

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

**DESARROLLO E IMPLEMENTACIÓN DE UN SISTEMA DE
CONTROL DE CALIDAD EN EL PROCESO DE HILADO DE
FIBRA DE ALPACA UTILIZANDO VISIÓN COMPUTACIONAL**

PRESENTADO POR:

Br. FRAN ANTHONY HANCCO CHAMPI

**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: Desarrollo e implementación de un
sistema de control de calidad en el proceso de hilado de fibra
de alpaca utilizando visión computacional

Presentado por: Fran Anthony Haneco Champi DNI N° 73967895
presentado por: DNI N°:
Para optar el título Profesional/Grado Académico de Ingeniero Informático y de
sistemas

Informo que el trabajo de investigación ha sido sometido a revisión por 3 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 7.....%.

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.	☒
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, 18 de agosto de 2026

Harley Vera Olivera
.....
Firma
Post firma Harley Vera Olivera

Nro. de DNI 82582815

ORCID del Asesor 0000 - 0003 - 2011 - 8797

Se adjunta:

- Reporte generado por el Sistema Antiplagio.
- Enlace del Reporte Generado por el Sistema de Detección de Similitud: oid: 27259.615202076

FRAN ANTHONY HANCCO CHAMPI

DESARROLLO E IMPLEMENTACIÓN DE UN SISTEMA DE CONTROL DE CALIDAD EN EL PROCESO DE HILADO DE FIBR...

 Universidad Nacional San Antonio Abad del Cusco

Detalles del documento

Identificador de la entrega

trn:oid:::27259:615202016

Fecha de entrega

18 ago 2026, 8:55 a.m. GMT-5

Fecha de descarga

18 ago 2026, 9:01 a.m. GMT-5

Nombre del archivo

ejemplar_tesis_observaciones_levantadas.pdf

Tamaño del archivo

37.1 MB

132 páginas

28.124 palabras

161.979 caracteres

7% 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

- 4%  Fuentes de Internet
- 1%  Publicaciones
- 5%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alerta de integridad para revisión

-  **Caracteres reemplazados**
138 caracteres sospechosos en N.º de páginas
Las letras son intercambiadas por caracteres similares de otro alfabeto.

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

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

PRESENTACIÓN

SEÑOR: DECANO DE LA FACULTAD DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA, INFORMÁTICA Y MECÁNICA DE LA UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD DEL CUSCO, **MGT. JORGE CHINCHIHUALPA GONZALES.**

SEÑORA: DIRECTORA DE LA ESCUELA PROFESIONAL DE INGENIERÍA INFORMÁTICA Y DE SISTEMAS, **DRA. YESHICA ISELA ORMEÑO AYALA.**

SEÑORES: DOCENTES MIEMBROS DEL JURADO.

Con la conformidad del reglamento de grados y títulos de la Escuela Profesional de Ingeniería Informática y de Sistemas, pongo a consideración el presente trabajo de tesis intitulado: **“DESARROLLO E IMPLEMENTACIÓN DE UN SISTEMA DE CONTROL DE CALIDAD EN EL PROCESO DE HILADO DE FIBRA DE ALPACA UTILIZANDO VISIÓN COMPUTACIONAL”** para optar al Título Profesional de **INGENIERO INFORMÁTICO Y DE SISTEMAS.**

Este trabajo de investigación se centra en la modernización de los procesos de control de calidad dentro de la industria textil regional, específicamente en el hilado artesanal de fibra de alpaca. Mediante el uso de tecnologías de visión computacional, se propone un sistema capaz de identificar defectos de manera objetiva y eficiente, superando las limitaciones de la inspección manual tradicional.

El desarrollo de este sistema no solo representa un avance técnico en el área de la inteligencia artificial, sino que busca proporcionar una herramienta accesible para los productores de Cusco, permitiéndoles elevar sus estándares de calidad y mejorar su posicionamiento en el mercado global.

Atentamente,

Br. FRAN ANTHONY HANCCO CHAMPI

ABREVIATURAS

- **BCE**: Binary Cross Entropy (Entropía Cruzada Binaria).
- **CLAHE**: Contrast Limited Adaptive Histogram Equalization.
- **CNN**: Convolutional Neural Networks (Redes Neuronales Convolucionales).
- **COCO**: Common Objects in Context.
- **DFL**: Distribution Focal Loss (Pérdida de Distribución Focal).
- **FPS**: Frames Per Second.
- **IoU**: Intersection over Union (Intersección sobre Unión).
- **mAP**: mean Average Precision (Precisión Media Promedio).
- **Nm**: Número Métrico (Titulación del hilo).
- **PCA**: Principal Component Analysis (Análisis de Componentes Principales).
- **SVD**: Singular Value Decomposition.
- **XAI**: Explainable Artificial Intelligence (IA Explicable).
- **YOLO**: You Only Look Once.

DEDICATORIA

*A mis padres, **Pedro y María**, por ser mi motor y mi mejor ejemplo. Gracias por su esfuerzo diario y por enseñarme, con su paciencia y constancia, a nunca dejar las cosas a medias y a culminar siempre todo lo que me propongo en la vida. Este título es por y para ustedes.*

*A mis abuelos, **León y Teófila**, quienes con su amor y sabiduría guiaron mis pasos. Gracias por esas conversaciones tan profundas donde me contaban cómo se esforzaron por cambiar la historia de nuestra familia, buscando mejorar la vida de los suyos y darles mejores oportunidades tanto a sus hijos como a nosotros sus nietos. Gracias por impulsarme a seguir mis sueños y por cada palabra de aliento que me impulsó a perseverar en los momentos de mayor incertidumbre. Su legado y sus bendiciones me acompañan siempre.*

A mis compañeros de carrera y colegas de investigación, por las jornadas de trabajo compartido y por esa motivación mutua que fue clave para transformar este desafío técnico en una realidad.

A mis familiares, por su respaldo constante y por celebrar conmigo cada etapa de este camino académico.

AGRADECIMIENTO

En primera instancia, manifiesto mi más sincero reconocimiento a la Universidad Nacional de San Antonio Abad del Cusco y, de manera especial, a la Escuela Profesional de Ingeniería Informática y de Sistemas, por haberme brindado la sólida formación académica y las oportunidades de crecimiento que han sido pilares fundamentales en mi desarrollo profesional.

Asimismo, hago extensivo un agradecimiento especial al Laboratorio de Algoritmos y Análisis de Datos (LAAD) por facilitar el soporte tecnológico indispensable para la ejecución de este proyecto. Mi gratitud al Dr. Harley Vera Olivera, asesor de esta tesis, y al Dr. Carlos Fernando Montoya Cubas, co-asesor, cuya guía experta y profundos conocimientos en inteligencia artificial fueron determinantes para alcanzar el rigor científico de esta investigación. De igual modo, valoro profundamente el apoyo de mis colegas: Johana, Milton, Gustavo y Glina; su compañerismo y las extensas jornadas de trabajo compartido permitieron transformar este desafío técnico en un logro colectivo.

Por otra parte, expreso mi especial consideración al CITE Textil Camélidos Cusco por abrirnos sus puertas y facilitar los materiales necesarios para el estudio. En este punto, cabe destacar la invaluable labor de la Ing. Lita Esther Castillo Yepes y el Dr. Raúl Valdivia Saravia, cuya orientación técnica y paciencia al transmitirnos las complejidades de la fibra de alpaca fueron esenciales. Su vasto conocimiento sobre las irregularidades del hilado artesanal permitió que los modelos de visión computacional se fundamentaran en una base sólida y con una aplicación real orientada al beneficio de los productores regionales.

Finalmente, deseo reconocer a los docentes de la facultad y a aquellos amigos que, mediante su apoyo moral y constantes consejos, alentaron la culminación de este trabajo. Cada palabra de aliento contribuyó al éxito de este esfuerzo dedicado a la tecnificación y mejora de nuestra industria textil artesanal.

ÍNDICE

PRESENTACIÓN	II
ABREVIATURAS	III
DEDICATORIA	IV
AGRADECIMIENTO	V
ÍNDICE	VI
ÍNDICE DE TABLAS	XI
ÍNDICE DE FIGURAS	XIII
RESUMEN	XV
ABSTRACT	XVI
INTRODUCCIÓN	XVII
1 PLANTEAMIENTO DEL PROBLEMA	1
1.1 Descripción de la situación problemática	1
1.2 Formulación del problema	2
1.2.1 Problema general	2
1.2.2 Problemas específicos	3
1.3 Justificación de la investigación	3
1.4 Objetivos de la investigación	4

1.4.1	Objetivo general	4
1.4.2	Objetivos específicos	4
1.5	Alcances y Limitaciones de la investigación	5
1.5.1	Alcances	5
1.5.2	Limitaciones	8
2	MARCO TEÓRICO CONCEPTUAL	11
2.1	Antecedentes	11
2.1.1	Antecedentes internacionales	11
2.1.2	Antecedentes nacionales	17
2.1.3	Síntesis de los antecedentes y contribución de la investigación	18
2.2	Bases Teóricas	20
2.2.1	Fibra de alpaca Huacaya y defectos de hilado artesanal	20
2.2.2	Visión computacional y procesamiento digital de imágenes	24
2.2.3	Arquitectura de aprendizaje profundo	26
2.2.4	Métricas de evaluación del modelo de detección	31
2.2.5	Inteligencia Artificial Explicable (XAI)	33
2.3	Marco Conceptual	36
2.3.1	Fundamentos del sistema textil de alpaca y variables de calidad	36
2.3.2	Visión computacional	38
2.3.3	Aprendizaje profundo y detección automática de objetos	39
2.3.4	Dataset y anotación	40
2.3.5	Métricas de evaluación	41
2.3.6	Explicabilidad de modelos de inteligencia artificial (XAI)	41
3	METODOLOGÍA	43
3.1	Tipo de investigación	43
3.2	Elección del modelo	44
3.3	Creación del dataset	44
3.3.1	Obtención de la muestra de hilo artesanal	44

3.3.2	Instrumento de adquisición de imágenes	45
3.3.3	Entorno controlado de captura de imágenes	46
3.3.4	Registro de la preparación y adquisición de imágenes	48
3.3.5	Selección y volumen del conjunto de imágenes	49
3.3.6	Etiquetado mediante segmentación de instancias	50
3.3.7	División del dataset	53
3.3.8	Estrategias de aumentación de datos	54
3.4	Entorno experimental y recursos computacionales	56
3.5	Entrenamiento de modelos	57
3.5.1	Especificación técnica de los modelos	57
3.5.2	Fase inicial: Experimentación con YOLOv8	58
3.5.3	Fase final: Configuración con YOLO11	58
3.6	Evaluación de los modelos	59
3.7	Análisis de XAI	60
3.7.1	Limitaciones de Grad-CAM en redes profundas	60
3.7.2	Optimización mediante Eigen-CAM	61
3.7.3	Justificación de la selección del método	62
3.8	Bucle de mejora iterativo	64
3.8.1	Curación de datos	64
3.8.2	Ajuste de la arquitectura y los hiperparámetros	66
3.9	Estructura y Funcionamiento del Sistema de Visión Computacional	66
3.9.1	Especificaciones y Arquitectura del Software	66
3.9.2	Módulo de Análisis de Imágenes y Diagnóstico Experimental	67
4	RESULTADOS	71
4.1	Evaluación y validación del entorno de captura	71
4.1.1	Comparativa de iluminación y estabilidad	71
4.2	Constitución y características del dataset de hilo artesanal	72
4.2.1	Composición cuantitativa y selección de muestras	72
4.3	Reporte de resultados experimentales	74

4.3.1	Fase 1: Experimentos preliminares con YOLOv8m-seg	74
4.3.2	Fase 2: Experimentos principales con YOLO11	74
4.3.3	Análisis detallado por clase	75
4.4	Justificación de selección del modelo y eficiencia operativa	75
4.5	Resultados Graficos	76
4.5.1	Resultados de segmentación de instancias	76
4.5.2	Análisis de las curvas Precisión–Recall	77
4.5.3	Análisis de la matriz de Confusión	78
4.5.4	Evaluación del proceso de aprendizaje y convergencia	79
4.6	Intepretación de resultados finales	81
4.7	Auditoría del modelo mediante Explicabilidad (XAI)	82
4.7.1	Análisis detallado de activaciones: Capa 16 (C3k2)	82
4.7.2	Validación mediante Experimentos de Ablación y Perturbación	84
4.8	Síntesis Operativa del Sistema Integrado	86
DISCUSIONES		88
CONCLUSIONES		91
RECOMENDACIONES		93
BIBLIOGRAFÍA		95
ANEXOS		99
A	Dataset gold standard	100
B	Algoritmos y configuraciones del sistema	100
B.1	Preprocesamiento y Aumentación de datos	100
B.2	Configuración de entrenamiento (Hiperparámetros)	103
B.3	Algoritmo de generación de mapas de calor (Eigen-CAM)	105
C	Difusión científica: póster Sinapsis 2025	106
D	Informe de aprobación de aspectos bioéticos	106
E	Galería completa de activaciones Eigen-CAM	108

F	Galería completa de activaciones Grad-CAM	109
G	Análisis de costos de infraestructura y presupuesto comparativo	110
G.1	Ficha Técnica Detallada del Sistema Industrial USTER TESTER 6 . . .	110
G.2	Cuadro Comparativo de Presupuesto e Infraestructura	114

ÍNDICE DE TABLAS

Tabla 1	Categorías comerciales de la fibra de alpaca Huacaya según el diámetro medio de fibra (MFD)	20
Tabla 2	Criterios de gradación y clasificación de hilos según ASTM D2255.	24
Tabla 3	Sustento de las técnicas de acondicionamiento y aumentación	26
Tabla 4	Componentes de las CNN	27
Tabla 5	Comparativa técnica de paradigmas de detección para inspección en tiempo real	28
Tabla 6	Hitos arquitectónicos de la familia YOLO relevantes para la presente investigación	28
Tabla 7	Métricas de evaluación, formulación matemática e interpretación	32
Tabla 8	Comparativa técnica de los métodos de explicabilidad evaluados	34
Tabla 9	Especificaciones técnicas del dispositivo de captura Xiaomi Poco M5s.	46
Tabla 10	Resumen de distribución de instancias en el conjunto de entrenamiento.	56
Tabla 11	Especificaciones del entorno de cómputo, entrenamiento y software.	56
Tabla 12	Comparativa de complejidad arquitectónica (Número de parámetros).	57
Tabla 13	Hiperparámetros técnicos de configuración para el entrenamiento (YOLOv8).	58
Tabla 14	Comparativa de hiperparámetros entre Configuración A y Configuración B.	59
Tabla 15	Métricas de evaluación aplicadas.	60
Tabla 16	Comparativa técnica para la selección del método de explicabilidad.	63
Tabla 17	Desempeño del modelo Fase 1: YOLOv8m-seg.	74
Tabla 18	Métricas globales: YOLO11m-seg vs. YOLO11l-seg.	74
Tabla 19	Rendimiento por clase (Métrica de Máscara): YOLO11m vs. YOLO11l.	75
Tabla 20	Comparativa de eficiencia operativa.	75

Tabla 21	Ficha técnica y especificaciones detalladas del USTER TESTER 6 (Modelo UT6-S800/A)	111
Tabla 21	Ficha técnica y especificaciones detalladas del USTER TESTER 6 (Modelo UT6-S800/A)	112
Tabla 21	Ficha técnica y especificaciones detalladas del USTER TESTER 6 (Modelo UT6-S800/A)	113
Tabla 22	Cuadro comparativo de costos de infraestructura y presupuesto del prototipo .	114

