similares entre sí. Si hay zonas de acumulación o de escasez, algunas medias se alejarán del conjunto. La variabilidad entre bloques se cuantifica como:

$$CV_B = \frac{\sigma(\mathbf{M}_B)}{\mu(\mathbf{M}_B)} \quad (3.8)$$

donde $\mathbf{M}_B = \{\mu_{ij}\}$ es el conjunto de medias por bloque. La clasificación se detalla en la Tabla 13.

Tabla 13

Umbrales de clasificación – Método 4 (Variación por bloques)

CV_B	Clasificación
$CV_B < 0,08$	Alta homogeneidad
$0,08 \leq CV_B < 0,15$	Media homogeneidad
$CV_B \geq 0,15$	Baja homogeneidad

3.11.3.7 *Justificación del enfoque multicriterio*

Cada uno de los cuatro métodos aborda la homogeneidad desde una perspectiva diferente y complementaria, tal como se resume en la Tabla 14. El uso de un único método podría conducir a evaluaciones incorrectas en casos donde el velo presenta deficiencias en una sola dimensión. Por ejemplo, un velo con espesor uniforme pero textura irregular sería clasificado como homogéneo por el Método 2 pero como heterogéneo por los Métodos 1 y 3. La combinación multicriterio permite una evaluación más robusta y representativa de la calidad real del velo.

Tabla 14*Dimensiones evaluadas por cada método de análisis de homogeneidad*

Método	Dimensión evaluada	Defecto que detecta
M1: Intensidad + Entropía	Uniformidad de densidad y textura local	Grumos, zonas vacías, textura irregular
M2: Perfil del velo	Variación longitudinal del espesor	Adelgazamientos, acumulaciones locales
M3: GLCM	Estructura textural de segundo orden	Cambios bruscos de densidad y textura irregular
M4: Variación por bloques	Heterogeneidad espacial global	Asimetría en distribución del material

3.11.3.8 Sistema de integración por votación

Los cuatro métodos producen cada uno una clasificación independiente: *Alta*, *Media* o *Baja* homogeneidad. Para integrar estas evaluaciones en una decisión final se aplica un mecanismo de votación por mayoría con reglas de prioridad definidas según el impacto sobre la calidad del producto:

- Si **dos o más** métodos clasifican el velo como *Baja homogeneidad* $\Rightarrow$ decisión final: **Baja homogeneidad**.
- Si **ningún** método clasifica como *Baja* y **dos o más** clasifican como *Alta* $\Rightarrow$ decisión final: **Alta homogeneidad**.
- En cualquier otro caso $\Rightarrow$ decisión final: **Media homogeneidad**.

La regla de prioridad para la categoría *Baja* responde al principio de conservación de calidad en el control de procesos textiles: es preferible clasificar incorrectamente un velo aceptable como deficiente (falso positivo) que aceptar un velo deficiente como bueno (falso negativo). Por ello, se requiere mayoría simple para rechazar, pero mayoría absoluta para aprobar como homogéneo.

Capítulo 4

Resultados y discusión

En este capítulo se presentan los resultados de la construcción y validación del *dataset*, la evaluación de las técnicas de reconocimiento de patrones y la implementación de la aplicación móvil. Posteriormente, se discuten los principales hallazgos, alcances y limitaciones de la investigación.

4.1. Construcción y validación del *dataset*

El primer objetivo específico fue construir un *dataset* representativo para neps, homogeneidad, pajillas y partículas y determinar la viabilidad de su etiquetado. En esta investigación, dicha representatividad se circunscribe a las muestras accesibles de fibra de alpaca blanca y a las condiciones de captura estudiadas. De las 1397 imágenes originales adquiridas, los criterios de calidad visual, consistencia de captura y confiabilidad de la etiqueta permitieron conformar un *dataset* analítico de 1105 imágenes: 575 para detección de impurezas y 530 para segmentación y análisis de homogeneidad. Estas se distribuyeron en 773 imágenes de entrenamiento, 221 de validación y 111 de prueba.

El juicio experto permitió establecer que las pajillas y partículas podían anotarse mediante cajas delimitadoras y que la cinta cardada podía segmentarse mediante máscaras para analizar su distribución aparente. En cambio, las 53 imágenes exploratorias a contraluz no permitieron diferenciar los neps de otras variaciones de la fibra con un criterio visual claro y reproducible. Por esta razón, los neps no se incorporaron como clase de entrenamiento y este resultado se considera una limitación técnica del *dataset* construido.

4.2. Hardware

El proceso de entrenamiento de los modelos de visión computacional se ejecutó sobre un servidor de alto rendimiento, dotado de una arquitectura multiprocesador con aceleración mediante GPU. Dicho sistema integra dos procesadores *Intel Xeon Silver 4114* a 2.20 GHz, sumando un total de 20 núcleos físicos y 40 hilos de ejecución, característica que posibilita un procesamiento eficiente en tareas paralelizables tales como la carga de datos, el preprocesamiento y el aumento de datos. Respecto a la memoria, el servidor cuenta con 62 GB de RAM, lo cual favorece el manejo de grandes volúmenes de información y permite el procesamiento simultáneo de múltiples lotes (*batches*) durante el entrenamiento. Para acelerar dicho proceso se empleó una GPU *NVIDIA GeForce RTX 5080*, con 16 GB de memoria VRAM y compatibilidad con CUDA 12.8. Esta unidad de procesamiento gráfico posibilita la ejecución eficiente de operaciones matriciales de alta exigencia computacional, esenciales en modelos de aprendizaje profundo como YOLOv8, contribuyendo a reducir de manera significativa los tiempos de entrenamiento. En lo referente al almacenamiento, el sistema se apoya en una unidad NVMe de alta velocidad; no obstante, se registró una ocupación del 97 % del espacio disponible durante la experimentación, situación que podría incidir negativamente en el rendimiento de las operaciones de lectura y escritura de datos.

Cabe destacar que la GPU fue utilizada como principal recurso de cómputo durante el entrenamiento, mientras que la CPU y la memoria RAM se emplearon en tareas auxiliares como la carga de datos, transformación de imágenes y gestión del pipeline de entrenamiento.

4.3. Configuración de entrenamiento

4.3.1 Detección de impurezas

Los tres modelos evaluados para la detección de impurezas, YOLOv8l, YOLO11s y YOLO26n, fueron entrenados bajo una configuración de hiperparámetros uniforme, con el objetivo de garantizar condiciones comparables y que las diferencias en desempeño sean atribuibles exclusivamente a la arquitectura de cada modelo.

4.3.1.1 Definición de hiperparámetros

El entrenamiento se realizó sobre el *dataset cardado-reetiquetado*, cuya configuración de clases y rutas se especifica en el archivo `data.yaml`.

La resolución de entrada de 800×800 píxeles fue seleccionada para preservar detalles finos relevantes en la detección de impurezas visibles, como pajillas y partículas. El mecanismo de parada temprana evita el sobreajuste sin sacrificar convergencia, mientras que los parámetros de regularización (*dropout* y decaimiento de pesos) contribuyen a la generalización del modelo. El peso aumentado en la función de pérdida de clasificación (`cls = 2.0`) otorga mayor énfasis a la correcta identificación del tipo de impureza.

Con el fin de complementar el aumento de datos realizado en la etapa de preparación del *dataset*, se configuraron tres técnicas de aumento en línea (*online augmentation*) aplicadas por YOLO durante el entrenamiento: mosaico, copia-pegado y mezcla lineal entre imágenes (*mixup*), descritas en la Tabla 15.

Tabla 15*Hiperparámetros de entrenamiento – Detección de impurezas*

Hiperparámetro	Valor	Descripción
<code>imgsz</code>	800	Resolución de entrada (px)
<code>epochs</code>	1 000	Épocas máximas de entrenamiento
<code>patience</code>	150	Tolerancia para parada temprana
<code>batch</code>	6	Imágenes por iteración
<code>device</code>	0	GPU de entrenamiento
<code>workers</code>	2	Procesos de carga de datos
<code>cls</code>	2.0	Peso de la pérdida de clasificación
<code>dropout</code>	0.1	Tasa de dropout
<code>weight_decay</code>	0.0005	Factor de decaimiento de pesos

4.3.2 Segmentación de cinta cardada

La segmentación de la cinta cardada constituye una tarea de menor complejidad respecto a la detección de impurezas, al tratarse de una única clase de interés. Por ello, la configuración de entrenamiento adoptada es más ligera, prescindiendo de técnicas adicionales de regularización y aumento de datos en línea. Los tres modelos, YOLOv8n-seg, YOLO11n-seg y YOLO26n-seg, compartieron la misma configuración base, con excepción de la resolución de entrada del modelo YOLO26n-seg, fijada en 600×600 píxeles frente a los 640×640 píxeles utilizados por los otros dos modelos.

4.3.2.1 Definición de hiperparámetros

El entrenamiento se realizó sobre el *dataset Cinta-cardada-3-2*, cuya configuración se especifica en el archivo `data.yaml`. La configuración completa se resume en la Tabla 16.

Tabla 16*Hiperparámetros de entrenamiento – Segmentación de cinta cardada*

Hiperparámetro	Valor	Descripción
<code>imgsz</code>	640	Resolución de entrada (px)
<code>epochs</code>	300	Épocas máximas de entrenamiento
<code>batch</code>	8	Imágenes por iteración
<code>device</code>	0	GPU de entrenamiento
<code>workers</code>	2	Procesos de carga de datos

4.4. Aplicación y evaluación de técnicas

4.4.1 *Detección de pajillas y partículas*

Los tres modelos se entrenaron bajo las mismas condiciones de hardware.


4.4.1.1 *YOLOv8l*

El entrenamiento se detuvo tras 169 épocas por la activación del mecanismo de parada temprana, alcanzando un tiempo total de 3 horas 19 minutos y 48 segundos.

La Figura 41 presenta las curvas de entrenamiento del modelo, en las que se observa una convergencia estable y sostenida durante todo el proceso. Las pérdidas de entrenamiento (`box_loss`, `cls_loss` y `dfl_loss`) descendieron de forma consistente desde valores iniciales de 1.876, 6.510 y 1.075 hasta estabilizarse en 0.812, 1.777 y 0.828 en la época final. Por su parte, las pérdidas de validación se estabilizaron tempranamente hacia la época 15, sin evidencia de sobreajuste en las épocas posteriores. En cuanto a las métricas de validación, la precisión y el recall se ubicaron alrededor de 0.80 y 0.78, respectivamente, mientras que el $mAP@0.5$ se mantuvo próximo a 0.83 y el $mAP@0.5:0.95$ rondó 0.57.

Figura 41

Evolución de las pérdidas de caja, clasificación y DFL, así como de las métricas de precisión, recall, $mAP@0.5$ y $mAP@0.5:0.95$, durante el entrenamiento y la validación del modelo YOLOv8l para la detección de impurezas.



Los resultados de la evaluación sobre el conjunto independiente de prueba se resumen en la Tabla 17.

Tabla 17

Métricas sobre el conjunto de prueba – YOLOv8l

Clase	P	R	F1	$mAP@0.5$	$mAP@0.5:0.95$
pajilla	0.772	0.791	0.781	0.850	0.562
partícula	0.873	0.823	0.848	0.907	0.637
Promedio	0.823	0.807	0.815	0.879	0.600

Nota. P = precisión; R = recall; $F1$ = media armónica entre precisión y recall; mAP = precisión promedio media.


Sobre el conjunto de prueba, la clase *partícula* obtuvo mayor precisión y F1 que *pajilla*, mientras que *pajilla* alcanzó un recall ligeramente superior. El $mAP@0.5$ global fue de 0.879, con valores de 0.850 y 0.907 para *pajilla* y *partícula*, respectivamente. La velocidad de inferencia registrada fue de 29.7 ms por imagen y su complejidad arquitectónica fue de 164.8 GFLOPs.

La Figura 42 presenta la matriz de confusión obtenida al evaluar YOLOv8l sobre el conjunto de prueba. El modelo identificó correctamente 290 instancias de *pajilla* y

677 de *partícula*. Adicionalmente, 41 pajillas y 78 partículas fueron clasificadas como fondo, y se registraron 85 y 141 detecciones de ambas clases sobre regiones de fondo, respectivamente. Las confusiones entre clases fueron poco frecuentes: 14 pajillas se predijeron como *partícula* y 23 partículas como *pajilla*.

Figura 42

Matriz de confusión obtenida para el modelo YOLOv8l sobre el conjunto independiente de prueba (filas: clases predichas; columnas: clases verdaderas).



4.4.1.2 YOLO11s


Tras 204 épocas se activó el mecanismo de parada temprana, con lo cual el entrenamiento se completó en 2 horas 35 minutos y 16 segundos.

Tal como se aprecia en la Figura 43, el modelo alcanzó una convergencia estable desde las primeras épocas de entrenamiento. Las pérdidas (`box_loss`, `cls_loss` y `dfl_loss`) partieron de 1.933, 7.042 y 1.071 y disminuyeron de manera sostenida hasta ubicarse en 0.934, 2.090 y 0.840 al finalizar el entrenamiento. Un comportamiento similar se observó en las pérdidas de validación, que se estabilizaron alrededor de la

época 20 sin mostrar señales de sobreajuste posteriormente. Las métricas de validación reflejaron una precisión y un recall estables cercanos a 0.80 y 0.79, respectivamente, con un $mAP@0.5$ en torno a 0.84 y un $mAP@0.5:0.95$ próximo a 0.57.

Figura 43

Curvas de entrenamiento y validación del modelo YOLO11s aplicado a la detección de impurezas, con el comportamiento por época de las pérdidas de caja, clasificación y DFL y de las métricas de precisión, recall, $mAP@0.5$ y $mAP@0.5:0.95$.



Sobre el conjunto independiente de prueba, la evaluación arrojó los resultados que se resumen en la Tabla 18.

Tabla 18

Métricas sobre el conjunto de prueba – YOLO11s

Clase	P	R	F1	$mAP@0.5$	$mAP@0.5:0.95$
pajilla	0.787	0.809	0.798	0.845	0.578
partícula	0.863	0.826	0.844	0.920	0.637
Promedio	0.825	0.818	0.821	0.883	0.608

Nota. P = precisión; R = recall; $F1$ = media armónica entre precisión y recall; mAP = precisión promedio media.


Sobre el conjunto de prueba, la clase *partícula* obtuvo un desempeño superior al de *pajilla* en precisión, F1 y mAP , lo que es consistente con su mayor representación. YOLO11s alcanzó un $mAP@0.5$ global de 0.883, con valores de 0.845 y 0.920 para *pajilla*

y *partícula*, respectivamente. La velocidad de inferencia registrada fue de 23.7 ms por imagen.

Como evaluación complementaria, la Figura 44 muestra la matriz de confusión de YOLO11s sobre el conjunto de prueba. Se clasificaron correctamente 281 instancias de *pajilla* y 658 de *partícula*, mientras que 44 pajillas y 103 partículas fueron confundidas con el fondo; a su vez, se registraron 71 y 107 detecciones de ambas clases sobre regiones de fondo. Las confusiones directas entre clases fueron reducidas: 20 pajillas se predijeron como *partícula* y 17 partículas como *pajilla*.

Figura 44

Matriz de confusión del modelo YOLO11s evaluado sobre el conjunto independiente de prueba; las filas corresponden a las clases predichas y las columnas a las clases verdaderas.




4.4.1.3 YOLO26n

El mecanismo de parada temprana se activó a las 189 épocas, acumulando un tiempo de entrenamiento de 4 horas 34 minutos y 53 segundos.

En la Figura 45 se muestran las curvas de entrenamiento, donde se aprecia una convergencia estable a lo largo de todo el proceso. Las pérdidas de entrenamiento (`box_loss`, `cls_loss` y `dfl_loss`) descendieron desde 2.119, 11.074 y 0.003 hasta valores finales de 1.354, 3.073 y 0.0017. Cabe destacar que la `dfl_loss` de este modelo opera en una escala considerablemente menor que los modelos anteriores, lo que es consistente con la arquitectura compacta de YOLO26n. En validación, las pérdidas se estabilizaron tempranamente alrededor de la época 20, con valores finales de `val/box_loss` $\approx 1,16$, `val/cls_loss` $\approx 3,56$ y `val/dfl_loss` $\approx 0,00156$, sin evidencia de sobreajuste. Las métricas correspondientes mostraron una precisión y un recall cercanos a 0.80 y 0.77, respectivamente, con un `mAP@0.5` próximo a 0.83 y un `mAP@0.5:0.95` alrededor de 0.57.

Figura 45

Desempeño del modelo YOLO26n durante el entrenamiento y la validación para la detección de impurezas: pérdidas de caja, clasificación y DFL, junto con precisión, recall, `mAP@0.5` y `mAP@0.5:0.95` registrados en cada época.



La Tabla 19 resume los resultados obtenidos al evaluar el modelo sobre el conjunto independiente de prueba (58 imágenes, 1 123 instancias).

Tabla 19*Métricas sobre el conjunto de prueba – YOLO26n*

Clase	P	R	F1	mAP@0.5	mAP@0.5:0.95
pajilla	0.808	0.744	0.775	0.847	0.560
partícula	0.829	0.819	0.824	0.901	0.640
Promedio	0.819	0.781	0.800	0.874	0.600


Nota. P = precisión; R = recall; $F1$ = media armónica entre precisión y recall; mAP = precisión promedio media.

Sobre el conjunto de prueba, la clase *partícula* obtuvo un desempeño superior al de *pajilla* en recall, F1 y mAP. YOLO26n alcanzó un mAP@0.5 global de 0.874, con valores de 0.847 y 0.901 para *pajilla* y *partícula*, respectivamente. La inferencia sobre prueba registró 35.5 ms por imagen; el modelo posee 2 375 226 parámetros y 5.2 GFLOPs.