ÍNDICE DE FIGURAS

Figura 1	Proceso de limpieza y lavado de la fibra de alpaca	22
Figura 2	Proceso de escarmenado y cardado de la fibra de alpaca	22
Figura 3	Muestra de hilo artesanal de alpaca	22
Figura 4	Arquitectura detallada de YOLOv8	29
Figura 5	Arquitectura detallada de YOLO11	30
Figura 6	Defecto de tipo vellosidad (<i>hairiness</i>) identificado en el hilo de alpaca Huacaya.	37
Figura 7	Defecto de tipo <i>nep</i> (mota) con morfología nodular característica.	37
Figura 8	Comparativa entre la localización mediante cajas delimitadoras y mediante máscaras.	38
Figura 9	Contraste entre el modelo de caja negra y la transparencia de la IA explicable (XAI).	42
Figura 10	Diagrama del flujo metodológico iterativo adoptado.	43
Figura 11	Muestra física de hilo de alpaca utilizada para la captura de imágenes.	45
Figura 12	Dispositivo móvil Xiaomi Poco M5s utilizado para la captura de imágenes.	46
Figura 13	Entorno de adquisición: Caja cerrada artesanal.	47
Figura 14	Entorno de adquisición: Cabina de luz de laboratorio.	48
Figura 15	Captura realizada por el investigador.	48
Figura 16	Segmento de 12-14 cm con escala métrica.	49
Figura 17	Estructura de directorios de las capturas en el equipo local.	49
Figura 18	Dataset cargado y gestionado en la plataforma Roboflow.	50
Figura 19	Ejemplo de un Nep (Clase 0) segmentado en el hilo de alpaca.	52
Figura 20	Ejemplo de Vellosidad (Clase 1) segmentada en el hilo de alpaca.	52

Figura 21	Distribución porcentual del dataset (Train, Val, Test).	54
Figura 22	Comparativa visual del efecto CLAHE sobre la muestra de fibra.	55
Figura 23	Evolución de los mapas de características bajo Grad-CAM	61
Figura 24	Visualización de la progresión de atención en diferentes niveles de la arquitectura.	63
Figura 25	Evolución técnica del proceso de anotación	65
Figura 26	Interfaz de pruebas procesando una muestra óptima.	68
Figura 27	Interfaz de pruebas identificando una densidad intermedia de defectos.	69
Figura 28	Interfaz de pruebas detectando una alta concentración de imperfecciones.	69
Figura 29	Comparativa de los entornos de adquisición evaluados para la captura de fibra de alpaca.	72
Figura 30	Gestión y organización del dataset de hilo artesanal en la plataforma Roboflow.	73
Figura 31	Conjunto de etiquetas de validación (<i>Ground Truth</i>).	76
Figura 32	Resultados de la inferencia realizada por el modelo YOLO11m-seg.	76
Figura 33	Curvas Precisión–Recall global del modelo seleccionado.	77
Figura 34	Matriz de confusión — YOLO11m-seg.	78
Figura 35	Análisis de convergencia y estabilidad del modelo seleccionado.	80
Figura 36	Ampliación de la Capa 16 (C3k2).	83
Figura 37	Auditoría de explicabilidad del modelo YOLO11m-seg en la Capa 16 (C3k2) mediante experimentos de ablación y perturbación.	85
Figura 38	Diagrama integral del proceso transformativo de fibra.	86
Figura 39	Muestra representativa del Dataset.	100
Figura 40	Póster científico presentado en Sinapsis 2025.	106
Figura 41	Carta de aprobación Comité de Bioética	107
Figura 42	Visualización integral de las activaciones en Eigen-Cam	108
Figura 43	Visualización integral de las activaciones en Grad-Cam	109

RESUMEN

En la región del Cusco, la cadena de valor de la fibra de alpaca enfrenta limitaciones competitivas debido a la falta de estandarización en el control de calidad del hilado artesanal, donde la inspección visual manual resulta subjetiva, lenta y propensa a la fatiga del operario. Frente a esta problemática, la presente investigación tuvo como objetivo principal desarrollar e implementar un sistema automatizado de control de calidad basado en visión computacional para la inspección del hilado artesanal.

Metodológicamente, se adoptó un enfoque experimental y aplicado. Se diseñó un entorno de adquisición de imágenes controlado y se consolidó un conjunto de datos propio en colaboración con el CITE Textil Camélidos Cusco, registrando defectos morfológicos como *neps* y vellosidades. Para el procesamiento e inferencia, se entrenaron y evaluaron modelos de aprendizaje profundo basados en la arquitectura YOLO (*You Only Look Once*), priorizando una alta precisión de segmentación y tiempos de respuesta aptos para entornos reales de producción.

Los resultados demuestran la viabilidad técnica del prototipo implementado, logrando clasificar y localizar anomalías con exactitud en condiciones operativas dinámicas. Se concluye que la integración de visión por computador en procesos tradicionales elimina el error por apreciación visual humana, dotando a los productores cusqueños de una herramienta tecnológica accesible que estandariza la calidad técnica y potencia su competitividad comercial.

Palabras clave: Visión computacional, Hilado artesanal, Fibra de alpaca, YOLO, Control de calidad.

ABSTRACT

In the Cusco region, the alpaca fiber value chain faces competitive limitations due to the lack of standardization in artisanal yarn quality control, where manual visual inspection is subjective, slow, and prone to operator fatigue. To address this issue, the main objective of this research was to develop and implement an automated quality control system based on computer vision for the inspection of artisanal yarn.

Methodologically, an experimental and applied approach was adopted. A controlled image acquisition environment was designed, and a proprietary dataset was consolidated in collaboration with CITE Textil Camélidos Cusco, annotating morphological defects such as *neps* and hairiness. For processing and inference, deep learning models based on the YOLO (*You Only Look Once*) architecture were trained and evaluated, prioritizing high segmentation accuracy and suitable response times for real production environments.

The results demonstrate the technical feasibility of the implemented prototype, successfully classifying and localizing anomalies with high precision under dynamic operating conditions. It is concluded that integrating computer vision into traditional processes eliminates human visual assessment errors, providing Cusco artisans with an accessible technological tool that standardizes technical quality and enhances commercial competitiveness.

Keywords: Computer vision, Artisanal spinning, Alpaca fiber, YOLO, Quality control.

INTRODUCCIÓN

La industria textil en el Perú, y particularmente en la región del Cusco, constituye un pilar fundamental tanto para la identidad cultural como para el sustento económico de diversas comunidades rurales. La fibra de alpaca, reconocida mundialmente por su finura, propiedades térmicas y resistencia, se posiciona como una de las materias primas más valiosas en el mercado internacional de lujo. No obstante, a pesar de este potencial, el sector enfrenta desafíos significativos en términos de estandarización y control de calidad, especialmente en las etapas de hilado artesanal y semi-industrial. La competitividad de los productores locales se ve frecuentemente limitada por la dificultad de garantizar productos que cumplan con los rigurosos estándares técnicos exigidos por los mercados globales.

Históricamente, el control de calidad en los procesos de hilado en Cusco ha dependido de la inspección visual manual realizada por expertos u operarios con base en su experiencia empírica. Si bien este conocimiento tradicional es invaluable, la evaluación humana es inherentemente subjetiva, propensa a la fatiga y carente de una métrica cuantitativa reproducible. Esta variabilidad en la detección de defectos, como irregularidades en el grosor, exceso de vello o presencia de impurezas, suele derivar en una producción heterogénea que incrementa los costos operativos y reduce el valor agregado de las prendas finales. Por otro lado, aunque existen soluciones tecnológicas comerciales de vanguardia para la caracterización de hilos, estas suelen ser costosas, voluminosas y diseñadas para entornos industriales de gran escala, lo que las vuelve inaccesibles para los pequeños y medianos productores de la región.

Ante este panorama, la presente investigación propone el desarrollo e implementación de un sistema de control de calidad basado en visión computacional y técnicas de aprendizaje profundo Deep Learning. Esta propuesta adopta los criterios de la norma internacional ASTM D2255 como un referente técnico comparativo, permitiendo que la evaluación automatizada guarde coherencia con los parámetros de apariencia exigidos industrialmente. La integración de arquitecturas de redes neuronales convolucionales (CNN) permite automatizar la detección

y clasificación de imperfecciones en el hilo de fibra de alpaca con una precisión superior a la observación convencional. Mediante la captura de imágenes en entornos controlados y el procesamiento digital avanzado, el sistema es capaz de analizar parámetros críticos de calidad en tiempo real, proporcionando una herramienta objetiva y accesible que optimiza el proceso de hilado artesanal.

El enfoque técnico de este trabajo se centra en el diseño de un entorno de adquisición de imágenes de alta fidelidad, la construcción de un dataset especializado de fibras de alpaca Huacaya, la evaluación de modelos de detección de objetos y segmentación para identificar fallos específicos como las vellosidades y los neps. A diferencia de los sistemas industriales cerrados, esta propuesta busca adaptarse a la realidad de los talleres locales en colaboración con entidades técnicas como el CITE Textil Camélidos Cusco, fomentando una transferencia tecnológica efectiva que potencie la innovación en el sector.

Finalmente, el alcance de esta tesis comprende desde el desarrollo algorítmico hasta la validación rigurosa de los modelos mediante métricas de rendimiento y explicabilidad. Este proceso asegura que la solución propuesta no solo sea técnicamente sólida desde la perspectiva de la inteligencia artificial, sino también funcionalmente relevante para las necesidades de los productores al permitirles contrastar su producción con estándares internacionales de calidad. Con ello, se sientan las bases para una modernización tecnológica que preserve la esencia del trabajo artesanal cusqueño, elevando su calidad hacia niveles de competitividad internacional.

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

1.1 Descripción de la situación problemática

La industria textil en el Perú, y de manera sumamente representativa en la región del Cusco, posee una relevancia económica y cultural trascendental cimentada en la producción de fibra de alpaca. Esta materia prima es valorada a nivel internacional como una de las fibras más finas y exclusivas del mercado de lujo, destacando por su suavidad, capacidad térmica y durabilidad. Cusco, consolidado históricamente como un centro neurálgico en la manufactura de textiles de alta calidad, ha visto el impacto directo de esta actividad en su economía local; recientemente, iniciativas de comercialización han permitido que aproximadamente 329 familias alpaqueras de la región logren transar 24.7 toneladas de fibra, generando ingresos directos superiores a los S/ 790,672.50 Ministerio de Desarrollo Agrario y Riego (2023).

Sin embargo, a pesar del enorme potencial que estas cifras sugieren, la industria local enfrenta desafíos críticos que comprometen su sostenibilidad y capacidad competitiva. El núcleo del problema reside en las deficiencias del control de calidad durante el proceso de hilado, el cual carece de métodos estandarizados y precisos para asegurar la excelencia del producto final. En la actualidad, la evaluación de la calidad del hilo artesanal se fundamenta casi exclusivamente en la inspección visual manual (Pereira et al., 2023). Esta práctica depende enteramente del juicio subjetivo y la experiencia empírica del operario, lo que introduce una variabilidad en la cadena productiva. Factores como el agotamiento humano, causado por la fatiga visual al fijar la mirada de manera continua sobre fibras heterogéneas (Haleem et al., 2021), facilitan que defectos técnicos, no sean identificados de manera oportuna.

Esta falta de precisión técnica tiene repercusiones que trascienden el taller artesanal. La generación de hilos con calidades heterogéneas restringe severamente la capacidad de los productores locales para acceder a mercados internacionales de alta gama, los cuales exigen estándares de uniformidad sumamente rigurosos. En última instancia, la ineficiencia en el control de calidad no solo se traduce en una pérdida de prestigio comercial, sino también en

un perjuicio económico directo para las comunidades rurales cuya subsistencia depende de la optimización de este recurso.

Por otro lado, la brecha tecnológica agrava significativamente esta situación. El estándar de la industria para la caracterización y evaluación de hilos recae en equipos de laboratorio volumétricos como el Uster Tester, cuya adquisición exige una inversión de capital superior a los S/165 000, además de demandar mantenimiento especializado e infraestructura dedicada (Haleem et al., 2021). En contraste, el sistema de visión computacional propuesto requiere una inversión total estimada en S/ 58 000 (Cálculo presupuestal determinado a partir de los Términos de Referencia (TDR) para la adquisición de componentes y materiales del proyecto, elaborados colaborativamente por el equipo de investigación con base en cotizaciones de mercado.), mediante el uso de un sensor óptico comercial y hardware integrado a un entorno estandarizado. Esta reducción de costos demuestra la viabilidad de implementar un control de calidad objetivo y automatizado sin representar una barrera económica insalvable para los productores locales.

Ante este escenario, se vuelve imperativo el desarrollo de soluciones innovadoras basadas en visión computacional que permitan automatizar la detección de defectos de forma económica, portátil y precisa. Solo mediante la integración de herramientas tecnológicas que reduzcan la subjetividad y mejoren la eficiencia del hilado artesanal, será posible proteger la reputación de los textiles cusqueños y garantizar un crecimiento económico sostenible para las familias productoras.

1.2 Formulación del problema

A partir de la caracterización de la problemática expuesta, donde se evidencia la necesidad de transitar de una inspección subjetiva hacia un monitoreo digital objetivo en la industria alpaquera, se establecen las siguientes interrogantes de investigación:

1.2.1 Problema general

¿De qué manera es posible desarrollar e implementar un sistema de visión computacional destinado al control de calidad en el proceso de hilado artesanal de fibra de alpaca?

1.2.2 Problemas específicos

- ¿Cómo se puede diseñar y construir un entorno controlado para la captura de imágenes de hilos de fibra de alpaca que garantice una iluminación, resolución y estabilidad adecuadas?
- ¿Cómo se puede crear un dataset etiquetado con imágenes de hilos de fibra de alpaca que incluya defectos comunes?
- ¿Qué algoritmos de visión computacional son los más efectivos para la detección y clasificación de defectos en hilos de fibra de alpaca?
- ¿Qué técnicas de explicabilidad son las más adecuadas para interpretar las decisiones del sistema en la detección de defectos en hilos de fibra de alpaca?

1.3 Justificación de la investigación

- **Conveniencia y relevancia industrial:** La calidad del hilo artesanal determina las propiedades finales del tejido; sin embargo, la inspección manual vigente introduce una subjetividad que limita la competitividad técnica. Esta propuesta automatiza dicho proceso, permitiendo una estandarización rigurosa que optimiza la cadena productiva y garantiza productos de alta gama aptos para mercados globales.
- **Relevancia social y económica:** Dado que la camélido-cultura es el sustento de numerosas familias rurales en la región, este sistema actúa como una herramienta de democratización tecnológica. Al elevar el valor agregado del hilo artesanal, se facilita la inserción de los pequeños productores en mercados competitivos, mejorando sus utilidades y fomentando la inclusión digital mediante la tecnificación de saberes ancestrales.
- **Implicaciones prácticas e innovación:** Existe una necesidad crítica de soluciones accesibles, pues equipos industriales como el sistema USTER resultan de difícil acceso por su alto costo y dimensiones. Esta investigación justifica el desarrollo de una alternativa portátil y no invasiva que utiliza hardware comercial para realizar análisis en tiempo real,

ofreciendo una solución técnica adaptada a la realidad operativa de los talleres locales en Cusco.

- **Valor teórico y tecnológico:** El estudio contribuye al avance de la inteligencia artificial aplicada al sector textil artesanal. Mediante el uso de arquitecturas de vanguardia como YOLOv11 y técnicas de explicabilidad (XAI), se establece un precedente científico para la digitalización de fibras naturales, generando una base sólida para futuras investigaciones en la automatización de procesos industriales complejos.

1.4 Objetivos de la investigación

En correspondencia con la problemática identificada, la investigación se orienta al cumplimiento de las siguientes metas técnicas y científicas:

1.4.1 *Objetivo general*

Desarrollar e implementar un sistema de visión computacional para el control de calidad en el proceso de hilado artesanal de fibra de alpaca, con el propósito de automatizar la detección de defectos y reducir la subjetividad en la producción artesanal.