La matriz de confusión de prueba (Figura 46) muestra 267 instancias de *pajilla* y 654 de *partícula* correctamente clasificadas. Asimismo, 57 pajillas y 94 partículas fueron clasificadas como fondo; se registraron 57 y 156 detecciones de ambas clases sobre regiones de fondo, respectivamente. Las confusiones directas entre clases fueron 21 pajillas predichas como *partícula* y 30 partículas predichas como *pajilla*.

Figura 46

Resultados de clasificación del modelo YOLO26n sobre el conjunto independiente de prueba, expresados como matriz de confusión (filas: clases predichas; columnas: clases verdaderas).



4.4.1.4 Análisis de desempeño

Los tres modelos fueron evaluados sobre el mismo conjunto independiente de prueba (58 imágenes, 1 123 instancias), lo que permite una comparación directa de su desempeño. La Tabla 20 resume las métricas obtenidas por clase y modelo.

Tabla 20*Comparación de métricas sobre prueba por clase y modelo*

Modelo	Clase	P	R	F1	mAP@0.5	mAP@0.5:0.95
YOLO11s	pajilla	0.787	0.809	0.798	0.845	0.578
	partícula	0.863	0.826	0.844	0.920	0.637
YOLOv8l	pajilla	0.772	0.791	0.781	0.850	0.562
	partícula	0.873	0.823	0.848	0.907	0.637
YOLO26n	pajilla	0.808	0.744	0.775	0.847	0.560
	partícula	0.829	0.819	0.824	0.901	0.640

Nota. P = precisión; R = recall; $F1$ = media armónica entre precisión y recall; mAP = precisión promedio media.

Métricas de precisión

En el conjunto de prueba, YOLO11s obtuvo precisiones de 0.787 y 0.863 para *pajilla* y *partícula*; YOLOv8l alcanzó 0.772 y 0.873; y YOLO26n obtuvo 0.808 y 0.829, respectivamente. En mAP@0.5, YOLO11s alcanzó 0.845 y 0.920 por clase, frente a 0.850 y 0.907 de YOLOv8l y 0.847 y 0.901 de YOLO26n. Las diferencias son reducidas, aunque YOLO11s conserva el mejor promedio global.

En todos los modelos, *partícula* superó consistentemente a *pajilla* en todas las métricas, lo que refleja su mayor representación en el *dataset* (1 552 vs. 674 instancias). La clase *pajilla*, al ser menos frecuente y morfológicamente más variable, presentó mayor dificultad de detección en los tres modelos.

Métricas de pérdida

Las curvas de pérdida de los tres modelos muestran un comportamiento convergente similar. En todos los casos, las pérdidas de entrenamiento (`box_loss`, `cls_loss` y `dfl_loss`) presentaron una reducción sostenida desde las primeras épocas, con estabilización alrededor de las épocas 15–20. Las pérdidas de validación acompañaron esta tendencia sin presentar divergencia respecto a las pérdidas de entrenamiento, lo que indica ausencia de sobreajuste en los tres modelos.

YOLOv8l presentó los valores finales de pérdida de entrenamiento más bajos (`box`: 0.812, `cls`: 1.777, `dfl`: 0.828), consistente con su mayor capacidad de representación.

YOLO11s y YOLO26n mostraron valores finales similares entre sí, aunque con escalas distintas en la `df1_loss` debido a diferencias arquitectónicas.

Curvas de entrenamiento

El comportamiento general de las curvas de entrenamiento fue consistente entre los tres modelos. La precisión y el recall en validación alcanzaron sus valores estables alrededor de las épocas 15–20 en los tres casos, y se mantuvieron sin degradación hasta la activación de la parada temprana. El mAP@0.5 mostró una subida rápida en las primeras épocas seguida de una meseta estable, lo que sugiere que los modelos convergieron efectivamente dentro del presupuesto de épocas disponible.

YOLO11s completó 204 épocas, YOLOv8l 169 épocas y YOLO26n 189 épocas antes de activarse la parada temprana con una tolerancia de 150 épocas, lo que indica que ninguno de los modelos se beneficiaría significativamente de continuar el entrenamiento más allá del punto de convergencia alcanzado.

4.4.2 Segmentación de cinta cardada

4.4.2.1 YOLOv8n-seg


Los tres modelos evaluados fueron entrenados sobre la GPU Quadro GP100 (16 273 MiB) bajo el entorno Ultralytics 8.4.7 con Python 3.10.19 y torch 2.1.0+cu118, utilizando el mismo conjunto de validación de 106 imágenes con 107 instancias de la clase *Cinta*. Las 53 imágenes correspondientes al conjunto de prueba se mantuvieron reservadas para verificaciones posteriores del sistema de segmentación. En todos los casos, las métricas de precisión, recall y mAP@0.5 obtenidas sobre validación alcanzaron valores cercanos a 1.0, lo que refleja la naturaleza relativamente simple de la tarea de segmentación de una única clase sobre fondo controlado.

El modelo cuenta con 3 258 259 parámetros y 12.0 GFLOPs. Completó las 300 épocas configuradas en 3 horas 40 minutos y 43 segundos. Las curvas de entrenamiento (Figura 47) muestran una convergencia rápida y estable: las pérdidas se redujeron pronunciadamente en las primeras épocas y se estabilizaron alrededor de la época 30,

manteniéndose sin fluctuaciones significativas hasta el final.

Figura 47


Curvas de pérdida y métricas de entrenamiento y validación del modelo YOLOv8n-seg.



La evaluación reportó $P = 1.000$, $R = 0.991$, $mAP@0.5 = 0.995$ y $mAP@0.5:0.95 = 0.994$ tanto para detección como segmentación. La matriz de confusión (Figura 48) muestra 106 instancias correctamente segmentadas y 1 clasificada como fondo. La velocidad de inferencia fue de 2.2 ms por imagen.

Figura 48

Matriz de confusión de la segmentación obtenida con YOLOv8n-seg.




4.4.2.2 YOLO11n-seg

El modelo cuenta con 2 834 763 parámetros y 10.2 GFLOPs. Completó 222 épocas en 3 horas 8 minutos y 24 segundos. Las curvas de entrenamiento (Figura 49) muestran una convergencia similar a la del modelo anterior, con reducción pronunciada de pérdidas en las primeras épocas y estabilización progresiva hasta el final.

Figura 49


Comportamiento de las pérdidas y métricas de validación del modelo YOLO11n-seg a lo largo del entrenamiento.



La evaluación reportó $P = 0.999$, $R = 0.991$, $mAP@0.5 = 0.995$ y $mAP@0.5:0.95 = 0.994$, idénticos en detección y segmentación. La matriz de confusión (Figura 50) es equivalente a la del YOLOv8n-seg: 106 instancias correctas y 1 clasificada como fondo. La velocidad de inferencia fue de 2.9 ms por imagen.

Figura 50

Resultados de segmentación del modelo YOLO11n-seg expresados como matriz de confusión.




4.4.2.3 YOLO26n-seg

El modelo cuenta con 2 689 079 parámetros y 9.6 GFLOPs, siendo el más compacto de los tres. Completó 164 épocas en 2 horas 52 minutos y 28 segundos. A diferencia de los modelos anteriores, las curvas de entrenamiento (Figura 51) muestran una convergencia más gradual durante las primeras épocas, estabilizándose conforme avanzó el entrenamiento.

Figura 51


Evolución de las pérdidas y métricas de validación durante el entrenamiento del modelo YOLO26n-seg.



La evaluación reportó $P = 0.998$, $R = 0.991$, $mAP@0.5 = 0.995$ y $mAP@0.5:0.95 = 0.992$. La matriz de confusión (Figura 52) muestra 106 instancias correctamente segmentadas, 1 clasificada como fondo y 1 falso positivo proveniente del fondo. La velocidad de inferencia fue de 3.3 ms por imagen.

Figura 52

Matriz de confusión correspondiente a la segmentación con el modelo YOLO26n-seg.



4.4.2.4 Análisis de desempeño

Los tres modelos se compararon utilizando el mismo conjunto de validación (106 imágenes, 107 instancias), garantizando así condiciones equivalentes para analizar sus respectivos desempeños. Estos resultados se emplearon para seleccionar la arquitectura de segmentación, mientras que el conjunto independiente de prueba, conformado por 53 imágenes, quedó reservado para verificaciones posteriores. En la Tabla 21 se resumen las métricas de validación alcanzadas por cada modelo.

Tabla 21*Comparación de métricas de validación – modelos de segmentación*

Modelo	P	R	mAP@0.5	mAP@0.5:0.95	Épocas	ms/img
YOLOv8n-seg	1.000	0.991	0.995	0.994	300	2.2
YOLO11n-seg	0.999	0.991	0.995	0.994	222	2.9
YOLO26n-seg	0.998	0.991	0.995	0.992	164	3.3

Nota. P = precisión; R = recall; mAP = precisión promedio media; ms/img = milisegundos por imagen.