1.4.2 *Objetivos específicos*

- Diseñar y construir un entorno controlado para la captura de imágenes de hilos de fibra de alpaca, optimizando factores de iluminación, resolución y estabilidad para asegurar la calidad y fidelidad de los datos de entrada.
- Crear un dataset etiquetado con imágenes de hilos de fibra de alpaca que contemple los defectos técnicos más recurrentes y representativos del proceso de hilatura.
- Evaluar y seleccionar los algoritmos de visión computacional más efectivos para la detección y clasificación automática de imperfecciones en el hilo de alpaca.
- Implementar técnicas de explicabilidad que permitan interpretar las decisiones del sistema en la detección de defectos, garantizando que los resultados sean comprensibles y

confiables.

1.5 Alcances y Limitaciones de la investigación

Para garantizar la viabilidad técnica y el rigor científico del estudio, se establecen las fronteras que definen el alcance temático, técnico y geográfico del sistema de visión computacional propuesto. Esta sección detalla los parámetros específicos que potencian la investigación, así como las restricciones operativas que reconocen los desafíos inherentes al entorno de aplicación artesanal.

1.5.1 Alcances

La investigación se circunscribe a parámetros técnicos y operativos cuidadosamente seleccionados para asegurar un enfoque especializado en las necesidades del sector textil de la región del Cusco:

- **Estandarización del material (Titulación 5):** El sistema se enfoca exclusivamente en hilos de titulación 5. Esta elección estratégica responde a que los procesos de cardado están configurados para alcanzar este grosor específico, lo que permite estandarizar la adquisición de datos y centrar el análisis algorítmico en parámetros consistentes, reduciendo el ruido visual derivado de la variabilidad de diámetros.
- **Selección de la materia prima (Fibra de Alpaca Huacaya):** El proyecto se restringe a la fibra de la raza Huacaya CITE Camélidos Sudamericanos (2021). Se selecciona esta variedad por su alta disponibilidad regional y sus propiedades físicas finura, suavidad y rizado, factores que presentan una morfología visual homogénea que permite reducir la varianza en la captura de datos. Esta selección actúa como un control de variables que evita la dispersión analítica que implicaría el uso de múltiples especies con estructuras de fibra heterogéneas, centrando el modelo en la detección de defectos estructurales.
- **Calidad de la fibra analizada (Calidad Baby):** El sistema se especializa en el análisis de fibra de calidad Baby, la cual presenta un diámetro situado entre 20.1 y 23 micras CITE

Camélidos Sudamericanos (2021). Esta categoría representa el estándar de excelencia para prendas de alta sensibilidad y es uno de los segmentos más exigentes para el control de calidad en el hilado artesanal. Al focalizar el estudio en esta finura específica, se garantiza una mayor precisión en el entrenamiento de los modelos para detectar defectos críticos en fibras de alto valor comercial.

- **Detección de imperfecciones críticas:** El sistema se especializa en la identificación y clasificación de dos fallos técnicos fundamentales que comprometen la calidad estética y la integridad estructural del hilado:
 - *Vellosidad*: Se enfoca en la detección de fibras cortas que sobresalen del núcleo del hilo, factor crítico que origina el efecto *pilling* (formación de bolitas) en las prendas terminadas, lo cual degrada significativamente su apariencia y durabilidad.
 - *Neps*: Identificación de pequeñas aglomeraciones o enredos de fibras que se manifiestan como nudos o puntos en la superficie del hilo, afectando tanto la suavidad al tacto como la uniformidad visual de la prenda.
- **Selección cromática y versatilidad (Fibra Blanca):** La investigación se centrará exclusivamente en el análisis de fibra de color blanco. Esta delimitación responde a recomendaciones técnicas de expertos en camélidos, quienes señalan que la fibra blanca posee la mayor versatilidad en la industria textil debido a su capacidad para ser teñida en cualquier tonalidad posterior. Desde la perspectiva de la visión computacional, el uso de fibra blanca permite estandarizar los niveles de contraste y reflectancia en la captura de imágenes, facilitando una identificación más precisa de la vellosidad y los neps al reducir las interferencias visuales propias de las fibras con pigmentación natural oscura.
- **Arquitecturas de Aprendizaje Profundo:** La investigación se centra en el uso de las CNN, priorizando específicamente la familia de modelos YOLO (*You Only Look Once*) Pereira et al. (2023). Esta selección técnica se fundamenta en la alta efectividad y velocidad reportada en la literatura científica para el procesamiento de imágenes en tiempo real. La implementación de estos modelos permite alcanzar un equilibrio óptimo entre la precisión en la detección de defectos y la eficiencia computacional, facilitando la ejecución

del sistema en dispositivos basados en visión computacional y asegurando su futura portabilidad a entornos de producción locales Pereira et al. (2023).

- **Validación técnica por expertos y Dataset Gold Standard:** Para garantizar que la detección automatizada posea una base técnica irrefutable, el proceso de validación se sustenta en la creación y uso de un dataset de referencia denominado *Gold Standard*. Este recurso ha sido consolidado bajo la supervisión y criterio de una experta con amplia trayectoria y vinculación técnica con el CITE Textil Camélidos Cusco. Su participación activa permitió obtener un etiquetado de buena precisión para las categorías de vellosidad y neps, asegurando que el entrenamiento y la validación del sistema de visión computacional se alineen estrictamente con los estándares de calidad vigentes en la industria.
- **Los criterios de severidad definidos en la norma ASTM D2255:** Se emplean en esta investigación como un marco de referencia para la evaluación de la calidad del hilo. Es preciso señalar que el sistema de visión computacional no realiza una clasificación automática de grados; en su lugar, actúa como una herramienta de diagnóstico que proporciona métricas objetivas, tales como el conteo de neps y la densidad de vellosidad, las cuales permiten comparar el producto final contra los estándares de calidad comercial establecidos por dicha normativa.
- **Formalización y nivel de madurez del sistema:** El sistema desarrollado se formaliza como un sistema de software a nivel de prototipo funcional enfocado en la inspección de calidad textil. El sistema abarca cuatro subsistemas lógicos integrados: (a) *Subsistema de adquisición Digital* (captura e ingesta de imágenes en entorno controlado), (b) *Subsistema de inferencia y visión Computacional* (procesamiento e identificación multiclase), (c) *Subsistema de clasificación* (cuantificación de defectos y veredicto de calidad según parámetros de tolerancia), y (d) *Subsistema de interfaz y reporte* (interacción con el usuario y visualización de máscaras).
- **Ámbito geográfico, social y procedencia de la fibra:** La investigación se localiza geográficamente en la región del Cusco, Perú. La materia prima utilizada para la generación del *dataset* y las pruebas experimentales proviene directamente de la comunidad de Ocon-

gate, provincia de Quispicanchis, suministrada por pequeños productores dedicados a la crianza de alpacas. El proceso de captura de imágenes y la validación técnica se desarrollan en las instalaciones del CITE Textil Camélidos Cusco, bajo un entorno de laboratorio y semi-industrial. Esta delimitación social es clave, ya que el proyecto busca beneficiar al eslabón más vulnerable de la cadena productiva, el pequeño productor, proporcionando una solución tecnológica escalable a su realidad y capacidad operativa, excluyendo de este alcance la implementación o pruebas en plantas industriales de gran escala.

1.5.2 Limitaciones

Se reconocen factores restrictivos que definen la frontera del desempeño del sistema y los desafíos del entorno real:

- **Dependencia de la calidad de adquisición:** El rendimiento de los modelos de detección está condicionado por la relación señal-ruido en la captura de imágenes. Se ha identificado que la elección de un fondo específico es crítica para minimizar las interferencias visuales y permitir una segmentación adecuada del hilo. No obstante, la presencia de ruido derivado de texturas de fondo inadecuadas o fluctuaciones imprevistas en la iluminación ambiental representan una limitación persistente. Estas variaciones técnicas dificultan el aislamiento preciso de las fibras de alpaca y pueden comprometer la capacidad del sistema para distinguir con claridad los defectos sutiles del ruido de fondo.
- **Variabilidad biológica de la fibra:** Una limitación crítica del estudio radica en la imposibilidad de controlar los factores pre-productivos que definen las propiedades físicas de la fibra de alpaca. Aspectos como el estado de salud del animal, su régimen nutricional, la edad al momento de la esquila y las condiciones climatológicas predominantes durante el crecimiento del vellón introducen una variabilidad natural significativa. Estas inconsistencias biológicas afectan la morfología y el comportamiento visual de la fibra, lo que representa un desafío para la generalización absoluta del modelo, ya que son variables externas que escapan al control técnico del investigador y dificultan un modelado matemático completamente uniforme.

- **Detección de defectos sutiles:** Existe una limitación intrínseca en la sensibilidad del sistema para identificar imperfecciones de escala microscópica o variaciones submilimétricas en la estructura del hilo. Esta restricción técnica surge de la combinación entre la resolución espacial del sensor óptico y la capacidad de extracción de características de los algoritmos de aprendizaje profundo. En consecuencia, defectos extremadamente sutiles, como neps diminutos o vellosidades incipientes, podrían no ser detectados con la nitidez necesaria, lo que establece un límite en la precisión global del sistema ante anomalías de mínima magnitud.
- **Validación restringida al entorno de software:** Los resultados referentes a la velocidad de procesamiento y latencia del sistema se basan exclusivamente en evaluaciones realizadas en un entorno de ejecución computacional controlado. Al no haberse efectuado la integración física con maquinaria industrial o sistemas embebidos de hardware final, los tiempos de respuesta obtenidos representan una estimación del desempeño algorítmico y no necesariamente reflejan el comportamiento del sistema en una línea de producción mecánica. Por lo tanto, la operatividad en tiempo real queda sujeta a la capacidad de cómputo del hardware donde se despliegue el modelo y a las restricciones de sincronización que surjan en futuras fases de implementación física.
- **Accesibilidad de hardware:** El desarrollo y la optimización de los modelos de aprendizaje profundo estuvieron condicionados por la capacidad de procesamiento del servidor disponible para la fase experimental. Al contar con recursos de cómputo de prestaciones intermedias, los tiempos requeridos para completar los ciclos de entrenamiento y ajuste de hiperparámetros fueron prolongados. Esta restricción técnica limitó la velocidad de iteración en la fase de experimentación, lo que implica que el rendimiento del modelo actual está supeditado a las capacidades del hardware empleado.
- **Restricción en la dimensión y representatividad del dataset:** La capacidad de generalización de los modelos de aprendizaje profundo depende directamente de la magnitud y diversidad del dataset de entrenamiento. En este estudio, el volumen de datos estuvo limitado por la complejidad técnica de la adquisición de imágenes nítidas, resultando en

una selección final de 500 muestras óptimas a partir de un registro inicial de 700 capturas. Esta reducción, necesaria para garantizar la calidad del entrenamiento, representa una limitación en la diversidad de ejemplos de vellosidad y neps analizados. En consecuencia, la robustez del sistema podría verse afectada ante anomalías poco frecuentes o variaciones estructurales del hilo que no hayan sido capturadas suficientemente en la muestra actual.

- **Limitación por instrumentación de captura no especializada:** La adquisición de datos se realizó utilizando el sensor óptico de un dispositivo móvil comercial (Xiaomi Poco M5s), el cual, a diferencia de las cámaras de visión industrial especializadas, posee limitaciones en cuanto a la profundidad de campo y la fidelidad de los píxeles. El procesamiento interno automático del dispositivo (como la reducción de ruido y el enfoque dinámico) puede introducir artefactos o suavizar detalles microscópicos de la fibra, lo que representa una restricción para la captura de características extremadamente finas. En consecuencia, la calidad de las imágenes obtenidas podría influir en la precisión del modelo al intentar discriminar imperfecciones cuya escala sea cercana al límite de resolución del sensor empleado.
- **Subjetividad en el etiquetado:** El proceso de anotación de las imágenes fue realizado directamente por el investigador, quien, a pesar de haber recibido capacitación técnica por parte de expertos en hilatura del CITE Textil Camélidos Cusco, no posee la vasta experiencia empírica de un maestro clasificador. Esta diferencia en el nivel de especialización introduce un riesgo de subjetividad o sesgo de interpretación durante la construcción del *dataset*, lo que podría derivar en inconsistencias al definir los límites exactos de una vellosidad o la magnitud de un nep. En consecuencia, el modelo de aprendizaje automático está supeditado a estos criterios de evaluación, lo que establece una frontera en la precisión absoluta del sistema al depender de un juicio humano en proceso de especialización técnica.

CAPÍTULO II

MARCO TEÓRICO CONCEPTUAL

2.1 Antecedentes

2.1.1 *Antecedentes internacionales*

Sistema inteligente de visión por computador para el análisis y caracterización de la calidad del hilo

- **Contexto del estudio:** La investigación desarrollada por Pereira et al. (2023) constituye una de las propuestas más recientes y robustas en la automatización del control de calidad textil mediante visión computacional. El estudio se centra en la superación de las limitaciones operativas de los equipos comerciales tradicionales, tales como el sistema USTER Tester, los cuales presentan restricciones críticas en cuanto a costos elevados, dimensiones físicas considerables y una capacidad analítica limitada a estándares de masa predefinidos Pereira et al. (2023).
- **Descripción técnica y analítica:** El valor técnico del trabajo reside en el diseño de un prototipo mecatrónico de bajo costo, que integra hardware de captura de alta velocidad, específicamente cámaras CMOS de alta resolución, con un flujo de procesamiento digital avanzado Pereira et al. (2023). Los autores implementaron un *pipeline* de visión que incluye segmentación de la unidad de diámetro del hilo (DIPU), proyecciones de nivel de gris y el método de *Poisson Matting* para una efectiva separación entre el núcleo del hilo y las fibras sueltas Pereira et al. (2023). Cabe destacar la integración de algoritmos de inteligencia artificial para la clasificación en tiempo real, logrando una correlación estadística validada con equipos industriales y un rendimiento de procesamiento de 45.45 FPS, demostrando que la visión artificial puede equiparar la fiabilidad de sensores ópticos industriales Pereira et al. (2023).
- **Limitaciones o vacíos:** A pesar de la innovación en el procesamiento de imágenes, el

estudio presenta brechas analíticas significativas al contrastarlo con las necesidades de fibras naturales:

1. *Entorno de Validación:* Los experimentos se realizaron bajo condiciones de laboratorio (cajas cerradas e iluminación artificial controlada), lo cual limita la capacidad de generalización del modelo ante el ruido, las vibraciones y la iluminación fluctuante inherentes a entornos de producción real Pereira et al. (2023).
 2. *Variabilidad Morfológica y Complejidad Estructural:* La metodología propuesta por Pereira et al. (2023) fue validada mediante el uso de fibras sintéticas y algodón, materiales que exhiben una homogeneidad geométrica superior a la de la fibra de alpaca. La arquitectura de detección del modelo citado asume una predictibilidad estructural que no se corresponde con las particularidades biológicas de la alpaca Huacaya. Factores como la medulación, la fluctuación aleatoria en el diámetro y la presencia de impurezas naturales introducen un nivel de complejidad morfológica que el algoritmo original, optimizado para fibras uniformes, no logra procesar con la precisión requerida Pereira et al. (2023).
-
- **Conexión con la investigación:** El presente estudio se constituye como la base tecnológica para nuestra tesis. Si bien Pereira et al. (2023) demuestran la viabilidad de sustituir equipos industriales costosos por sistemas basados en visión artificial, nuestra investigación extiende este paradigma adaptando los modelos de segmentación y detección para enfrentar la complejidad morfológica específica de la fibra de alpaca Huacaya. La diferencia fundamental reside en la robustez del modelo: mientras el antecedente busca la estandarización en entornos controlados, nosotros planteamos una solución diseñada para las condiciones operativas de la industria artesanal, optimizando la arquitectura de red para detectar anomalías específicas de las fibras naturales de los Andes peruanos.

Nuevo método para evaluar la apariencia del hilo basado en visión artificial y procesamiento de imágenes

- **Contexto del estudio:** El estudio realizado por Li et al. (2020) aborda la necesidad crítica de la industria textil por obtener mediciones precisas, rápidas y flexibles del diámetro del hilo, la vellosidad y los defectos, superando las deficiencias de los métodos tradicionales de capacitancia y microscopía biológica. Esta investigación es fundamental ya que establece una metodología para la extracción automática de parámetros de calidad sin intervención manual, utilizando sensores de imagen de alta resolución y algoritmos de procesamiento digital Li et al. (2020).
- **Descripción técnica y analítica:** La innovación central de este trabajo reside en la definición de la Unidad de Procesamiento de Imagen de Diámetro (DIPU), que permite promediar el diámetro en segmentos específicos (de 2 a 8 mm) para reducir el impacto de factores aleatorios y la incertidumbre en la forma del hilo Li et al. (2020). Metodológicamente, los autores proponen un flujo de segmentación avanzado donde el hilo se divide en regiones de primer plano definido, fondo definido y una región desconocida, la cual es procesada mediante el método de *Poisson matting* Li et al. (2020). Esta técnica permite separar completamente la imagen del hilo del fondo mediante un clasificador de conectividad, facilitando la extracción del núcleo del hilo y la posterior cuantificación de la vellosidad mediante sustracción de imágenes Li et al. (2020). El sistema demostró una alta precisión al ser contrastado con el Uster Tester, evidenciando que la visión artificial ofrece una mayor robustez frente a variaciones de humedad y tensión que los métodos capacitivos Li et al. (2020).
- **Limitaciones o vacíos:** A pesar de su eficacia en la segmentación estructural, la investigación presenta limitaciones metodológicas que nuestra tesis busca resolver:
 1. *Dependencia de Algoritmos Heurísticos:* El uso de *Poisson matting* y clasificadores de conectividad depende de umbrales y condiciones de contorno predefinidas, lo que puede resultar rígido ante fibras con variaciones morfológicas extremas o entornos con ruido óptico no controlado Li et al. (2020).

2. *Falta de Aprendizaje de Características*: El enfoque se basa en el procesamiento de imágenes convencional y no incorpora técnicas de aprendizaje profundo (*Deep Learning*). Esto limita la capacidad del sistema para aprender y generalizar la detección de defectos complejos o sutiles que no sigan un patrón, especialmente en fibras naturales como la alpaca Li et al. (2020).

- **Conexión con la investigación:** Este antecedente es vital para justificar la transición de métodos de procesamiento de imágenes clásicos hacia arquitecturas de aprendizaje profundo como YOLO. Mientras que Li et al. (2020) demuestra la importancia de aislar el núcleo del hilo para una medición precisa, nuestra investigación propone evolucionar esta separación mediante CNNs. Esto permitirá una detección de defectos más resiliente y autónoma, eliminando la necesidad de algoritmos de *matting* manuales y adaptando la inspección a la naturaleza estocástica y compleja de la fibra de alpaca Huacaya en entornos artesanales del Cusco.

Sistema de control de calidad en línea basado en visión computacional para hilos textiles

- **Contexto del estudio:** El estudio de Haleem et al. (2021) es un referente crítico en cuanto a la necesidad operativa de la industria textil por transitar hacia sistemas de monitoreo *online*. Identifican que la latencia en el control de calidad es el principal obstáculo para la eficiencia productiva, proponiendo que la visión computacional es la herramienta clave para cerrar esta brecha Haleem et al. (2021).
- **Descripción técnica y analítica:** Los autores validan la eficacia de los sensores ópticos para operar en condiciones dinámicas, utilizando el algoritmo de Viola-Jones para la detección específica de *neps* en hilos en movimiento Haleem et al. (2021). Este trabajo es valioso porque cuantifica la viabilidad de procesar información visual a velocidades industriales sin comprometer la precisión de la detección de defectos superficiales Haleem et al. (2021).
- **Limitaciones o vacíos:** El trabajo presenta una dependencia crítica de una infraestructura de hardware altamente especializada y costosa, lo que limita su aplicabilidad en entornos

de pequeña y mediana escala Haleem et al. (2021). Asimismo, el paradigma algorítmico utilizado (Viola-Jones) es rígido y carece de la capacidad de aprendizaje multiclase que ofrecen las CNNs modernas para procesar materiales biológicos complejos Haleem et al. (2021).

- **Conexión con la investigación:** Aunque la presente tesis no contempla el desarrollo de hardware industrial, el trabajo de Haleem et al. (2021) proporciona la base teórica que justifica el uso de la arquitectura YOLO en nuestra propuesta. El enfoque de esta investigación se centra en la **capacidad computacional y algorítmica** del sistema: mientras que Haleem et al. (2021) prioriza el entorno físico de detección, nosotros resolvemos la complejidad del análisis multiclase (vellosidad y *neps*) en fibra de alpaca Huacaya. Esto permite que el software desarrollado sea lo suficientemente ligero y potente para ser integrado en el futuro en hardware de bajo costo o sistemas móviles, cubriendo el vacío de accesibilidad tecnológica.

Medición automática de la vellosidad del hilo basada en el algoritmo de segmentación MRMRF mejorado

- **Contexto del estudio:** La investigación desarrollada por Jing et al. (2018) aborda uno de los problemas más persistentes en el control de calidad textil: la medición precisa de la vellosidad del hilo. Los autores explican que la vellosidad, definida como el conjunto de fibras que sobresalen del cuerpo principal del hilo, afecta directamente la apariencia, el tacto y la resistencia de las telas finales Jing et al. (2018). El estudio surge porque los métodos tradicionales (ópticos o de capacitancia) tienen dificultades para detectar fibras muy delgadas o se ven afectados por el ruido en las imágenes Jing et al. (2018).
- **Descripción técnica:** Los autores proponen un método basado en un algoritmo avanzado llamado Campo Aleatorio de Markov Multirresolución (MRMRF) mejorado Jing et al. (2018). Esta tecnología analiza la imagen del hilo en diferentes niveles de detalle o resoluciones, lo que permite separar con gran exactitud qué parte de la imagen es el núcleo del hilo y qué parte son las fibras sueltas (vellosidad) Jing et al. (2018). El sistema utiliza técnicas de procesamiento digital para limpiar las imágenes de interferencias y

luego aplica el algoritmo para contar y medir la longitud de cada fibra que sobresale Jing et al. (2018). Los resultados demostraron que este método es mucho más robusto y exacto que los sistemas de inspección manual o los sensores industriales convencionales, logrando una segmentación clara incluso en condiciones de baja visibilidad Jing et al. (2018).

- **Limitaciones o vacíos :** A pesar de su alta precisión matemática, el estudio presenta limitaciones importantes para el contexto de esta tesis:

1. *Ausencia de normas para el hilado artesanal:* Al igual que en investigaciones anteriores, este trabajo se apoya en estándares industriales generales. Sin embargo, no existen normas técnicas oficiales que regulen la vellosidad permitida en el hilado artesanal de alpaca, lo que obliga al artesano a trabajar sin un marco de referencia claro sobre qué tanta vellosidad es aceptable para un producto de lujo Jing et al. (2018).
2. *Complejidad Computacional:* El algoritmo MRMRF requiere una capacidad de procesamiento muy alta y tiempos de cálculo prolongados, lo que dificulta su uso en dispositivos sencillos o para un monitoreo rápido en tiempo real dentro de un taller pequeño Jing et al. (2018).
3. *Materiales estándar:* El sistema fue probado con hilos comunes, sin considerar la naturaleza estocástica y la alta variabilidad de la fibra de alpaca Huacaya, que es mucho más compleja de segmentar que el algodón o los hilos sintéticos Jing et al. (2018).

- **Conexión con la investigación:** Este antecedente es fundamental porque proporciona la lógica necesaria para entender cómo se debe separar la vellosidad del cuerpo del hilo. Debido a que no hay normas que controlen el hilado artesanal, esta tesis toma los principios de segmentación descritos por Jing et al. (2018) como una base técnica para definir los defectos que el sistema debe reconocer. A diferencia de este estudio, nuestra propuesta utiliza la arquitectura YOLO, que es mucho más rápida y eficiente para el procesamiento en tiempo real, permitiendo que el artesano de Cusco cuente con una

herramienta de control de calidad moderna que se adapte a las irregularidades propias de la fibra de alpaca.

2.1.2 Antecedentes nacionales

Finura al hilado y características de la fibra de alpaca Huacaya blanca de la zona norte región Puno 2019

- **Contexto del estudio:** La investigación realizada por Castillo Yepes et al. (2022) constituye un referente esencial a nivel nacional para comprender la relación entre las propiedades intrínsecas de la fibra de alpaca y su desempeño en el procesamiento textil. El estudio se enfoca en la caracterización técnica de la fibra de alpaca Huacaya blanca, estableciendo la línea base necesaria para gestionar la calidad en la cadena de valor de los camélidos sudamericanos en el sur del Perú Castillo Yepes et al. (2022).
- **Descripción técnica y analítica:** El trabajo aborda el problema de la falta de datos técnicos precisos sobre cómo la finura y otras características físicas de la fibra afectan la calidad del hilado final Castillo Yepes et al. (2022). Utilizando un enfoque descriptivo y correlacional, los autores analizaron muestras de fibra mediante equipos de laboratorio especializados para medir el diámetro de fibra (DF), el coeficiente de variación (CVDF) y el factor de confort (FC) Castillo Yepes et al. (2022). Los resultados determinaron que la selección rigurosa de la materia prima es determinante para alcanzar estándares de exportación, estableciendo correlaciones significativas entre la finura al hilado y la uniformidad del producto textil final. El valor analítico de esta fuente reside en que cuantifica los parámetros que definen un hilo de alta calidad desde una perspectiva biológica y textil Castillo Yepes et al. (2022).
- **Limitaciones o vacíos:** A pesar de su profundidad en el análisis de laboratorio, el estudio presenta vacíos críticos para la modernización del sector:
 1. *Ausencia de Automatización:* El estudio se limita al análisis estadístico *a posteriori* en laboratorio, sin proponer herramientas tecnológicas que permitan un monitoreo constante o automatizado durante la fase de hilatura Castillo Yepes et al. (2022).

2. *Persistencia de Métodos Tradicionales*: Se reconoce que, en la práctica regional, el control de calidad sigue dependiendo del juicio visual humano, el cual es propenso a errores que el análisis de laboratorio tradicional no puede corregir en tiempo real Castillo Yepes et al. (2022).

3. *Falta de Integración de IA*: No se contempla el uso de visión computacional ni aprendizaje profundo para la detección de defectos estructurales (como neps o vellosidad) durante el procesamiento, centrándose exclusivamente en las propiedades físicas pre-procesamiento Castillo Yepes et al. (2022).

- **Conexión con la investigación**: Este antecedente nacional valida científicamente los parámetros de calidad (finura y uniformidad) que nuestro sistema de visión computacional busca preservar. Mientras que Castillo Yepes et al. (2022) definen los requerimientos físicos ideales para un hilo competitivo, nuestra tesis propone la solución tecnológica para automatizar la vigilancia de estos estándares mediante modelos YOLO. De esta manera, nuestra investigación cierra la brecha entre el conocimiento técnico de laboratorio y la aplicación práctica en el taller artesanal, proporcionando una herramienta de monitoreo objetivo que sustituye la inspección manual mencionada como limitación en el contexto local.

2.1.3 Síntesis de los antecedentes y contribución de la investigación

El análisis de los antecedentes internacionales y nacionales permite identificar una clara evolución en el control de calidad textil, pasando de la inspección visual humana y el uso de equipos industriales costosos hacia el desarrollo de sistemas basados en visión computacional. Las investigaciones previas han validado que es posible medir parámetros críticos como el diámetro, la vellosidad y la presencia de defectos mediante el procesamiento digital de imágenes, utilizando técnicas que van desde la matemática clásica y algoritmos heurísticos hasta modelos de inteligencia artificial para la detección en tiempo real.

Sin embargo, tras la revisión del estado del arte, se han identificado brechas tecnológicas importantes que justifican la realización de la presente tesis:

- **Limitaciones en la naturaleza de la fibra:** La gran mayoría de los sistemas desarrollados a nivel internacional han sido entrenados y validados con fibras altamente homogéneas como el algodón o materiales sintéticos. Estos modelos presentan dificultades al enfrentarse a la fibra de alpaca Huacaya, la cual posee una complejidad estructural y biológica superior, con variaciones aleatorias en su diámetro que los algoritmos tradicionales no logran procesar con precisión.
- **Dependencia de hardware y entornos controlados:** Muchos de los sistemas propuestos requieren infraestructuras de hardware complejas, cámaras de laboratorio o condiciones de iluminación artificial muy estrictas. Esto limita su aplicación en entornos de producción real, especialmente en talleres donde el espacio y los recursos para implementar maquinaria industrial de alta gama son limitados.
- **Rigidez de los algoritmos clásicos:** El uso de métodos de procesamiento de imágenes convencionales suele depender de umbrales fijos y reglas predefinidas. Estos métodos carecen de la capacidad de aprendizaje y generalización necesaria para detectar defectos en un material tan variable como la alpaca, donde las fallas no siempre siguen un patrón visual exacto.

En respuesta a estas limitaciones, esta investigación propone un cambio de paradigma hacia el uso de arquitecturas de aprendizaje profundo, específicamente el modelo YOLO. A diferencia de los antecedentes que se centran en la segmentación matemática manual o en el hardware industrial pesado, este trabajo se enfoca en la capacidad del software para aprender las características intrínsecas de la fibra de alpaca. Al proponer un sistema basado en redes neuronales, se busca ofrecer una solución que sea lo suficientemente robusta para detectar anomalías de manera autónoma y rápida, adaptándose a las condiciones reales del hilado artesanal en la región del Cusco y cerrando la brecha entre la teoría científica y la práctica productiva local.

2.2 Bases Teóricas

Las bases teóricas se articulan en cinco áreas de conocimiento que proveen el sustento técnico del sistema de visión computacional propuesto. La primera establece el dominio de aplicación y la taxonomía de defectos a detectar. Las restantes cuatro abordan, progresivamente, los fundamentos algorítmicos, arquitectónicos, métricos y de interpretabilidad que estructuran la solución de ingeniería.

2.2.1 Fibra de alpaca Huacaya y defectos de hilado artesanal

Relevancia económica y dominio de aplicación

La alpaca (*Vicugna pacos*) es el animal productor de fibra de mayor relevancia en los Andes peruanos, con una distribución geográfica concentrada entre los 3.800 y 5.000 msnm CITE Camélidos Sudamericanos (2021). La raza Huacaya produce un vellón esponjoso cuya fibra fina la posiciona en el segmento *ultra-premium* del mercado textil internacional. En la región del Cusco, iniciativas recientes de comercialización directa involucraron a 329 familias criadoras, generando ingresos superiores a S/ 790.672,50 por la transacción de 24,7 toneladas de fibra (Ministerio de Desarrollo Agrario y Riego, 2023). Esta relevancia económica hace del control de calidad del hilado artesanal una condición necesaria, no marginal, para el acceso a mercados de alta exigencia técnica. Tabla 1

Tabla 1
Categorías comerciales de la fibra de alpaca Huacaya según el diámetro medio de fibra (MFD)

Categoría	MFD (μm)	FC típico (%)	Aplicación
Baby Plus	$\leq 20,0$	> 98	Prendas de alta gama
Baby	$20,1 - 23,0$	> 95	Dominio de este estudio
Fleece	$23,1 - 26,5$	> 90	Prendas de uso general
Medium	$26,6 - 29,0$	> 85	Ropa exterior
Huarizo	$> 29,0$	< 80	Uso industrial

Fuente: Adaptado de CITE Camélidos Sudamericanos (2021).

Parámetros físicos de calidad

La calidad del hilo artesanal se cuantifica mediante parámetros físicos normalizados por la NTP 231.301.2014. Los más relevantes para la detección computacional son:

- **Coefficiente de variación del diámetro (CV_{DF}).** Cuantifica la dispersión relativa de los diámetros individuales respecto a la media:

$$CV_{DF} = \frac{\sigma_{DF}}{\overline{DF}} \times 100 \quad (2.1)$$

Un CV_{DF} elevado predice mayor densidad de irregularidades de sección transversal, puntos gruesos (*thick places*) y delgados (*thin places*), detectables mediante análisis de imagen. En el sistema propuesto, un CV_{DF} alto se correlaciona con mayor frecuencia de ocurrencias de *neps* en el dataset, condicionando la estrategia de muestreo durante el entrenamiento (Castillo Yepes et al., 2022).