Métricas de precisión

Los tres modelos alcanzaron un rendimiento prácticamente equivalente. El YOLOv8n-seg obtuvo la mayor precisión ($P = 1.000$), seguido del YOLO11n-seg ($P = 0.999$) y el YOLO26n-seg ($P = 0.998$). El recall fue idéntico en los tres casos ($R = 0.991$), al igual que el $mAP@0.5 = 0.995$. La única diferencia apreciable se observó en el $mAP@0.5:0.95$, donde el YOLOv8n-seg y el YOLO11n-seg obtuvieron 0.994 frente al 0.992 del YOLO26n-seg. Estas diferencias son marginales y no representan una ventaja práctica significativa entre arquitecturas para esta tarea.

Métricas de pérdida

Durante el entrenamiento, el YOLOv8n-seg mostró la convergencia más rápida, con pérdidas estabilizadas alrededor de la época 30 y sin fluctuaciones hasta la época 300. El YOLO11n-seg presentó un comportamiento similar con estabilización progresiva a lo largo de sus 222 épocas. El YOLO26n-seg exhibió una reducción más gradual de las pérdidas durante las primeras épocas, consistente con su arquitectura más compacta. En los tres modelos, las pérdidas de validación siguieron la misma tendencia que las de entrenamiento, sin indicios de sobreajuste.

Curvas de entrenamiento

Las curvas de entrenamiento (Figuras 47, 49 y 51) reflejan el comportamiento descrito. El YOLOv8n-seg y el YOLO11n-seg presentan perfiles de convergencia muy similares, con caída pronunciada en las primeras épocas y meseta estable en el resto del entrenamiento. El YOLO26n-seg muestra mayor variabilidad inicial, especialmente en `val/cls_loss`, aunque converge a valores finales comparables. En los tres casos,


las métricas de detección (B) y de máscara (M) son prácticamente simétricas, lo que confirma que los modelos aprenden ambas tareas de forma consistente.

4.4.2.5 Evaluación de la homogeneidad

La homogeneidad del velo de fibra cardada se evaluó mediante un sistema multicriterio compuesto por cuatro métodos complementarios: análisis de intensidad con entropía local (M1), perfil transversal del velo (M2), matriz de co-ocurrencia de niveles de gris (M3) y variación por bloques espaciales (M4). La decisión final se obtuvo por votación mayoritaria entre los cuatro métodos. La Figura 53 muestra la imagen de velo cardado utilizada para la evaluación, junto con la máscara de segmentación obtenida mediante el modelo YOLO-Seg entrenado.

Figura 53

Imagen evaluada y región de interés segmentada.




Método 1: Intensidad y entropía local

A partir de los píxeles contenidos en la región segmentada, se calculó el coeficiente de variación (CV) de la intensidad y la entropía media local mediante un kernel de 15×15 píxeles. Para la imagen evaluada se obtuvo $CV = 0,0783$ y $\bar{H} = 4,0833$, valores que corresponden a una clasificación de *media homogeneidad* según los umbrales definidos ($CV < 0,10$ y $\bar{H} < 4,0$ para alta homogeneidad). El mapa de entropía (Figura 54) revela una distribución no uniforme de la variabilidad textural: las zonas centrales del velo presentan mayor entropía, mientras que los bordes exhiben valores más bajos, lo que es consistente con la concentración de masa de fibra en la región central.

Figura 54


Mapa de entropía local superpuesto sobre el velo segmentado ($\overline{H} = 4,0833$, $CV = 0,0783$).

**Método 2: Perfil transversal de la cinta**


El perfil de espesor se obtuvo sumando, para cada columna x , la cantidad de píxeles pertenecientes al velo según la máscara binaria de segmentación: $p(x) = \sum_y m(x, y)$, donde $m(x, y) \in \{0, 1\}$. El CV del perfil resultante fue $CV = 0,1241$, clasificándose como *media homogeneidad* ($0,10 \leq CV < 0,20$). La Figura 55 muestra una tendencia creciente del espesor desde las columnas centrales hacia el extremo derecho de la imagen, lo que evidencia una distribución no uniforme de la masa de fibra a lo largo del velo. Este comportamiento puede atribuirse a variaciones en la alimentación durante el proceso de cardado.

Figura 55

Análisis del perfil transversal del velo (M2).



(a) Contorno del velo segmentado.



(b) Perfil transversal: espesor por columna (CV = 0,1241).


Método 3: Matriz de co-ocurrencia de niveles de gris (GLCM)

La región del velo recortada se cuantizó a 64 niveles y se calculó la GLCM con distancia $d = 5$ y ángulo $\theta = 0^\circ$. Las propiedades extraídas fueron: homogeneidad = 0,6636, contraste = 4,0165, energía = 0,2654 y correlación = 0,9949. El valor de homogeneidad obtenido es inferior al umbral de media homogeneidad ($> 0,70$), por lo que este método clasificó la muestra como *baja homogeneidad*. La Figura 56 presenta la matriz en escala logarítmica; la distribución dispersa de los valores de co-ocurrencia confirma una textura con alta variabilidad entre píxeles adyacentes, coherente con la

presencia de impurezas y zonas de fibra menos compacta observadas en la imagen original.

Figura 56

Matriz GLCM en escala logarítmica ($d = 5$, $\theta = 0^\circ$, 64 niveles).




Método 4: Variación espacial por bloques

El velo segmentado se subdividió en una cuadrícula de 4×4 bloques, calculándose la intensidad media de cada bloque sobre los píxeles de velo contenidos en él. El CV entre las medias de los bloques fue $CV = 0,0796$, clasificándose como *alta homogeneidad* ($CV < 0,08$). La Figura 57 presenta el mapa de bloques en dos representaciones complementarias: la matriz de intensidades medias permite comparar cuantitativamente la variación entre bloques, mientras que el overlay sobre el velo segmentado contextualiza espacialmente dicha variación. Los tonos blancos y amarillos indican zonas de mayor densidad de fibra, concentradas en la región central, mientras que los tonos anaranjados y rojos se distribuyen en los extremos y en el borde inferior del velo. No obstante, la variación global entre bloques se mantiene dentro del umbral de alta homogeneidad.

Figura 57

Variación espacial por bloques (4×4 , $CV = 0,0796$).



(a) Matriz de intensidad media por bloques.



(b) Mapa superpuesto sobre el velo segmentado.


Decisión final por votación

La integración de los cuatro métodos mediante votación mayoritaria produjo los siguientes resultados individuales: M1 = media, M2 = media, M3 = baja y M4 = alta homogeneidad. Con dos votos de media homogeneidad y sin mayoría de votos de baja (≥ 2 requeridos para clasificar como baja), la decisión final fue **media homogeneidad** (Figura 58). Este resultado es consistente con la inspección visual: el velo presenta una distribución de fibra predominantemente uniforme en su región central, con variaciones perceptibles en el espesor longitudinal y en los bordes, características propias de un velo de calidad intermedia.

De manera complementaria, las clasificaciones de homogeneidad fueron contrastadas cualitativamente con la valoración física y visual de la especialista. Durante esta revisión, varias respuestas del sistema fueron consideradas coherentes con las características observadas en las muestras, aunque no existió concordancia en todos los casos. Estos resultados respaldan el uso del sistema como una herramienta preliminar de apoyo y evidencian la necesidad de ampliar su validación.

Figura 58

Resultado final por votación mayoritaria: media homogeneidad (Altas: 1, Medias: 2, Bajas: 1).



4.5. Comparación global de modelos

Esta sección integra los resultados de ambas tareas, detección de impurezas y segmentación de cinta cardada, con el fin de identificar el modelo más adecuado para cada problema según su desempeño, eficiencia computacional y complejidad arquitectónica.

4.5.1 Detección de impurezas

Los tres modelos alcanzaron un desempeño competitivo sobre el mismo conjunto independiente de prueba. YOLO11s obtuvo el mejor mAP@0.5 promedio (0.883), seguido por YOLOv8l (0.879) y YOLO26n (0.874). También lideró en F1 promedio (0.821) y mAP@0.5:0.95 (0.608), frente a 0.815 y 0.600 de YOLOv8l y 0.800 y 0.600 de YOLO26n. Las diferencias fueron reducidas, pero YOLO11s mantuvo el mejor equilibrio predictivo global. YOLO26n fue el modelo más compacto, con 2 375 226 parámetros y

5.2 GFLOPs, aunque en esta ejecución de prueba registró una inferencia de 35.5 ms por imagen.

En todas las arquitecturas, la clase *partícula* superó consistentemente a *pajilla* en todas las métricas, lo que refleja su mayor representación en el *dataset* (1 552 vs. 674 instancias) y su menor variabilidad morfológica.

4.5.2 Segmentación de cinta cardada

Los tres modelos de segmentación alcanzaron un rendimiento prácticamente equivalente: $\text{mAP}@0.5 = 0.995$ en los tres casos y $\text{mAP}@0.5:0.95$ entre 0.992 y 0.994, con diferencias inferiores a 0.002 en todas las métricas. Ante esta equivalencia en desempeño, el criterio discriminante es la eficiencia: YOLOv8n-seg ofrece la menor latencia (2.2 ms/imagen), seguido por YOLO11n-seg (2.9 ms) y YOLO26n-seg (3.3 ms). YOLO26n-seg, siendo el modelo más compacto (2 689 079 parámetros, 9.6 GFLOPs), convergió en el menor número de épocas (164), lo que representa una ventaja en tiempo de entrenamiento sin sacrificio apreciable de precisión.

4.6. Implementación de la aplicación móvil

Para facilitar su uso durante el proceso de cardado, el sistema de visión computacional se implementó como una aplicación móvil desarrollada con Flutter. Esta aplicación utiliza modelos entrenados de detección y segmentación, integrados en formato TFLite dentro del dispositivo, lo que permite analizar imágenes de fibra de alpaca capturadas con la cámara o seleccionadas desde la galería del teléfono móvil.

Durante el proceso, la aplicación muestra los resultados del análisis de forma visual. En la detección de impurezas, se presentan las cajas delimitadoras correspondientes a pajillas y partículas. En la evaluación de homogeneidad, se visualiza el contorno de la cinta cardada y los indicadores calculados para determinar su uniformidad. Al finalizar el análisis, la aplicación genera un diagnóstico de calidad que puede ser revisado desde

el historial local.

El desarrollo y las pruebas de la aplicación se realizaron utilizando el siguiente entorno:

- **Lenguaje de programación:** Dart.
- **Framework:** Flutter.
- **Entorno de desarrollo:** Visual Studio Code.
- **Plataforma de prueba:** Android.

Justificación de la selección del software. Flutter se eligió porque permitió integrar en una sola aplicación la interfaz de usuario, el acceso a la cámara y la galería, la ejecución de los modelos y el almacenamiento local de resultados. Su desarrollo mediante una única base de código facilita el mantenimiento y una posible adaptación posterior a otras plataformas. Asimismo, la experiencia previa de la investigadora con Flutter y Dart redujo el tiempo de aprendizaje y el riesgo de implementación, aunque este no fue el único criterio de selección.

Los modelos se incorporaron en formato TFLite para realizar la inferencia directamente en el teléfono. Esta decisión evita depender de un servidor externo o de una conexión a Internet durante el análisis, reduce la transferencia de las imágenes y limita los costos asociados con infraestructura remota. En conjunto, Flutter y TFLite fueron compatibles con el objetivo de implementar una herramienta móvil y autónoma. La validación de software y rendimiento se circunscribió a la plataforma Android y al dispositivo empleado en las pruebas; la compatibilidad y el desempeño en otros sistemas y equipos deberán evaluarse antes de su uso operativo.

4.6.1 Arquitectura de la aplicación

La arquitectura de la aplicación se organizó bajo un enfoque de procesamiento local, es decir, sin conexión a un servidor externo para realizar el análisis. Los modelos

de visión computacional se encuentran integrados dentro de la aplicación móvil y se ejecutan directamente en el dispositivo.

La aplicación se divide en módulos funcionales encargados de recibir la imagen, ejecutar el análisis, interpretar los resultados y presentarlos al usuario. Esta organización permite separar las tareas de la interfaz, el procesamiento y el almacenamiento de resultados.

Los módulos principales de la aplicación son los siguientes:

- **Módulo de interfaz:** permite al usuario seleccionar el tipo de análisis, ingresar una imagen y visualizar los resultados.
- **Módulo de entrada de imagen:** gestiona la captura desde la cámara y la selección de imágenes desde la galería.
- **Módulo de inferencia local:** ejecuta los modelos integrados de detección de impurezas y segmentación de la cinta cardada.
- **Módulo de postprocesamiento:** interpreta las salidas de los modelos, generando cajas delimitadoras, conteos, máscaras, contornos y métricas.
- **Módulo de diagnóstico:** clasifica la muestra según los resultados obtenidos en la detección de impurezas o en la evaluación de homogeneidad.
- **Módulo de almacenamiento local:** guarda los resultados del análisis en el historial de la aplicación.
- **Módulo de exportación:** genera archivos descargables con los resultados del análisis y, para la detección, la imagen con cajas delimitadoras.

4.6.2 Flujo de funcionamiento


El flujo de funcionamiento de la aplicación inicia cuando el usuario selecciona el tipo de análisis que desea realizar e ingresa una imagen de la fibra de alpaca, ya sea mediante

la cámara del dispositivo móvil o desde la galería. Luego, la imagen es preparada para la inferencia local y procesada por el modelo correspondiente. Posteriormente, los resultados son interpretados para generar el diagnóstico, almacenarlos en el historial local y permitir su exportación.

La Figura 59 presenta el pipeline general de funcionamiento de la aplicación móvil.

Figura 59

Pipeline general de funcionamiento de la aplicación móvil.



Como se observa en dicha figura, el funcionamiento de la aplicación se organiza en ocho etapas: adquisición de imagen, preprocesamiento, inferencia, postprocesamiento, diagnóstico, revisión del especialista, almacenamiento local y exportación. Estas etapas permiten ordenar el proceso de análisis desde el ingreso de la imagen hasta la generación de resultados para su posterior revisión.

4.6.3 Integración con el modelo de visión computacional

La integración con los modelos de visión computacional se realizó incorporando los modelos entrenados dentro de la aplicación móvil, permitiendo que la inferencia se ejecute de manera local en el dispositivo. De esta forma, la aplicación no requiere conexión con un servidor externo para procesar las imágenes ni para generar los resultados del análisis.

La aplicación utiliza dos modelos principales. El primero corresponde al modelo de detección de impurezas, encargado de identificar pajillas y partículas en la fibra de alpaca. Este modelo genera como salida las clases detectadas, los niveles de confianza y las coordenadas de las cajas delimitadoras. Estas cajas se proyectan sobre la imagen

original para que el usuario pueda visualizar la ubicación de cada impureza.


El segundo modelo corresponde al modelo de segmentación de la cinta cardada, empleado para la evaluación de homogeneidad. Este modelo permite identificar la región de la fibra dentro de la imagen y generar una máscara o contorno de la cinta. A partir de esta región segmentada, la aplicación calcula los indicadores utilizados para determinar el nivel de homogeneidad de la muestra.

Antes de la inferencia, la imagen ingresada es adaptada al tamaño requerido por los modelos. Luego, las salidas obtenidas son postprocesadas para convertirlas en información útil para el diagnóstico, como cajas delimitadoras, conteos, máscaras, contornos y métricas de homogeneidad.

La Figura 60 muestra las dos formas de ingreso de imágenes disponibles en la aplicación móvil: captura mediante cámara y selección desde la galería del dispositivo.

Figura 60

Opciones de ingreso de imágenes en la aplicación móvil.



(a) Captura de imagen mediante cámara.

(b) Selección de imagen desde la galería.

4.6.4 Interfaz de usuario

La aplicación cuenta con una pantalla principal desde la cual el usuario puede seleccionar el tipo de análisis a realizar: detección de impurezas o evaluación de homogeneidad. Además, permite elegir si la imagen será capturada con la cámara del dispositivo o seleccionada desde la galería.

La interfaz fue diseñada para facilitar el uso del sistema durante el proceso de

cardado. Por ello, las opciones principales se presentan de manera directa, permitiendo iniciar rápidamente el análisis de una muestra. Asimismo, las pantallas de resultados priorizan la visualización de la imagen procesada, debido a que esta permite verificar visualmente las regiones detectadas por el modelo.

La Figura 61 presenta la pantalla principal de la aplicación, desde la cual el usuario accede a los módulos de análisis implementados.

Figura 61

Pantalla principal de la aplicación móvil.




Para el análisis de impurezas, la aplicación muestra la imagen evaluada con las cajas

delimitadoras correspondientes a pajillas y partículas. También se presenta el conteo de cada clase detectada y la clasificación generada por el sistema. En la evaluación de homogeneidad, se presenta la imagen de la cinta cardada junto con el diagnóstico obtenido mediante el sistema de votación multicriterio. La Figura 62 muestra los resultados generados para ambos tipos de análisis.

Figura 62

Resultados de los módulos de análisis de la aplicación móvil.



(a) Resultado de detección de pajillas y partículas.


(b) Resultado de evaluación de homogeneidad.

La aplicación también cuenta con un historial local, donde se almacenan las mues-

tras analizadas. Desde esta sección, el usuario puede revisar la imagen evaluada, consultar los resultados obtenidos y registrar la opinión del especialista. La Figura 63 presenta el historial local y el formulario destinado al registro de la opinión especializada.

Figura 63

Historial local y registro de opinión del especialista.



(a) Historial de muestras analizadas.