- **Factor de confort (FC).** Expresa la proporción de fibras con diámetro inferior a $30 \mu m$, umbral a partir del cual las fibras generan picazón en la piel:

$$FC = P(DF_i < 30 \mu m) \times 100 \% \quad (2.2)$$

Proceso de hilado artesanal como fuente de defectos

El proceso de transformación de fibra en hilo sigue una cadena de etapas secuenciales. Cada etapa es fuente potencial de un defecto con morfología visual específica y detectable por visión computacional.

Los procesos de limpieza y lavado se ilustran en la Figura 1; el escarmenado y cardado, en la Figura 2; y una muestra del hilo artesanal resultante, en la Figura 3.

Figura 1

Proceso de limpieza y lavado de la fibra de alpaca

Limpieza de fibra cruda



Secado de fibra de alpaca



Figura 2

Proceso de escarmenado y cardado de la fibra de alpaca

Escarmenado manual



Cardado manual



Figura 3

Muestra de hilo artesanal de alpaca



Estándares de evaluación de calidad en hilos: Norma ASTM D2255

La evaluación de la calidad en hilos hilados requiere de criterios objetivos que permitan la estandarización de la apariencia textil. La norma ASTM D2255, *Standard Test Method for Grading Spun Yarns for Appearance*, constituye el referente técnico internacional para la gradación de hilos hilados mediante el análisis visual comparativo ASTM International (2017). El fundamento de esta evaluación reside en la caracterización de defectos superficiales y estructurales que afectan la calidad comercial del hilado ASTM International (2017).

Criterios de evaluación y clasificación

La gradación de un hilo se determina mediante la evaluación compuesta de factores morfológicos específicos: la uniformidad (*unevenness*), la presencia de vellosidad (*fuzziness*) y la cantidad de neps (*neppiness*) ASTM International (2017). La norma establece una jerarquía de grados que permite cuantificar la severidad de las irregularidades presentes en la estructura del hilo ASTM International (2017).

- **Neps:** Aglomeraciones de fibras entrelazadas que, dependiendo de su tamaño y cantidad, determinan la degradación del grado de calidad. Los neps que exceden tres veces el diámetro normal del hilo son considerados defectos críticos ASTM International (2017).
- **Vellosidad:** Protrusiones de fibras fuera del cuerpo principal del hilo. Un exceso de vellosidad se asocia directamente con una apariencia rugosa y una disminución en la calidad estética y funcional ASTM International (2017).

La clasificación técnica establecida por la norma define cuatro grados principales, los cuales sirven como base para la categorización industrial, tal como se detalla en la Tabla 2.

Tabla 2

Criterios de gradación y clasificación de hilos según ASTM D2255.

Grado	Características de la Apariencia
Grado A	Uniformidad excepcional; ausencia de neps grandes y vellosidad excesiva. No contiene materia extraña.
Grado B	Buena uniformidad; presencia escasa de neps pequeños. Puede presentar una vellosidad ligeramente mayor al Grado A.
Grado C	Presencia incrementada de neps y mayor vellosidad. El contraste entre zonas gruesas y delgadas es más pronunciado que en el Grado B.
Grado D	Presencia de slubs (nudos) de gran tamaño y elevada densidad de neps. Presenta una apariencia general rugosa e irregular.

Fuente: Basada en criterios de la norma ASTM International (2017).

2.2.2 Visión computacional y procesamiento digital de imágenes

Representación matemática de la imagen digital

La visión computacional dota a los sistemas computacionales de la capacidad de adquirir, interpretar y comprender información visual del mundo físico (Gonzalez and Woods, 2018). Formalmente, una imagen digital en escala de grises se modela como $f : \mathbb{Z}^2 \rightarrow \{0, \dots, 2^B - 1\}$, donde $f(x, y)$ es la intensidad en la posición (x, y) y B es la profundidad de bits ($B = 8$ para 256 niveles). En imágenes RGB la función se extiende a tres canales: $f(x, y) = [R(x, y), G(x, y), B(x, y)]^T$ (Gonzalez and Woods, 2018).

Preprocesamiento de imágenes

El éxito de la detección de defectos microscópicos en fibras de alpaca reside en la capacidad del modelo para generalizar ante variaciones de iluminación y ruido. Para ello, se adoptan técnicas fundamentadas en el procesamiento digital de señales y la teoría de la regularización, permitiendo normalizar la entrada sensorial y suavizar los límites de decisión del modelo mediante los siguientes enfoques:

- **Ecualización Adaptativa de Histograma (CLAHE):** Esta técnica (*Contrast Limited Adaptive Histogram Equalization*) opera sobre subregiones de la imagen para optimizar el contraste local. Matemáticamente, se basa en la redistribución de la función de densidad de probabilidad (PDF) de los niveles de intensidad, restringida por un umbral de corte (*clip limit*) que previene la amplificación del ruido. La transformación se rige por la función de distribución acumulativa local, garantizando un mapeo de intensidades proporcional a la señal en cada subregión (Zuiderveld, 1994).

- **Regularización por Interpolación Lineal (Mixup):** Actúa como un mecanismo de regularización estructural que entrena al modelo sobre combinaciones convexas de pares de ejemplos (x_i, y_i) y (x_j, y_j) . Esta técnica mejora la robustez ante muestras ruidosas de vellosidad al forzar un comportamiento lineal en las regiones intermedias de las clases (Zhang et al., 2017). Su formulación matemática se define como:

$$\tilde{x} = \lambda x_i + (1 - \lambda)x_j \quad ; \quad \tilde{y} = \lambda y_i + (1 - \lambda)y_j \quad (2.3)$$

donde $\lambda \in [0, 1]$ es una variable aleatoria distribuida según $\text{Beta}(\alpha, \alpha)$.

- **Composición por Máscaras (Copy-Paste):** Fundamentada en la teoría de composición de imágenes (*Alpha Blending*), esta técnica permite el desacoplamiento de instancias. Al integrar la morfología de un defecto (como los neps) en diversos fondos, se obliga a la red neuronal a extraer características intrínsecas del objeto independientemente de su entorno original (Ghiasi et al., 2021). Se define formalmente mediante el producto de Hadamard ($\odot$):

$$\tilde{I} = M \odot I_{src} + (1 - M) \odot I_{dst} \quad (2.4)$$

donde M es una máscara binaria de segmentación, mientras que I_{src} e I_{dst} representan las imágenes de origen y destino respectivamente.

Tabla 3

Sustento de las técnicas de acondicionamiento y aumentación

Técnica	Parte Matemática	Parte Teórico
CLAHE	Procesamiento de histogramas	Estabilización de la varianza lumínica local.
Mixup	Interpolación convexa y distribución Beta	Suavizado de la superficie de pérdida.
Copy-Paste	Álgebra de matrices y máscaras binarias	Invarianza al contexto y reducción del sobreajuste.

Fuente: Basada en Zuiderveld (1994); Zhang et al. (2017); Ghiasi et al. (2021).

2.2.3 Arquitectura de aprendizaje profundo

Redes neuronales convolucionales

Las CNNs constituyen la arquitectura dominante del aprendizaje profundo aplicado al análisis de imágenes (LeCun et al., 2015). Su funcionamiento jerárquico replica el procesamiento visual: capas iniciales detectan características locales elementales (bordes, texturas), mientras capas profundas integran esas respuestas en representaciones semánticamente complejas como la morfología de un *nep* o el gradiente radial de la velloidad.

La operación fundamental es la convolución discreta entre el mapa de características de entrada $\mathbf{X} \in \mathbb{R}^{H \times W \times C}$ y un filtro aprendible $\mathbf{K} \in \mathbb{R}^{k \times k \times C}$:

$$Z_{i,j} = \sigma \left(\sum_{c=1}^C \sum_{m=0}^{k-1} \sum_{n=0}^{k-1} K_{m,n,c} \cdot X_{i+m,j+n,c} + b \right) \quad (2.5)$$

donde $\sigma(\cdot)$ es la función de activación y b el sesgo aprendible. La Tabla 4 resume los componentes clave de las CNN empleadas en este trabajo y su relevancia específica.

Tabla 4
Componentes de las CNN

Componente	Formulación / Operación	Impacto en la Tesis
Activación Si-LU	$f(x) = x \cdot \sigma(x)$	Estabilidad en datasets pequeños
Batch Norm	$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \cdot \gamma + \beta$	Aceleración de convergencia
Bloque SPPF	Max-pooling en cascada	Detección de neps y vellosidad
Conv. Separable	$K_{depth} + K_{point}$	Viabiliza el despliegue en móvil
Funciones Loss	$\mathcal{L}_{box} + \mathcal{L}_{cls} + \mathcal{L}_{dfl}$	Precisión en localización (IoU)

Fuente: Basada en LeCun et al. (2015); Ioffe and Szegedy (2015); Khanam and Hussain (2024).

Paradigmas de detección de objetos

La selección de la arquitectura de detección de objetos se basa en el compromiso entre la precisión de localización y la velocidad de inferencia. En el contexto del control de calidad textil, la capacidad de respuesta en tiempo real es un requerimiento crítico. Los detectores basados en aprendizaje profundo se categorizan en dos paradigmas principales:

- **Detectores de dos etapas (Two-stage):** Arquitecturas como Faster R-CNN que fragmentan la tarea en: 1) Propuesta de regiones mediante una RPN (*Region Proposal Network*) y 2) Clasificación y refinamiento de *bounding boxes*. Aunque ofrecen alta precisión, su coste computacional es elevado para entornos de producción Girshick et al. (2014).
- **Detectores de una etapa (One-stage):** Arquitecturas como la familia YOLO que tratan la detección como un único problema de regresión. Realizan la predicción de clases y coordenadas en un solo *forward pass*, optimizando la latencia para procesos en línea Redmon et al. (2016).

Tabla 5

Comparativa técnica de paradigmas de detección para inspección en tiempo real

Paradigma	Mecanismo de Inferencia	Viabilidad en Hilado Textil
Dos etapas	Secuencial (RPN + Clasificación)	Baja: Latencia > 100 ms (Inadecuado)
Una etapa	Unificado (Regresión directa)	Alta: > 30 FPS (Tiempo Real)

Fuente: Basado en Girshick et al. (2014); Redmon et al. (2016).

Familia de arquitecturas YOLO

YOLO divide la imagen de entrada en una cuadrícula de $S \times S$ celdas; cada celda predice B cajas delimitadoras con sus puntuaciones de confianza y C probabilidades de clase. La puntuación final para la clase c en la caja b es:

$$\text{Score}_{c,b} = p_{\text{obj},b} \cdot P(\text{clase}_c \mid \text{objeto}) \quad (2.6)$$

La Tabla 6 resume los hitos arquitectónicos más relevantes de la familia YOLO para el contexto de esta tesis.

Tabla 6

Hitos arquitectónicos de la familia YOLO relevantes para la presente investigación

Versión	Año	Contribución Principal
YOLOv1	2016	Detección como regresión en cuadrícula única; tiempo real
YOLOv3	2018	Detección multi-escala en tres niveles de resolución
YOLOv4	2020	Integración de CSPDarknet53, Mosaic y pérdida CIoU
YOLOv7	2022	Arquitectura E-ELAN y re-parametrización de modelos
YOLOv8	2023	Cabeza desacoplada <i>anchor-free</i>, bloque C2f y PAFPN
YOLOv9	2024	Arquitectura PGI y GELAN para eficiencia paramétrica
YOLO11	2024	Bloque C3K2 y módulo de autoatención parcial C2PSA
YOLO26	2025	Inferencia <i>NMS-free</i> para dispositivos de borde

Fuente: Basado en Yaseen (2023); Rao (2024).

El sustento teórico de la presente investigación se enmarca en la evolución de los detectores de una sola etapa, identificando a **YOLOv8** y **YOLO11** como los exponentes actuales de la convergencia entre eficiencia paramétrica y precisión representacional. Estas arquitecturas consolidan principios avanzados de diseño, como la integración de mecanismos de atención, apto de abordar la complejidad morfológica de las fibras naturales.

■ YOLOv8: bloque C2f y cabeza Desacoplada

La arquitectura se organiza en una estructura clásica de *backbone*, *neck* y *head*, cuya disposición de componentes y flujo de datos se detalla en la Figura 4.


- **Módulo C2f:** Implementa el concepto de *Cross Stage Partial* con dos ramas de flujo de gradiente. Matemáticamente, para un mapa de entrada $\mathbf{X} \in \mathbb{R}^{C_{in} \times H \times W}$, se define como:

$$\mathbf{Y}_{C2f} = \text{Conv}_{1 \times 1} \left(\text{Concat} \left[\mathbf{X}_1, \mathbf{B}_1(\mathbf{X}_1), \dots, \mathbf{B}_n(\mathbf{X}_1), \mathbf{X}_2 \right] \right) \quad (2.7)$$

donde la concatenación de tensores intermedios maximiza la reutilización de gradientes.

- **Cabeza desacoplada (*Anchor-free*):** Separa las ramas de regresión (localización) y clasificación por clase. Esta independencia elimina el conflicto de gradientes y se instancia en tres escalas $\{P_3, P_4, P_5\}$, permitiendo detectar simultáneamente *neps* submilimétricos (escala P_3) y zonas extensas de vellosoidad (escalas P_4/P_5).

Figura 4
Arquitectura detallada de YOLOv8



Fuente: Tomado de Yaseen (2023)

■ YOLO11: Bloque C3K2 y autoatención parcial C2PSA

La organización jerárquica de sus capas y la integración de nuevos módulos se ilustra en la Figura 5, destacando las contribuciones orientadas a la captura de dependencias globales.

- **Módulo C3K2:** Sustituye al bloque C2f mediante el uso de kernels de 3×3 en configuraciones de doble cuello de botella:

$$Y_{C3K2} = \text{Conv}_{1 \times 1}(\text{Concat}[\text{Conv}_{3 \times 3}(\text{Conv}_{3 \times 3}(X_1)), X_2]) \quad (2.8)$$


Esta configuración amplía el campo receptivo efectivo, mejorando la detección de patrones complejos de velloidad con menor conteo de parámetros.

- **Módulo C2PSA:** Integra el mecanismo de *Partial Self-Attention* tras el bloque SPFF. Al procesar solo el 50 % de los canales mediante autoatención espacial (PSA), reduce el coste computacional cuadrático:

$$Y_{C2PSA} = \text{Conv}_{1 \times 1}(\text{Concat}[\text{PSA}(X_1), X_2]) \quad (2.9)$$

Esta capacidad permite capturar dependencias de largo alcance en el hilo, facilitando la discriminación entre defectos y el fondo homogéneo de la imagen.

Figura 5
Arquitectura detallada de YOLO11



Fuente: Tomado de Rao (2024)

Funciones de pérdida y estrategias de aprendizaje

El proceso de optimización de los modelos YOLOv8 y YOLOv11 se fundamenta en la minimización de una función de pérdida multiobjetivo. Esta métrica permite al modelo ajustar sus pesos para resolver simultáneamente los problemas de localización y clasificación. La función de pérdida total se define como:

$$\mathcal{L}_{\text{total}} = \lambda_{\text{box}} \mathcal{L}_{\text{box}} + \lambda_{\text{cls}} \mathcal{L}_{\text{cls}} + \lambda_{\text{dff}} \mathcal{L}_{\text{dff}} \quad (2.10)$$

Donde los componentes se fundamentan en los siguientes principios:

- **Pérdida de regresión de caja ($\mathcal{L}_{\text{box}}$):** Utiliza el criterio CIOU (*Complete Intersection over Union*), el cual no solo penaliza el desajuste de área, sino también la distancia entre centros y la diferencia en la relación de aspecto de las cajas.
- **Pérdida de clasificación ($\mathcal{L}_{\text{cls}}$):** Basada en la Entropía Cruzada Binaria , evalúa la probabilidad de que el objeto detectado pertenezca a la categoría de *nep* o velloso.
- **Pérdida de distribución focal ($\mathcal{L}_{\text{dff}}$):** Específica para modelos *anchor-free*, optimiza la probabilidad de los valores de los bordes de la caja para manejar casos donde los límites del defecto son ambiguos o difusos Jocher et al. (2023).