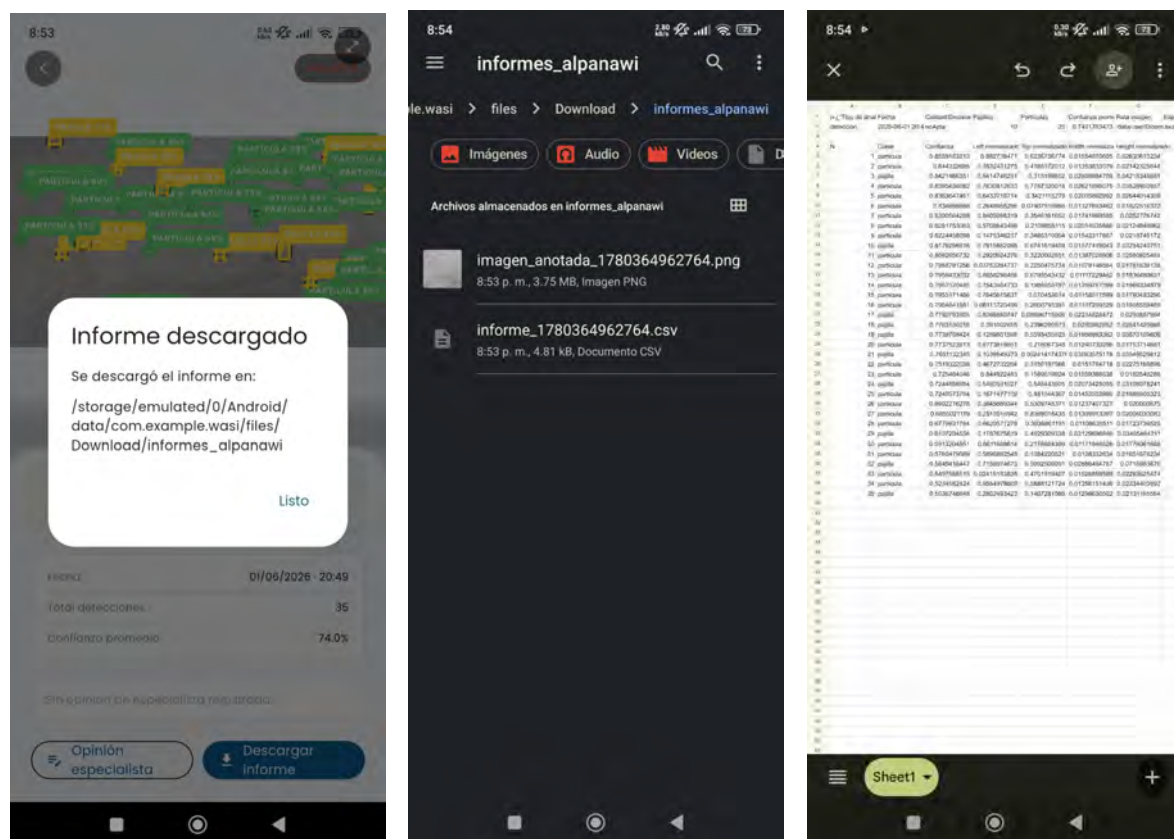
(b) Registro de opinión y recomendación del especialista.

Finalmente, la aplicación permite descargar los resultados del análisis en archivos almacenados localmente. Para la detección de impurezas se genera una imagen anotada y un archivo CSV con las clases, niveles de confianza y coordenadas normalizadas de

cada detección. La Figura 64 muestra la confirmación de descarga, la ubicación de los archivos generados y la visualización del informe exportado.

Figura 64

Exportación y visualización de informes generados por la aplicación móvil.



(a) Confirmación de descarga del informe.

(b) Archivos generados por la aplicación.

(c) Informe CSV con las detecciones registradas.

4.6.5 Generación del diagnóstico de calidad

La generación del diagnóstico de calidad depende del tipo de análisis realizado. En el caso de la detección de impurezas, la aplicación considera el número total de pajillas y partículas detectadas en la imagen. Cada impureza identificada representa una evidencia visual que afecta la calidad de la muestra. Por ello, el sistema utiliza una regla de clasificación basada en umbrales operativos definidos como criterio inicial de apoyo, ajustables posteriormente con validación especializada y estándares propios del proceso productivo.

- **Apta:** hasta 5 impurezas detectadas.

- **Observada:** de 6 a 10 impurezas detectadas.
- **No apta:** más de 10 impurezas detectadas.

En el caso de la evaluación de homogeneidad, el diagnóstico se obtiene mediante un sistema de votación multicriterio. La aplicación calcula indicadores asociados a la uniformidad de la cinta cardada, tales como variación de intensidad, perfil del velo, textura y variación local. Cada método genera una evaluación parcial, la cual se contabiliza como voto de alta, media o baja homogeneidad. La categoría con mayor número de votos determina el diagnóstico final.

El resultado se presenta mediante etiquetas visuales y texto descriptivo, de modo que el usuario pueda interpretar rápidamente el estado de la muestra. Además, el diagnóstico queda registrado en el historial local, junto con la imagen evaluada y los datos generados durante el análisis. En la detección de impurezas, la aplicación permite exportar una imagen con las cajas delimitadoras; mientras que, en la evaluación de homogeneidad, se exportan las métricas calculadas y la decisión final.

4.7. Discusión

En esta sección se interpretan los principales hallazgos, su alcance y las limitaciones que impiden generalizarlos más allá de las condiciones estudiadas.

4.7.1 Construcción y viabilidad del dataset

El etiquetado manual de impurezas en fibra de alpaca representa una de las etapas más críticas y costosas del pipeline. La distinción entre las clases *pajilla* y *partícula* requirió criterio experto, dado que ambas comparten características visuales similares en términos de tamaño y color bajo determinadas condiciones de iluminación. Esta ambigüedad morfológica se refleja directamente en el desempeño diferenciado de los modelos: en los tres casos, *pajilla* obtuvo métricas consistentemente inferiores a las de *partícula*, lo que sugiere que la variabilidad intraclasses de *pajilla* es mayor y más

difícil de capturar con el volumen de anotaciones disponible (674 vs. 1 552 instancias). Durante el proceso de anotación se identificaron casos en los que objetos susceptibles de ser etiquetados no habían sido marcados en versiones anteriores del *dataset*. La corrección de estas omisiones mediante re-etiquetado asistido por modelo redujo el ruido en las anotaciones y mejoró la consistencia del conjunto de entrenamiento. No obstante, no puede descartarse la presencia de instancias sin etiquetar en el conjunto final, lo que constituye una fuente de error difícil de cuantificar y que podría penalizar artificialmente las métricas de recall.

Para la tarea de segmentación, el etiquetado fue considerablemente más sencillo al tratarse de una única clase con bordes bien definidos sobre fondo controlado. Esto se refleja en los resultados: los tres modelos alcanzaron métricas cercanas a 1.0, lo que indica que la calidad de las anotaciones fue suficiente para que cualquier arquitectura evaluada resolviera la tarea sin dificultad.

4.7.2 Aplicación y evaluación de técnicas de reconocimiento

4.7.2.1 Interpretación comparativa y selección de modelos

Los tres detectores alcanzaron resultados cercanos sobre el mismo conjunto independiente de prueba. La ligera ventaja de YOLO11s indica que una arquitectura de mayor tamaño, como YOLOv8l, no garantiza un mejor desempeño en este dominio. Asimismo, aunque YOLO26n fue el modelo más compacto, esa menor complejidad no produjo la menor latencia en el entorno utilizado. En las tres arquitecturas, *pajilla* presentó resultados inferiores a *partícula*; este comportamiento es coherente con su menor número de instancias, mayor variabilidad morfológica y similitud con algunas regiones del fondo fibroso.

En segmentación, el rendimiento prácticamente equivalente de los tres modelos se explica por tratarse de una sola clase, con bordes definidos, iluminación uniforme y fondo controlado. Las diferencias observadas bajo umbrales de IoU más estrictos corresponden a pequeñas variaciones en los bordes de las máscaras y no modificaron el

funcionamiento posterior del análisis de homogeneidad.

Con base en la comparación presentada en la sección anterior, se seleccionó YOLO11s para la detección por su mejor equilibrio entre mAP, F1 y tiempo de inferencia, y YOLOv8n-seg para delimitar la cinta por su precisión y menor latencia. Los tiempos reportados corresponden al entorno de cómputo experimental; por ello, no representan directamente el rendimiento de la aplicación en todos los dispositivos móviles.

4.7.2.2 Generalización y alcance de la evaluación

Las matrices de confusión muestran que el fondo fue la principal fuente de error, especialmente en regiones cuya textura se asemeja a las impurezas o cuando estas ocupan pocos píxeles. El análisis exploratorio de imágenes descartadas durante la depuración, debido a sobreexposición, desenfoque, ángulos atípicos o densidades fuera del rango habitual, mostró menor confianza y más falsos negativos para *pajilla*. Por tanto, la robustez fuera del entorno controlado requiere ampliar el *dataset* con variaciones de iluminación, posición, densidad, lote y color.

El alcance de la evaluación fue diferente para cada componente: la detección de pajillas y partículas se evaluó sobre un conjunto independiente de prueba; la segmentación se comparó sobre validación; la homogeneidad se estimó mediante indicadores visuales calibrados empíricamente; y la detección de neps no resultó viable con las imágenes disponibles. En consecuencia, las métricas obtenidas sustentan el funcionamiento del prototipo bajo condiciones semejantes a las estudiadas, pero no permiten afirmar su generalización a todo el proceso productivo.