Debido a la naturaleza técnica del dominio textil y la disponibilidad de datos, la teoría del aprendizaje es:

- **Aprendizaje por transferencia (*Transfer Learning*):** Se fundamenta en la reutilización de características jerárquicas preaprendidas. Los filtros de capas iniciales (detectores de bordes y texturas) son transferidos desde modelos entrenados en datasets masivos, permitiendo la convergencia en dominios específicos con menor volumen de datos Hussain (2024).

2.2.4 Métricas de evaluación del modelo de detección

El rendimiento de los detectores de objetos se cuantifica mediante métricas que evalúan tanto la precisión de la clasificación como la exactitud de la localización espacial.

Matriz de confusión y métricas de rendimiento

La evaluación parte de la matriz de confusión, que organiza las predicciones en cuatro categorías: Verdaderos Positivos (TP), Verdaderos Negativos (TN), Falsos Positivos (FP) y Falsos Negativos (FN). En la inspección de fibras, los FN (defectos no detectados) representan el mayor riesgo, pues comprometen la calidad del producto final Sokolova and Lapalme (2009). La Tabla 7 sintetiza las métricas derivadas aplicadas a este estudio.

Tabla 7
Métricas de evaluación, formulación matemática e interpretación

Métrica	Formulación	Rango	Interpretación en el hilo
Precisión (P)	$\frac{TP}{TP+FP}$	[0, 1]	Capacidad de evitar falsas alarmas de neps.
Recall (R)	$\frac{TP}{TP+FN}$	[0, 1]	Efectividad en capturar todos los defectos reales.
F1-Score	$2 \cdot \frac{P \cdot R}{P+R}$	[0, 1]	Balance armónico ante clases desbalanceadas.
IoU	$\frac{ \hat{B} \cap B_{gt} }{ \hat{B} \cup B_{gt} }$	[0, 1]	Precisión del ajuste de la caja al defecto.
mAP@0.5	$\frac{1}{ C } \sum_c \int_0^1 P_c(R) dR$	[0, 1]	Calidad global del modelo (independiente del umbral).
FPS	$1/\tau_{inf}$	> 0	Velocidad de procesamiento (viabilidad operativa).

Fuente: Basado en Sokolova and Lapalme (2009); Padilla et al. (2020).

Métricas globales y viabilidad

Para determinar la superioridad técnica entre YOLOv8 y YOLO11, se emplean dos criterios de síntesis:

- **mAP (mean Average Precision):** Es la métrica estándar que calcula el área bajo la curva Precisión-Recall (PR). A diferencia de las métricas puntuales, el mAP proporciona una evaluación integral del modelo en todos los niveles de confianza posibles, siendo el indicador principal para comparar la capacidad de detección entre las arquitecturas evaluadas Padilla et al. (2020).

- **Eficiencia en tiempo real (FPS):** La viabilidad de despliegue en un entorno artesanal depende de los Cuadros por Segundo (FPS). Tomando como referencia el estándar de 45.45 FPS sugerido para el monitoreo de hilado Pereira et al. (2023), esta métrica define si la latencia del modelo permite una respuesta inmediata ante la aparición de neps o vellosidad excesiva.

2.2.5 *Inteligencia Artificial Explicable (XAI)*

Fundamentos de XAI

Los modelos de aprendizaje profundo suelen operar bajo el paradigma de caja negra, donde la ruta lógica entre la entrada sensorial y la predicción final permanece opaca. En el control de calidad de la fibra de alpaca, esta falta de transparencia representa una barrera para la confianza del operario, quien requiere verificar si la detección de defectos se basa en la morfología real del hilo o en artefactos de la captura.

La XAI aborda este desafío mediante métodos post-hoc que generan mapas de calor para interpretar visualmente las activaciones de la red. En esta investigación, se consideran dos enfoques principales basados en la naturaleza de su cálculo:

1. **Grad-CAM (Gradient-weighted Class Activation Mapping):** Es el estándar basado en gradientes. Utiliza el flujo de información de la retropropagación, backpropagation, para comunicar la importancia de cada neurona en la última capa convolucional respecto a una decisión específica. Al promediar los gradientes del mapa de características, resalta las regiones que influyeron positivamente en la predicción.
2. **Eigen-CAM (Principal Components Activation Map):** Es un método independiente de gradientes que utiliza el Análisis de Componentes Principales PCA sobre el tensor de activaciones de la capa objetivo. Bajo la premisa de que el primer componente principal captura la estructura espacial dominante, permite aislar patrones morfológicos del ruido de fondo sin depender del flujo de retropropagación.

La Tabla 8 resume los atributos técnicos de ambos métodos, los cuales definen su aptitud para auditar arquitecturas complejas como la familia YOLO.

Tabla 8

Comparativa técnica de los métodos de explicabilidad evaluados

Atributo	Grad-CAM	Eigen-CAM
Mecanismo	Basado en gradientes ($\partial y^c / \partial A^k$)	Basado en activaciones (PCA)
Dependencia	Requiere retropropagación	Independiente de gradientes
Fidelidad Visual	Sensible al ruido en redes profundas	Robusto ante fluctuaciones de varianza
Compatibilidad	Limitada en cabezas desacopladas	Universal para cualquier arquitectura

Fuente: Basado en Muhammad and Yeasin (2020); Samek et al. (2019).

Eigen-CAM: Análisis de componentes principales (PCA)

La metodología Eigen-CA propone una alternativa a la visualización de activaciones que prescinde de la retropropagación de gradientes. Su fundamento reside en la aplicación del Análisis de Componentes Principales PCA sobre el tensor de activaciones de la capa convolucional objetivo, bajo la premisa de que el primer componente principal captura la estructura espacial de los objetos detectados Muhammad and Yeasin (2020).

Dado un tensor de activaciones $\mathbf{A} \in \mathbb{R}^{C \times H \times W}$ (donde C es el número de canales y $H \times W$ la resolución espacial), se realiza una reducción de dimensionalidad para proyectar la información en una sola dimensión. El proceso se describe mediante los siguientes pasos:

1. **Cálculo de la varianza:** Se identifica la dirección de máxima varianza en el espacio de activaciones. Esto se logra obteniendo los autovectores de la matriz de covarianza del tensor o, equivalentemente, mediante la Descomposición en Valores Singulares (SVD) de la matriz reformateada $\tilde{\mathbf{A}} \in \mathbb{R}^{C \times (H \cdot W)}$.
2. **Extracción del primer componente:** Se selecciona el autovector $\mathbf{u}_1$ correspondiente al mayor autovalor (λ_1), el cual representa el primer componente principal (PC1).
3. **Proyección y visualización:** El mapa de saliencia final L_{EigenCAM} se genera proyectando las activaciones originales sobre este primer componente:

$$L_{\text{EigenCAM}} = \text{reshape}(\tilde{\mathbf{A}}^T \mathbf{u}_1, H \times W) \quad (2.11)$$

Grad-CAM: Mapeo de activación de clase mediante gradientes

La técnica Grad-CAM (Gradient-weighted Class Activation Mapping) es uno de los algoritmos de explicabilidad post-hoc más extendidos, cuya función principal es producir mapas de localización visual que resaltan las regiones importantes de una imagen para la predicción de una clase específica Selvaraju et al. (2020).

A diferencia de los métodos basados únicamente en activaciones, Grad-CAM utiliza el flujo de información de la retropropagación, backpropagation, para calcular la importancia de cada neurona. El proceso matemático se fundamenta en obtener los gradientes de la puntuación para una clase c (y^c , antes de la función Softmax) con respecto a los mapas de características A^k de la última capa convolucional Selvaraju et al. (2020).

1. **Cálculo de pesos de neurona (α_k^c):** Se calcula la importancia del mapa de características k para la clase objetivo c mediante el promedio global de los gradientes (Global Average Pooling):

$$\alpha_k^c = \overbrace{\frac{1}{Z} \sum_i \sum_j}^{\text{Global Average Pooling}} \underbrace{\frac{\partial y^c}{\partial A_{i,j}^k}}_{\text{Gradientes}} \quad (2.12)$$

donde Z es el número de píxeles en el mapa de características y (i, j) representan las coordenadas espaciales.

2. **Combinación lineal y rectificación:** Se realiza una suma ponderada de los mapas de características activados y se aplica la función de activación ReLU (Rectified Linear Unit):

$$L_{\text{Grad-CAM}}^c = \text{ReLU} \left(\sum_k \alpha_k^c A^k \right) \quad (2.13)$$

La aplicación de la función ReLU es crítica en este proceso, ya que permite al sistema enfocarse exclusivamente en aquellas características que tienen una influencia positiva en la clase de interés (por ejemplo, la presencia de un nep). Las características con influencia negativa se filtran, bajo la premisa de que pertenecen a otras categorías o al fondo de la imagen Selvaraju et al. (2020).

2.3 Marco Conceptual

2.3.1 Fundamentos del sistema textil de alpaca y variables de calidad

En esta sección se definen los conceptos fundamentales relacionados con la materia prima y los procesos de transformación que delimitan el alcance físico del sistema de detección propuesto.

- **Fibra de alpaca:** Fibra natural proteica obtenida del vellón de la alpaca (*Vicugna pacos*). Para efectos de esta investigación, el concepto se restringe exclusivamente a la raza **Huacaya**, de coloración **blanca** y categoría de calidad **Baby** (diámetro medio entre 20,1 y 23,0 μm), proveniente de la comunidad de Ocongate, Cusco (CITE Camélidos Sudamericanos, 2021).
- **Uster Tester:** Sistema de laboratorio basado en sensores capacitivos y ópticos, consolidado como el estándar internacional e industrial para la evaluación objetiva de la calidad del hilo. Este equipo cuantifica de manera automatizada parámetros críticos como la variación de masa, el índice de vellosidad (*hairiness*) y la frecuencia de imperfecciones espaciales (*neps*, zonas gruesas y delgadas) a altas velocidades (Haleem et al., 2021).
- **Hilado artesanal:** Proceso de transformación de la fibra en un hilo continuo mediante operaciones de cardado y torsión manual o semi-manual. Se caracteriza por una alta variabilidad estructural debida al factor humano, lo que justifica la necesidad de una supervisión automatizada para estandarizar su calidad final (CITE Camélidos Sudamericanos, 2021).
- **Titulación del hilo ($Nm\ 5$):** Relación métrica entre longitud y masa. La titulación $Nm\ 5$ indica que 5 metros de hilo pesan 1 gramo. Este parámetro es crítico en la investigación, ya que estandariza el diámetro visual del núcleo del hilo en las imágenes, facilitando que el modelo YOLO se enfoque en las desviaciones (defectos) sobre un fondo de grosor constante (CITE Camélidos Sudamericanos, 2021).
- **Vellosidad (*Hairiness*):** Defecto caracterizado por la proyección radial de fibras desde

el núcleo del hilo, formando una aureola difusa. Como se observa en la Figura 6, este defecto degrada el factor de confort y aumenta la tendencia al *pilling* en la prenda final (Jing et al., 2018).

Figura 6

Defecto de tipo vellosidad (hairiness) identificado en el hilo de alpaca Huacaya.



- **Neps (Motas):** Enredos compactos de fibras de forma nodular con diámetros variables. En la Figura 7 se aprecia su morfología característica, originada por fracturas mecánicas o biológicas durante el procesamiento de la fibra (Li et al., 2020).

Figura 7

Defecto de tipo nep (mota) con morfología nodular característica.




- **Control de calidad textil:** Conjunto de procedimientos para verificar la conformidad del producto. Históricamente subjetivo y propenso a la fatiga humana en el entorno artesanal de Cusco, la investigación propone su transición hacia un control basado en datos y visión computacional (Haleem et al., 2021; Pereira et al., 2023).

2.3.2 Visión computacional


- **Visión computacional:** Disciplina de la inteligencia artificial que permite a los sistemas interpretar información visual del mundo físico. En este trabajo, es el paradigma que integra la adquisición, preprocesamiento y detección de defectos en el hilo de alpaca (Gonzalez and Woods, 2018).
- **Segmentación por instancias (*Instance Segmentation*):** Tarea que combina la localización y la delineación individual de cada objeto. A diferencia de la detección simple, este enfoque permite separar y etiquetar cada vellosoidad o *nep* a nivel de píxel, como se ilustra en la comparativa de la Figura 8.
- **Caja delimitadora (*Bounding Box*):** Primitiva geométrica definida por coordenadas (x, y, w, h) que encierra un objeto. Es la unidad básica de salida de los detectores de objetos y sirve como referencia inicial para la localización del defecto en la imagen.
- **Máscara (*Mask*):** Representación binaria donde los píxeles con valor 1 pertenecen al defecto y los de valor 0 al fondo. La máscara es el resultado final de la segmentación por instancias y permite calcular parámetros métricos exactos del área del daño en la fibra (Gonzalez and Woods, 2018).

Figura 8

Comparativa entre la localización mediante cajas delimitadoras y mediante máscaras.



(a) Detección (*Bounding Boxes*)



(b) Segmentación (*Máscaras*)

2.3.3 *Aprendizaje profundo y detección automática de objetos*

- **Aprendizaje profundo (*Deep Learning*):** Subcampo del aprendizaje automático que utiliza redes neuronales multicapa para extraer jerarquías de características de forma automática. En esta tesis, permite que el sistema aprenda a diferenciar un *nep* de una fibra de vellosidad sin necesidad de descriptores manuales (LeCun et al., 2015).
- **Red neuronal convolucional (CNN):** Arquitectura diseñada para procesar datos con estructura de rejilla (imágenes). Utiliza capas de convolución que aplican filtros aprendibles, capturando patrones espaciales y texturas críticas para la inspección (LeCun et al., 2015).
- **Arquitectura YOLO:** Detector de objetos de una sola etapa que trata la detección como un problema de regresión global. Se seleccionaron las versiones YOLOv8 y YOLO11 por su capacidad de realizar segmentación de instancias con alta eficiencia computacional (Jocher et al., 2023; Hussain, 2024).
- **Backbone (Columna vertebral):** Red encargada de la extracción de características fundamentales de la imagen. En los modelos evaluados, abarca las primeras capas (típicamente de la 0 a la 9) Rao (2024).
- **Neck (Cuello):** Módulo intermedio que combina y refina las características extraídas por el *backbone*. Utiliza estructuras como FPN (*Feature Pyramid Network*) para procesar el defecto en diferentes escalas Rao (2024).
- **Head (Cabeza de detección):** Etapa final que realiza las predicciones de clase y localización. En YOLO, se utiliza una cabeza desacoplada que separa las tareas de clasificación y regresión, mejorando la precisión en la delineación de los defectos Rao (2024).
- **Aprendizaje por transferencia (*Transfer Learning*):** Estrategia que consiste en inicializar el modelo con pesos preentrenados en grandes conjuntos de datos (COCO).(Hussain, 2024).

2.3.4 *Dataset y anotación*

- **Dataset :** Colección estructurada de unidades de información (imágenes) y sus correspondientes metadatos (etiquetas). Constituye el insumo fundamental para que los algoritmos de aprendizaje profundo identifiquen patrones y regularidades estadísticas en un dominio específico.
- **Anotación o Etiquetado (*Labeling*):** Proceso de asignación de información semántica a los datos crudos. En el contexto de la segmentación de instancias, consiste en la delimitación de objetos mediante máscaras poligonales que definen la extensión espacial y la categoría de cada entidad de interés.
- **Ground Truth:** Representación de la realidad del dominio que se asume como absolutamente correcta y objetiva. Actúa como el estándar de comparación para cuantificar la precisión del modelo, donde cualquier desviación de la predicción respecto a esta referencia se considera un error.
- **Gold Standard:** Denominación de un dataset cuya calidad y veracidad han sido validadas por un experto humano o un criterio de referencia superior. Representa el techo teórico de precisión y confiabilidad dentro de un proceso de etiquetado manual.
- **División de datos (*Data Splitting*):** Estrategia de partición de un *dataset* en subconjuntos independientes para garantizar la integridad del proceso de evaluación:
 - **Entrenamiento:** Datos utilizados para el ajuste de los parámetros y pesos de la red neuronal.
 - **Validación:** Datos empleados para el monitoreo del aprendizaje y la optimización de hiperparámetros, evitando el sobreajuste.
 - **Prueba :** Datos reservados para una evaluación final e imparcial de la capacidad de generalización del modelo sobre escenarios no observados.

2.3.5 Métricas de evaluación


- **Precisión (*Precision*):** Indicador de la confiabilidad de las detecciones positivas; representa la capacidad del modelo para evitar falsas alarmas.
- **Sensibilidad (*Recall*):** Indicador de la exhaustividad del sistema; mide la capacidad para capturar todos los defectos reales presentes en la muestra.
- **Puntuación F1:** Métrica de balance que integra la precisión y la sensibilidad, útil para evaluar el rendimiento global ante clases de datos desbalanceadas.
- **Intersección sobre Unión (IoU):** Coeficiente que mide la exactitud de la localización espacial comparando la superposición de la predicción frente a la referencia.
- **mAP (*mean Average Precision*):** Métrica estandarizada que resume la calidad global de la detección y segmentación en todos los niveles de confianza del modelo.
- **Eficiencia Computacional (FPS):** Medida de la velocidad de procesamiento expresada en cuadros por segundo, que define la aptitud del modelo para trabajar en entornos de tiempo real.

2.3.6 Explicabilidad de modelos de inteligencia artificial (XAI)

- **Inteligencia Artificial Explicable (XAI):** Campo de la inteligencia artificial orientado a dotar de transparencia a los modelos, permitiendo que sus predicciones sean comprensibles y auditables. Como se ilustra conceptualmente en la Figura 9, su implementación es fundamental para transformar la percepción de caja negra en un sistema transparente que fomente la confianza del usuario final y garantice la equidad en las decisiones automatizadas (Samek et al., 2019).

Figura 9

Contraste entre el modelo de caja negra y la transparencia de la IA explicable (XAI).



Fuente: Tomado de Goswami (2026).

- **Modelo de caja negra (Black-box):** Término que describe a los sistemas de aprendizaje profundo cuya estructura interna y lógica de decisión son opacas. En esta investigación, describe la naturaleza de las redes convolucionales antes de la aplicación de técnicas de interpretación.
- **Eigen-CAM:** Técnica de explicabilidad post-hoc que permite visualizar las activaciones de la red de forma independiente al flujo de gradientes. Su funcionamiento se basa en aplicar el PCA sobre los mapas de características de las capas convolucionales para extraer la dirección de máxima varianza. Al proyectar las activaciones sobre el primer componente principal, el sistema logra aislar y resaltar la estructura espacial dominante del defecto reduciendo el ruido visual y la pixelación asociados a los métodos basados en retropropagación Muhammad and Yeasin (2020).
- **Grad-CAM:** Técnica de explicabilidad basada en gradientes que utiliza la información del flujo de retropropagación (*backpropagation*) para asignar pesos de importancia a las neuronas de la última capa convolucional. Genera un mapa de localización de grano grueso que resalta las regiones de interés para una clase específica, permitiendo identificar qué características visuales justifican la decisión del modelo (Selvaraju et al., 2020).

CAPÍTULO III

METODOLOGÍA

3.1 Tipo de investigación

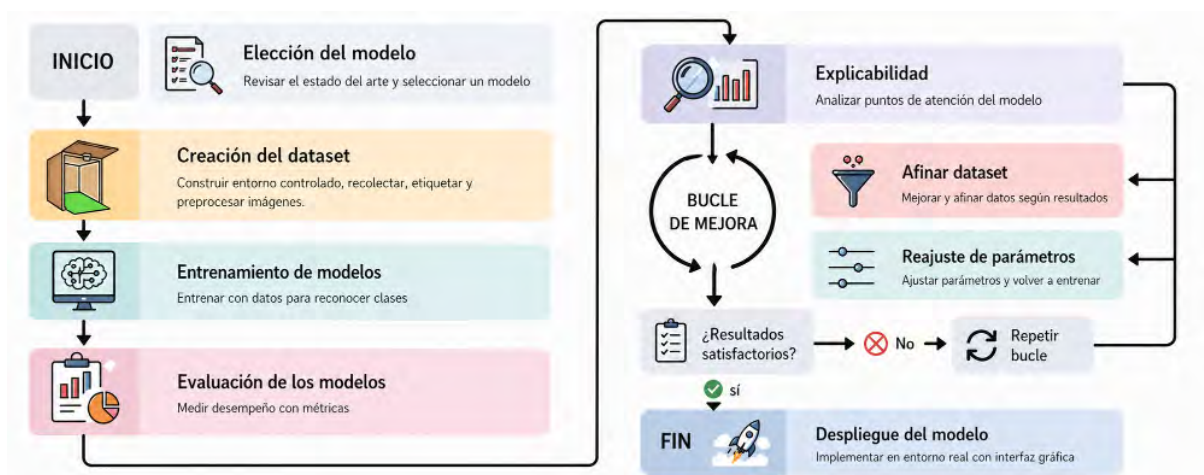
La investigación es de tipo **aplicada**, ya que emplea principios y herramientas científicas consolidadas, visión computacional, redes neuronales convolucionales y aprendizaje profundo, para resolver un problema concreto y delimitado: la ausencia de un mecanismo objetivo, reproducible y tecnológicamente accesible para detectar defectos en el hilado artesanal.

Complementariamente, la investigación presenta un enfoque **experimental**, dado que se emplean de manera sistemática diversas herramientas y configuraciones, tales como la arquitectura del modelo, las condiciones del entorno de captura, las estrategias de balanceo de clases, así como los parámetros de entrenamiento y los hiperparámetros de optimización, con el fin de evaluar su impacto en las métricas de rendimiento del detector de defectos.

Proceso metodológico

El diagrama metodológico seguido se ilustra en la Figura 10, el cual refleja fielmente el flujo iterativo ejecutado durante el desarrollo experimental de la investigación.

Figura 10
Diagrama del flujo metodológico iterativo adoptado.



3.2 Elección del modelo

La primera fase consistió en una revisión exhaustiva del estado del arte en sistemas de visión computacional aplicados al control de calidad de hilos textiles y a la detección de defectos en materiales fibrosos naturales. Esta revisión abarcó tanto los enfoques de procesamiento clásico de imágenes como las arquitecturas de aprendizaje profundo.

Dentro del espacio de arquitecturas de aprendizaje profundo, se descartaron los detectores de dos etapas (Faster R-CNN) Girshick et al. (2014) por sus latencias de inferencia superiores a 100 ms por imagen, incompatibles con el requisito de procesamiento en tiempo real. Se seleccionó en cambio la familia YOLO Redmon et al. (2016) en su paradigma de detección de una sola etapa (*single-stage*), por su equilibrio demostrado entre precisión y velocidad de inferencia en tareas de inspección de calidad industrial.

Dado que los defectos del hilo de alpaca, especialmente la vellosidad, no presentan una morfología rectangular predecible, sino contornos irregulares y difusos, se tomó la decisión técnica fundamental de adoptar segmentación de instancias Ghiasi et al. (2021) en lugar de detección clásica con cajas delimitadoras Padilla et al. (2020). La segmentación de instancias permite delinear las regiones exactas de cada defecto mediante máscaras poligonales, lo cual aporta mayor precisión tanto en la localización como en la cuantificación de la extensión superficial del defecto.

3.3 Creación del dataset

La construcción de un dataset fue la fase de mayor impacto sobre el rendimiento final del sistema. Esta fase se subdivide en las siguientes etapas: obtención de la muestra de hilo, adquisición de imágenes en entorno controlado, etiquetado mediante segmentación de instancias y preprocesamiento.

3.3.1 Obtención de la muestra de hilo artesanal

La materia prima empleada para la construcción del dataset proviene de la comunidad de Ocongate, provincia de Quispicanchis, región del Cusco, y corresponde exclusivamente a fibra

de alpaca Huacaya blanca, categoría Baby (diámetro medio de fibra entre 20,1 y 23,0 μm), hilada con titulación Nm 5. Para asegurar la representatividad de los defectos en el conjunto de imágenes, se trabajó con una muestra física de **15 metros de hilo artesanal**. La longitud seleccionada permitió cubrir una amplia variabilidad en la distribución natural de los defectos a lo largo del hilo: zonas con alta densidad de vellosidad, zonas con presencia de neps aislados o agrupados, y tramos de hilo aparentemente conforme, necesarios para que el modelo aprenda a discriminar correctamente entre las clases de defecto y el estado libre de imperfecciones, tal como se muestra en la Figura 11.

Figura 11

Muestra física de hilo de alpaca utilizada para la captura de imágenes.



3.3.2 Instrumento de adquisición de imágenes

Para el proceso de captura de las imágenes, se empleó un dispositivo móvil Xiaomi Poco M5s, seleccionado por su capacidad de resolución y versatilidad en entornos de iluminación controlada. Las especificaciones técnicas detalladas del dispositivo se presentan en la Tabla 9.

Tabla 9

Especificaciones técnicas del dispositivo de captura Xiaomi Poco M5s.

Característica	Especificación
Modelo	Xiaomi Poco M5s
Cámara Principal	64 MP, f/1.8, 26mm (gran angular)
Cámara Macro	2 MP, f/2.4
Procesador	MediaTek Helio G95
Resolución Pantalla	1080 x 2400 píxeles
Sistema Operativo	Android (MIUI/HyperOS)

El dispositivo fue montado en un soporte dedicado para asegurar la estabilidad durante la toma, tal como se ilustra en la Figura 12.

Figura 12

Dispositivo móvil Xiaomi Poco M5s utilizado para la captura de imágenes.



3.3.3 Entorno controlado de captura de imágenes


La adquisición de imágenes requirió el diseño y la evaluación de un entorno controlado que garantizara condiciones reproducibles de iluminación, encuadre y resolución. Esta etapa

implicó la exploración y comparación de dos configuraciones distintas antes de adoptar la solución definitiva.

- **Primera configuración: caja cerrada construida.** Tal como se ilustra en la Figura 13, en una primera instancia se diseñó y construyó manualmente una caja cerrada de MDF en forma de cubo de 60 cm de lado, con iluminación LED difusa interna, montada específicamente para aislar el hilo del entorno lumínico exterior. Se utilizó un fondo de color verde oscuro mate para evitar contrailuminaciones, simulando un entorno controlado. Sin embargo, esta configuración presentó limitaciones técnicas que la hicieron inviable para la construcción del dataset a la escala requerida, tales como una cadencia de captura extremadamente baja, una distribución no uniforme de la iluminación y dificultades de manipulación del hilo dentro del espacio.

Figura 13

Entorno de adquisición: Caja cerrada artesanal.



- **Segunda configuración: cabina de luz de laboratorio.** Ante las limitaciones de la caja construida, se recurrió a la cabina de luz de laboratorio mostrada en la Figura 14, disponible en las instalaciones del CITE Textil Camélidos Cusco. Esta cabina proporcionó

ventajas determinantes para la investigación, incluyendo una iluminación LED difusa de espectro blanco distribuida de forma homogénea.

Figura 14

Entorno de adquisición: Cabina de luz de laboratorio.



3.3.4 Registro de la preparación y adquisición de imágenes

Con el fin de asegurar la reproducibilidad y calidad técnica del *dataset*, se estandarizó la preparación y captura de las muestras de hilo artesanal, como se observa en la Figura 15. Cada muestra se seleccionó en segmentos de 12 a 14 cm de longitud y se utilizó una regla como testigo métrico para verificar su escala y disposición dentro del campo de visión, tal como se muestra en la Figura 16. Durante la captura, la cámara se posicionó ortogonalmente al eje del hilo, a una distancia constante de 20 cm y con un zoom de 2.5×, manteniendo así una configuración uniforme entre las muestras.

Figura 15

Captura realizada por el investigador.




Figura 16
Segmento de 12-14 cm con escala métrica.



3.3.5 Selección y volumen del conjunto de imágenes


- **Captura y organización de archivos:** La fase de adquisición permitió obtener un total de 700 imágenes del hilo artesanal, capturadas en formato .jpg con una resolución de 3840×2160 px. Las capturas fueron organizadas inmediatamente en 6 carpetas dentro del equipo de cómputo. La nomenclatura adoptada, bajo el formato Hilo_artesanal_blanco_fecha, permitió garantizar la trazabilidad de cada sesión de captura, tal como se muestra en la Figura 17.

Figura 17
Estructura de directorios de las capturas en el equipo local.



- **Gestión en Roboflow:** Cada imagen fue sometida a una revisión de calidad técnica que evaluó criterios de nitidez, exposición, ausencia de desenfoque por movimiento y adecuación del encuadre. De este proceso de selección se retuvieron 500 imágenes de mayor calidad diagnóstica, descartando 200 capturas con artefactos. El conjunto seleccionado fue procesado y subido a la plataforma Roboflow, como se observa en la Figura 18, facilitando la gestión del etiquetado y la preparación de versiones para el entrenamiento del modelo.

Figura 18
Dataset cargado y gestionado en la plataforma Roboflow.



3.3.6 Etiquetado mediante segmentación de instancias

El proceso de anotación del dataset se realizó mediante segmentación de instancias, utilizando la plataforma Roboflow como herramienta de etiquetado. A diferencia del etiquetado con cajas delimitadoras rectangulares, la segmentación de instancias requiere delinear con precisión el contorno poligonal de cada región defectuosa, generando una máscara binaria que delimita exactamente la extensión espacial del defecto en la imagen.

Criterios de etiquetado basados en ASTM D2255

Para garantizar la validez técnica de las anotaciones, el proceso de etiquetado del dataset siguió los criterios de severidad definidos en la norma ASTM D2255 ASTM International (2017). La norma especifica que la evaluación de la apariencia del hilo se basa en factores como la vellosidad y la presencia de neps, los cuales son determinantes para la clasificación comercial del hilado.

En consecuencia, el proceso de anotación manual mediante segmentación de instancias no se limitó a una identificación visual básica, sino que aplicó los umbrales de severidad descritos por el estándar:


- **Criterio de Neps:** Se priorizó la segmentación de aglomeraciones nodulares que exceden tres veces el diámetro promedio del hilo . Siguiendo la normativa ASTM D2255, estos defectos fueron etiquetados con especial atención, dado que su presencia es un factor determinante para degradar la clasificación del hilo hacia grados inferiores (tales como el Grado D), al comprometer tanto su uniformidad como su integridad estructural.
- **Criterio de Vellosidad :** Se segmentaron las fibras que sobresalen de la estructura principal del hilo, fenómeno definido técnicamente en el estándar como *fuzziness* . Bajo los criterios de la norma, estas protrusiones fueron etiquetadas como defectos dado que afectan directamente la uniformidad visual y el tacto del producto final, constituyendo un indicador clave para diferenciar los grados de calidad .

Se definieron las dos clases de anotación:

1. **Nep (clase 0):** Aglomeración compacta y nodular de fibras sobre la superficie del hilo, de morfología aproximadamente circular o elipsoidal. Cada nep fue anotado como una instancia individual con su máscara poligonal correspondiente, tal como se ilustra en la Figura 19.

Figura 19


Ejemplo de un Nep (Clase 0) segmentado en el hilo de alpaca.