4.7.3 Implementación de la herramienta de usuario final

La aplicación móvil integró los modelos seleccionados y los métodos de análisis en un flujo de uso que permite capturar o seleccionar una imagen, ejecutar inferencia local, presentar pajillas y partículas detectadas, estimar la homogeneidad aparente, conservar un historial, registrar la opinión del especialista y exportar resultados. Esta integración

demuestra la factibilidad técnica de trasladar los componentes experimentales a una herramienta funcional sin depender de un servidor externo.

La implementación y verificación funcional corresponden a un prototipo cuya utilidad debe interpretarse como apoyo a la inspección. Las latencias medidas durante la experimentación pertenecen al entorno de cómputo utilizado y no constituyen una evaluación formal del rendimiento en todos los dispositivos móviles. Asimismo, la aplicación no sustituye los ensayos textiles instrumentales ni emite una certificación normativa. Para afirmar su eficacia operativa se requerirían pruebas de usabilidad con operarios y una validación prospectiva en condiciones reales o semiindustriales.

4.7.4 *Síntesis general*

El sistema se implementó mediante cuatro componentes relacionados: un *dataset* documentado, modelos de detección de impurezas, segmentación y análisis multicriterio de homogeneidad, y una aplicación móvil que integra los resultados.

En conjunto, los hallazgos respaldan la viabilidad del sistema como herramienta complementaria para identificar pajillas y partículas visibles y estimar la homogeneidad aparente bajo condiciones semejantes a las estudiadas. No respaldan una detección automática concluyente de neps ni una declaración de conformidad con la NTP. El alcance de la solución está delimitado por la fibra blanca, el entorno de captura controlado, el tamaño y composición del *dataset* y la ausencia de validación instrumental para homogeneidad y neps.

Capítulo 5

Conclusiones y recomendaciones

5.1. Conclusiones

1. Se implementó un sistema de apoyo al control de calidad de la fibra de alpaca durante el cardado mediante la construcción de un *dataset* propio obtenido en entornos controlados, el entrenamiento de modelos de visión computacional, la aplicación de métodos multicriterio para evaluar la homogeneidad aparente y la integración de los componentes seleccionados en una aplicación móvil. El sistema permitió identificar pajillas y partículas visibles mediante YOLO11s y evaluar la homogeneidad aparente de la cinta cardada a partir de indicadores de intensidad, entropía local, perfil transversal, textura GLCM y variación por bloques. En cambio, el análisis de viabilidad determinó que la detección de neps no fue técnicamente viable bajo las condiciones de captura utilizadas, debido a su reducido tamaño, bajo contraste y falta de un criterio visual reproducible. En consecuencia, el sistema implementado constituye una herramienta complementaria de preinspección visual y registro de resultados, pero no sustituye el juicio experto, los ensayos textiles instrumentales ni representa una certificación de cumplimiento normativo.
2. Se construyó y documentó un *dataset* propio bajo las condiciones de captura estudiadas en el CITE Textil Camélidos Cusco. De las 1397 imágenes originales adquiridas, se seleccionaron 1105 para el conjunto analítico: 575 orientadas a la detección de pajillas y partículas y 530 a la evaluación de homogeneidad,

distribuidas en entrenamiento, validación y prueba. El juicio experto confirmó que las pajillas y partículas podían etiquetarse mediante cajas delimitadoras. En cambio, los neps no pudieron diferenciarse de manera clara y reproducible frente a otras variaciones de la fibra en las imágenes a contraluz, por lo que no se incorporaron como clase de entrenamiento. De este modo, se determinó la viabilidad de etiquetado de pajillas y partículas, mientras que para los neps se documentó una limitación técnica.

3. La aplicación y comparación de técnicas de reconocimiento de patrones permitió seleccionar YOLO11s para identificar pajillas y partículas visibles. En el conjunto independiente de prueba, este modelo presentó el mejor desempeño global, con precisión media de 0.825, F1 promedio de 0.821 y mAP@0.5 de 0.883, frente a 0.879 de YOLOv8l y 0.874 de YOLO26n. La homogeneidad aparente se evaluó mediante intensidad, entropía local, perfil transversal, textura GLCM y variación por bloques, integrados mediante una regla de votación. Estos resultados respaldan la identificación de pajillas y partículas y la evaluación visual de homogeneidad dentro de las condiciones estudiadas, pero no una detección automática concluyente de neps ni una medición textil normativa.
4. Se implementó una aplicación móvil funcional desarrollada con Flutter que integró los modelos seleccionados en formato TFLite y ejecutó el procesamiento localmente, sin depender de un servidor externo. La herramienta permitió capturar o seleccionar imágenes, visualizar pajillas y partículas detectadas, estimar la homogeneidad aparente, almacenar los resultados en un historial, registrar la opinión del especialista y exportar información en formato CSV. Las pruebas funcionales verificaron la ejecución de estas operaciones; sin embargo, el prototipo debe mantenerse como herramienta de apoyo y requiere validación de usabilidad y desempeño en condiciones reales o semiindustriales antes de su adopción operativa.

5.2. Recomendaciones

1. Ampliar y diversificar el *dataset* con imágenes provenientes de distintos lotes, colores, densidades, condiciones de iluminación y configuraciones de cardado. Es importante priorizar la calidad, representatividad y consistencia de los datos antes de incorporar arquitecturas más complejas, ya que el desempeño del sistema depende en gran medida de la calidad del conjunto de entrenamiento.
2. Fortalecer la validación con especialistas textiles, de modo que las métricas computacionales empleadas, como el coeficiente de variación de intensidad o las características GLCM, puedan relacionarse con parámetros de calidad reconocidos por la industria, tales como regularidad de cinta, densidad lineal o índices instrumentales de imperfecciones.
3. Mantener el sistema como una herramienta de apoyo a la toma de decisiones, complementaria a la inspección experta y a los métodos instrumentales de control de calidad. Esta recomendación resulta especialmente importante mientras no se disponga de una validación amplia en escenarios industriales reales.

5.2.1 Líneas de trabajo futuro

1. Integrar el sistema desarrollado en un entorno de cardado real o semiindustrial, incorporando una cámara fija, control de iluminación y un dispositivo de inferencia local compatible con procesamiento en tiempo casi real, como una plataforma embebida o un equipo móvil de mayor capacidad.
2. Ampliar el estudio de neps mediante nuevas condiciones de captura, incluyendo mayor resolución, lentes macro, iluminación rasante, retroiluminación controlada o sensores especializados, con el fin de determinar si es posible obtener imágenes suficientemente informativas para su etiquetado y detección.

3. Mejorar la detección de impurezas pequeñas mediante estrategias de aumento de datos dirigido a la clase *pajilla*, balanceo de clases, ajuste de umbrales de confianza y evaluación de arquitecturas o módulos especializados para objetos de baja escala y bajo contraste.
4. Aplicar técnicas de explicabilidad e interpretabilidad, como Grad-CAM u otros mapas de activación, para analizar las regiones de la imagen que influyen en las predicciones de los modelos (Selvaraju et al., 2020). Esto permitiría validar si el sistema atiende a las zonas de interés textil, fortalecer la confianza del especialista y facilitar la detección de posibles sesgos del modelo.
5. Extender la evaluación de homogeneidad mediante modelos de regresión o clasificación supervisada que estimen un índice continuo de homogeneidad a partir de características visuales y mediciones textiles instrumentales, reduciendo la dependencia de umbrales fijos y permitiendo una calibración más precisa según los estándares de calidad de cada lote de fibra.

Bibliografía

- Ajit, A., Acharya, K., & Samanta, A. (2020). A Review of Convolutional Neural Networks. *2020 International Conference on Emerging Trends in Information Technology and Engineering (IC-ETITE)*.
- Ali, M. L., & Zhang, Z. (2024). The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. *Computers*, 13(12), 336. <https://doi.org/10.3390/computers13120336>
- Alpaca del Perú. (2024). Fibra Textil: Características y Clasificación. Consultado el 20 de marzo de 2025, desde <https://www.alpacadelperu.pe/wp-content/uploads/2018/08/FIBRAS-TEXTILES-CARACTERISTICAS-Y-CLASIFICACIONES.pdf>
- Beleites, C., Neugebauer, U., Bocklitz, T., Krafft, C., & Popp, J. (2013). Sample Size Planning for Classification Models. *Analytica Chimica Acta*, 760, 25-33. <https://doi.org/10.1016/j.aca.2012.11.007>
- Brigato, L., & Iocchi, L. (2021). A Close Look at Deep Learning with Small Data. *2020 25th International Conference on Pattern Recognition (ICPR)*, 2490-2497. <https://doi.org/10.1109/ICPR48806.2021.9412492>
- Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., & Kalinin, A. A. (2020). Albumentations: Fast and Flexible Image Augmentations. *Information*, 11(2), 125. <https://doi.org/10.3390/info11020125>
- El Pythonista. (2024). *Anaconda: distribución de Python para el desarrollo científico*. Consultado el 12 de noviembre de 2025, desde <https://elpythonista.com/anaconda>
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2010). The PASCAL Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88, 303-338. <https://doi.org/10.1007/s11263-009-0275-4>

- Figuerola, R. L., Zeng-Treitler, Q., Kandula, S., & Ngo, L. H. (2012). Predicting Sample Size Required for Classification Performance. *BMC Medical Informatics and Decision Making*, 12(8). <https://doi.org/10.1186/1472-6947-12-8>
- Geburu, T., Morgenstern, J., Vecchione, B., Vaughan, J. W., Wallach, H., Daumé III, H., & Crawford, K. (2021). Datasheets for Datasets. *Communications of the ACM*, 64(12), 86-92. <https://doi.org/10.1145/3458723>
- Han, P. H., Li, X. r., Liu, R., Zhang, S., & Yuan, C. (2024). Prediction method of carding process production quality based on digital twin technology. *Textile Research Journal*, 94(5-6), 713-724. <https://doi.org/10.1177/00405175231217120>
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610-621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Hu, D., Liu, X., & Xu, J. (2024). Improved YOLOv5-based image detection of cotton impurities. *Textile Research Journal*, 94(7-8), 906-917. <https://doi.org/10.1177/00405175231221296>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2018). Densely Connected Convolutional Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://arxiv.org/abs/1608.06993>
- Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A Review of Deep Transfer Learning and Recent Advancements. *Technologies*, 11(2), 40. <https://doi.org/10.3390/technologies11020040>
- Ingle, N., & Jasper, W. J. (2024). A review of deep learning within the framework of artificial intelligence for enhanced fiber and yarn quality. *Textile Research Journal*, 1-30. <https://doi.org/10.1177/00405175241265510>
- Instituto Nacional de Calidad. (2021). *NTP 231.309:2005 (revisada el 2021): Fibra cardada de alpaca. Definiciones, requisitos, clasificación y rotulado* (Norma Técnica Peruana N.º NTP 231.309:2005). Instituto Nacional de Calidad.

- Instituto Tecnológico de la Producción. (2023). *Actualización de la lista de servicios adicionales de los Centros de Innovación Productiva y Transferencia Tecnológica*. Ministerio de la Producción. Consultado el 13 de agosto de 2026, desde https://cdn.www.gob.pe/uploads/document/file/4789229/RDE%20104-2023-ITP_Anexo3.pdf?v=1688400978
- Khanam, R., & Hussain, M. (2024). YOLOv11: An Overview of the Key Architectural Enhancements. *arXiv preprint arXiv:2410.17725*. <https://arxiv.org/abs/2410.17725>
- Klingler, N. (2023). Segmentación de Imágenes con Aprendizaje Profundo (Guía). Consultado el 5 de diciembre de 2025, desde <https://viso.ai/deep-learning/image-segmentation-using-deep-learning/>
- Li, J., Zhong, Z., Han, Y., & Wang, X. (2025). Cotton-YOLO: A Lightweight Detection Model for Falled Cotton Impurities Based on Yolov8. *Symmetry*, 17(8), 1185. <https://doi.org/10.3390/sym17081185>
- Li, Q., Ma, W., Li, H., Zhang, X., Zhang, R., & Zhou, W. (2024). Cotton-YOLO: Improved YOLOv7 for Rapid Detection of Foreign Fibers in Seed Cotton. *Computers and Electronics in Agriculture*, 219, 108752. <https://doi.org/10.1016/j.compag.2024.108752>
- Lin, J., & Du, Y. (2025). Research on the Identification Method of Foreign Fibers in Cotton Based on CAF-YOLO Model. *Proceedings of the 2025 2nd International Conference on Computer and Multimedia Technology (ICCMT 2025)*, 310-316. <https://doi.org/10.1145/3757749.3757799>
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context. *Computer Vision – ECCV 2014*, 740-755. https://doi.org/10.1007/978-3-319-10602-1_48
- Lockuán Lavado, F. E. (2012). *La Industria Textil y su Control de Calidad* [Versión 0.1, octubre de 2012].

- Ministerio de Producción del Perú. (2024). *Estudio Sectorial del Sector Textiles y Confecciones de Fibra 2024* (inf. téc.) (Elaborado por PRODUCE). Oficina de Estudios Económicos. Lima, Perú.
- Ministerio de Producción del Perú. (2025, marzo). *Análisis Sectorial: Desempeño e importancia de la Industria de Textil y Confecciones 2020–2025* (inf. téc.) (Elaborado por PRODUCE-OGEIEEE-OEE). Oficina General de Evaluación de Impacto y Estudios Económicos – Oficina de Estudios Económicos. Lima, Perú.
- Nath, J. M., Shukla, S. K., & Patil, P. G. (2015). Neps in cotton. *Journal of Cotton Research and Development*, 29, 329-332. <https://api.semanticscholar.org/CorpusID:185690978>
- O’Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. *arXiv preprint arXiv:1511.08458*.
- Raschka, S., Patterson, J., & Nolet, C. (2020). Machine Learning in Python: Main Developments and Technology Trends in Data Science, Machine Learning, and Artificial Intelligence. *Information*, 11(4), 193. <https://doi.org/10.3390/info11040193>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788.
- Sapkota, R., Cheppally, R. H., Sharda, A., & Karkee, M. (2025). YOLO26: Key Architectural Enhancements and Performance Benchmarking for Real-Time Object Detection. *arXiv preprint arXiv:2509.25164*. <https://arxiv.org/abs/2509.25164>
- Sapkota, R., & Karkee, M. (2025). Ultralytics YOLO Evolution: An Overview of YOLO26, YOLO11, YOLOv8 and YOLOv5 Object Detectors for Computer Vision and Pattern Recognition. *arXiv preprint arXiv:2510.09653*. <https://arxiv.org/abs/2510.09653>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2020). Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Lo-

- calization. *International Journal of Computer Vision*, 128(2), 336-359. <https://doi.org/10.1007/s11263-019-01228-7>
- Studer, S., Bui, T. B., Drescher, C., Hanuschkin, A., Winkler, L., Peters, S., & Müller, K.-R. (2021). Towards CRISP-ML(Q): A machine learning process model with quality assurance methodology. *Machine Learning and Knowledge Extraction*, 3(2), 392-413. <https://doi.org/10.3390/make3020020>
- Supo, J. (2014). *Seminarios de investigación científica: Metodología de la investigación para las ciencias de la salud* (2.^a ed.). Bioestadístico EIRL.
- Terven, J., Córdova-Esparza, D.-M., & Romero-González, J.-A. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4), 1680-1716. <https://doi.org/10.3390/make5040083>
- Wang, X., Wang, L., & Liu, X. (2003). *The Quality and Processing Performance of Alpaca Fibres* [RIRDC Publication No. 03/128, Project No. UD-2A]. Rural Industries Research; Development Corporation. <http://www.rirdc.gov.au>
- Xu, T., Ma, A., Lv, H., Dai, Y., Lin, S., & Tan, H. (2023). A lightweight network of near cotton-coloured impurity detection method in raw cotton based on weighted feature fusion. *IET Image Processing*, 17, 2585-2595. <https://doi.org/10.1049/ipr2.12788>
- Yaseen, M. (2024). What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector. *arXiv preprint arXiv:2408.15857*. <https://arxiv.org/abs/2408.15857>
- Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How Transferable Are Features in Deep Neural Networks? *Advances in Neural Information Processing Systems*, 27.

Anexo A. Resolución de exención de aspectos bioéticos

Evidencia de la revisión y exención de aspectos bioéticos emitida por el Comité de Bioética Institucional de la UNSAAC.

Figura 65

Oficio Virtual N° 014-2025-CBI-VRIN-UNSAAC.



Anexo B. Orden de servicio – CITE Textil Camélidos Cusco

Evidencia del asesoramiento técnico brindado por el CITE Textil Camélidos Cusco.

Figura 66

Orden de servicio de asesoramiento de tesis emitida por el CITE Textil Camélidos Cusco.




Timbre digitalizado por VALDIVIA
3462016 RUC: 2011136948
Fecha: 27/06/2025 11:23:23 -05:00
Código: Soy el autor del documento

SERVICIO: ASESORAMIENTO DE TESIS

Datos del cliente:

Razón social: UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD DEL CUSCO

RUC: 20172474501

Tesista: JOHANA MARÍA MAMANI MEZA

Detalle del servicio:

a) Tarea: Asesoramiento en el desarrollo de tesis de grado (X)

b) Título de la Tesis de Pregrado: "SISTEMA DE CONTROL DE CALIDAD DE LA FIBRA DE ALPACA BASADO EN VISIÓN COMPUTACIONAL PARA LA DETECCIÓN DE NEPS, HOMOGENEIDAD Y PAJILLAS EN EL PROCESO DE CARDADO"

c) Número de horas:

Horas programadas (48)	Horas ejecutadas (48)
------------------------	-----------------------

d) Fecha de ejecución del servicio:

Fecha Inicial (16/04/2025)	Fecha Final (20/06/2025)
----------------------------	--------------------------

e) Responsable del servicio: MVZ. Raúl Valdivia Saravia

f) Cargo del responsable: Especialista en Innovación y transferencia tecnológica