2. **Vellosidad (clase 1):** Esta clase representa las regiones donde se observa una proyección radial perceptible de fibras sueltas que sobresalen del núcleo principal del hilo. Conforme a la metodología adoptada y tal como se ilustra en la Figura 20, estas instancias se delimitaron de forma individual mediante máscaras poligonales de borde. Para estandarizar la anotación, se utilizaron guías de referencia (líneas horizontales blancas discontinuas), marcando como instancias válidas aquellas vellosidades cuya longitud superaba dicho umbral, conforme al criterio de la experta del CITE Textil Camélidos Cusco.

Figura 20

Ejemplo de Vellosidad (Clase 1) segmentada en el hilo de alpaca.



El proceso de anotación fue realizado manualmente, bajo la supervisión y validación técnica de la experta del CITE Textil Camélidos Cusco. Dado el nivel de detalle requerido por la


segmentación de instancias, cada imagen requirió un tiempo de anotación aproximado de entre 20 y 30 minutos para completar el etiquetado de las 500 imágenes seleccionadas. Esta inversión de tiempo es coherente con la complejidad morfológica de los defectos analizados y la precisión exigida por el estándar de calidad del *Dataset Gold Standard* CITE Camélidos Sudamericanos (2021). El dataset resultante fue gestionado y versionado en la plataforma Roboflow, la cual provee control de versiones del dataset y exportación en el formato nativo de las arquitecturas YOLO.

3.3.7 *División del dataset*

Para optimizar el rendimiento y la generalización del modelo, el dataset de 500 imágenes fue particionado en tres subconjuntos mediante una mezcla aleatoria de las imágenes. Esta distribución, que garantiza una representación equilibrada para el entrenamiento, validación y prueba, se ilustra en la Figura 21:

- **Conjunto de entrenamiento (70 %):** 350 imágenes originales destinadas a la actualización iterativa de los pesos del modelo. Este subconjunto fue el único sobre el cual se aplicaron posteriormente las técnicas de sobremuestreo de *neps* y la aumentación por CLAHE descritas en la sección siguiente.
- **Conjunto de validación (20 %):** 100 imágenes crudas e inalteradas, empleadas únicamente para monitorear el progreso del entrenamiento por época, ajustar hiperparámetros y aplicar la política de detención temprana (*early stopping*).
- **Conjunto de prueba (*Test Set*) (10 %):** 50 imágenes crudas reservadas. Este conjunto no tuvo intervención alguna en el ajuste del modelo ni en la parada temprana, utilizándose de forma imparcial para la evaluación de las métricas finales y las pruebas de simulación en la interfaz interactiva.

Figura 21
Distribución porcentual del dataset (Train, Val, Test).



3.3.8 Estrategias de aumentación de datos

El dataset se incrementó mediante una estrategia dual que combinó técnicas de procesamiento previo (*offline*) y transformaciones dinámicas durante el entrenamiento (*online*).

Aumentación offline: Balanceo y CLAHE

Para mitigar el desequilibrio de clases y aumentar el volumen de datos, se ejecutaron dos procesos consecutivos. El dataset original presentaba una distribución asimétrica, con una prevalencia de 1 nep por cada 8 instancias de vellosidad por imagen. Para corregir esto, se aplicó una técnica de sobremuestreo mediante el triplicado de las muestras que contenían neps. Este ajuste balanceó la relación de clases a 1 nep por cada 4 vellosidades, incrementando significativamente la diversidad de casos de neps y consolidando un conjunto base de 1,400 imágenes.

Posteriormente, se aplicó la técnica de CLAHE sobre la totalidad de este conjunto. En el proceso se utilizó $tileGridSize=8 \times 8$, que dividió la imagen en 64 regiones para ajustar el contraste localmente, mitigando la iluminación no uniforme inherente a la cabina de captura. Paralelamente, el $clipLimit=3.0$ limitó la amplificación del contraste para evitar realzar el ruido de fondo, asegurando que solo los detalles morfológicos de interés fueran acentuados. Al añadir estas imágenes procesadas al conjunto original, se alcanzó un total de 2,800 imágenes. Como se observa en la Figura 22, esta técnica logra una mejora sustancial en la nitidez de las fibras y defectos.

Figura 22

Comparativa visual del efecto CLAHE sobre la muestra de fibra.



Imagen original (hilo08)



Procesada con CLAHE (hilo08calhe)

Aumentación online: Transformaciones dinámicas

Durante el entrenamiento, se configuró una aumentación de datos dinámica que aplica transformaciones en cada época. A diferencia del método *offline*, estas técnicas exponen al modelo a múltiples variantes geométricas y de composición, reduciendo el sobreajuste y mejorando la generalización. Las técnicas y su impacto se describen a continuación:

- **Mosaic (0.8):** Combina cuatro imágenes en una sola, forzando al modelo a aprender el contexto del objeto dentro de escenas complejas y mejorando la detección de objetos pequeños.
- **Copy-Paste (0.6):** Extrae instancias de defectos y las superpone sobre otros fondos, desacoplando el objeto del entorno original y obligando al modelo a aprender características intrínsecas del defecto.
- **Mixup (0.05):** Superpone dos imágenes con transparencia, funcionando como un regularizador que suaviza los límites de decisión y reduce el sobreajuste.
- **Degrees (30.0), Fliplr (0.5), Flipud (0.5):** Aplican rotaciones y volteos, proporcionando invarianza geométrica frente a cambios de orientación o posición en la captura.

El conjunto de entrenamiento alcanzó un volumen total de 30,768 instancias, cuya distribución se resume en la Tabla 10.

Tabla 10

Resumen de distribución de instancias en el conjunto de entrenamiento.

Clase	Instancias	Distribución (%)
Vellosidad	24,536	79.74 %
Nep	6,232	20.26 %
Total	30,768	100 %

3.4 Entorno experimental y recursos computacionales

En la Tabla 11 se resumen las especificaciones técnicas detalladas del hardware y el ecosistema de software empleado. Los experimentos de entrenamiento y evaluación fueron realizados en una estación de trabajo de alto rendimiento, configurada específicamente para tareas de Deep Learning. Esta infraestructura proporcionó la capacidad de cómputo necesaria para gestionar el entrenamiento iterativo de los modelos YOLO, asegurando la estabilidad y la reproducibilidad de los resultados científicos.

Tabla 11

Especificaciones del entorno de cómputo, entrenamiento y software.

Categoría	Especificación
Procesador	2x Intel Xeon Gold 6134 @ 3.20 GHz
Memoria RAM	128 GB DDR4 @ 2666 MHz
GPU	NVIDIA Quadro GP100 (16 GB VRAM)
Almacenamiento	SSD 250 GB (SO) / HDD 2 TB (Datos)
Sistema Operativo	Ubuntu 22.04 LTS / Linux
Lenguaje	Python 3.10
Framework IA	PyTorch 2.0+ con aceleración CUDA 12.2
Librería YOLO	Ultralytics API (v8.x / v11.x)
Entorno de Desarrollo	Jupyter Notebook / Visual Studio Code / Cursor

La arquitectura del sistema se centró en aprovechar la potencia de cómputo paralelo de la GPU NVIDIA Quadro GP100 mediante el uso de núcleos CUDA, lo cual permitió gestionar eficientemente las capas convolucionales de las redes neuronales profundas. El flujo de trabajo se articuló sobre un entorno de desarrollo basado en Python, utilizando Jupyter Notebook para la experimentación rápida y la visualización de métricas en tiempo real durante el entrenamiento.

La implementación de los modelos se realizó mediante el framework PyTorch, integrando la librería de Ultralytics para la gestión de las arquitecturas YOLO. Esta combinación técnica garantizó una gestión optimizada de los tensores y la memoria de video (VRAM), facilitando el procesamiento masivo del dataset de hilo artesanal. Finalmente, el uso de herramientas como Visual Studio Code y el editor Cursor permitió una depuración precisa de los algoritmos de inferencia y la integración de técnicas de explicabilidad mediante visión computacional.

3.5 Entrenamiento de modelos

El proceso de entrenamiento de los modelos de segmentación de instancias se ejecutó en las instalaciones del Laboratorio de Algoritmos y Análisis de Datos (LAAD) de la Universidad Nacional de San Antonio Abad del Cusco (UNSAAC), empleando el framework Ultralytics. Las actividades de entrenamiento se organizaron en dos fases metodológicas diferenciadas por la arquitectura de red neuronal seleccionada, siguiendo un protocolo de experimentación iterativa para el ajuste de hiperparámetros.

3.5.1 Especificación técnica de los modelos

Para fundamentar la selección de las arquitecturas experimentales, se presenta en la Tabla 12 una comparación de la complejidad estructural de los modelos utilizados, medida en cantidad de parámetros. Esta métrica es determinante para comprender el comportamiento del sistema ante las restricciones de memoria de la GPU Quadro GP100. Los valores reportados corresponden a la implementación estándar del framework Ultralytics Jocher et al. (2023).

Tabla 12
Comparativa de complejidad arquitectónica (Número de parámetros).

Modelo	Parámetros (aprox.)	Justificación
yolov8m-seg	25.9 M	Base de referencia para experimentación inicial. Arquitectura optimizada con menor carga paramétrica.
yolo11m-seg	20.1 M	
yolo11l-seg	25.3 M	Alta capacidad para segmentación de contornos finos.

3.5.2 Fase inicial: Experimentación con YOLOv8

Durante la etapa inicial, se realizaron cinco ciclos de entrenamiento empleando la arquitectura YOLOv8, seleccionando la variante medium (yolov8m-seg). Esta variante fue elegida por su capacidad equilibrada para extraer características de textura fina, críticas en la detección de defectos en fibras, sin exceder las capacidades de procesamiento del servidor disponible.

La sistematización de los hiperparámetros se detalla en la Tabla 13, la cual resume la configuración técnica aplicada en los experimentos.

Tabla 13

Hiperparámetros técnicos de configuración para el entrenamiento (YOLOv8).

Parámetro	Valor	Justificación técnica
Modelo	yolov8m-seg	Variante medium equilibrada para segmentación.
Resolución	960 px	Resolución alta para capturar defectos finos en el hilo.
Batch Size	8	Ajustado a la capacidad de VRAM de la GPU NVIDIA Quadro GP100.
Épocas	250	Ciclos definidos para asegurar la convergencia del modelo.
Patience	50	Detención temprana ante estancamiento para evitar sobreajuste.
Workers	4	Carga paralela de datos para optimizar el flujo de entrenamiento.
Overlap Mask	True	Habilitado para mejorar la detección de instancias solapadas.
Dispositivo	GPU: 0	Ejecución acelerada mediante hardware dedicado.

Esta configuración permitió documentar de manera precisa el comportamiento del modelo, proporcionando una base empírica estandarizada que facilitó el análisis de convergencia y el posterior ajuste de hiperparámetros necesario para la transición hacia la arquitectura avanzada.

3.5.3 Fase final: Configuración con YOLO11

Tras completar la fase inicial, se procedió a la implementación de la arquitectura YOLO11, seleccionada por su eficiencia mejorada en la segmentación de instancias. En esta etapa se definieron dos configuraciones experimentales, denominadas Configuración A y Configuración B, para evaluar el impacto de distintas estrategias de regularización y ajuste de pesos. Los hiper-

parámetros técnicos detallados de ambas configuraciones se presentan de manera comparativa en la Tabla 14.

Debido a la mayor complejidad arquitectónica de YOLO11, la gestión eficiente de la memoria VRAM resultó crítica. Para procesar resoluciones superiores a 1 300 píxeles sin incurrir en errores de desbordamiento (*Out of Memory*), se implementó la asignación dinámica de recursos mediante `PYTORCH_CUDA_ALLOC_CONF=expandable_segments:True`

Tabla 14

Comparativa de hiperparámetros entre Configuración A y Configuración B.

Configuración A (YOLO11m)		Configuración B (YOLO11l)	
Parámetro	Valor	Parámetro	Valor
Modelo	yolo11m-seg	Modelo	yolo11l-seg
Resolución	1344 px	Resolución	1440 px
Batch Size	2	Batch Size	2
AMP	True	AMP	True
Épocas	400	Épocas	500
Patience	70	Patience	150
Optimizer	AdamW	Optimizer	AdamW
lr0	0.0005	lr0	0.0001
Class Loss	3.5	Cosine LR	True
Box Loss	10.0	Overlap Mask	False
Dropout	0.15	Class Loss	3.5
Validation	True	Box Loss	7.0
Device	0	DFL Loss	2.0
		Device	0

3.6 Evaluación de los modelos

Para la evaluación del desempeño del sistema, primero se definen las métricas fundamentales, adaptados a la detección de defectos en el hilo de alpaca:

- **Verdadero Positivo (TP):** Detecciones correctas; el modelo identifica un defecto (nep o

vellosidad) donde realmente existe.

- **Falso Positivo (FP):** Falsas alarmas; el modelo identifica un área como defectuosa cuando, en realidad, es parte del hilo sano o ruido de fondo.
- **Falso Negativo (FN):** Defectos omitidos; el modelo no detecta un defecto real presente en la muestra. Este componente es el más crítico para el control de calidad.
- **Verdadero Negativo (TN):** Identificación correcta de áreas del hilo sin defectos (en tareas de segmentación, esto corresponde mayoritariamente al fondo de la imagen).

Para cuantificar el éxito de la detección y la precisión de las máscaras generadas, se utilizan las métricas detalladas en la Tabla 15.

Tabla 15
Métricas de evaluación aplicadas.

Métrica	Interpretación en el Control de Calidad de Fibra
Precisión	Indica la confiabilidad de las alarmas. Asegura que el sistema no clasifique el hilo libre de impurezas como defectuoso.
Recall	Mide la sensibilidad del sistema. Es vital para garantizar que ninguna instancia de vellosidad excesiva pase desapercibida por el modelo.
mAP@0.5 (Mask)	Evalúa la calidad de la segmentación. Mide qué tan bien la máscara generada por YOLO se ajusta a la forma irregular del defecto.

3.7 Análisis de XAI

Para garantizar que las decisiones del modelo sean interpretables y confiables, se realizó un análisis comparativo de técnicas de mapas de calor para la auditoría de la detección en la fibra de alpaca.

3.7.1 Limitaciones de Grad-CAM en redes profundas

Inicialmente, se evaluó la técnica *Grad-CAM* (Gradient-weighted Class Activation Mapping), la cual utiliza el flujo de retropropagación (*backpropagation*) para asignar pesos de


importancia a las neuronas de las capas convolucionales. Sin embargo, al aplicarse sobre la arquitectura YOLOv11 para la detección de detalles finos, los resultados no fueron satisfactorios debido a las restricciones inherentes del método.

Como se observa en la Figura 23, existe una degradación progresiva de la fidelidad visual:

- **Capas Iniciales (Feature 0 a 2):** Los mapas de características logran retener gran parte de la estructura lineal del hilo de alpaca.
- **Capas Intermedias y Profundas (Feature 6 a 16):** Debido a la naturaleza de Grad-CAM en redes profundas, los mapas de calor presentan un alto nivel de ruido visual y una pixelación extrema.
- **Distorsión Estructural:** En las etapas finales (específicamente en Feature 10 y Feature 21), la información espacial se transforma en bloques de baja resolución que impiden una interpretación clara. Esta distorsión hace que el área de atención no se ajuste con precisión a la morfología sutil de los neps y vellosidades, imposibilitando una auditoría técnica confiable.

Figura 23

Evolución de los mapas de características bajo Grad-CAM



3.7.2 Optimización mediante Eigen-CAM

Como alternativa a los métodos de explicabilidad basados en gradientes, se implementó Eigen-CAM, técnica que utiliza el Análisis de Componentes Principales (PCA) sobre las activaciones internas de la red. Mediante la proyección sobre el primer componente principal (PC1),

se obtuvieron mapas de activación que permitieron visualizar las regiones con mayor presencia de información representacional. Para ello, se utilizaron *hooks* de PyTorch sobre diferentes capas del modelo YOLO11m-seg.

La auditoría de las activaciones permitió observar la evolución jerárquica de las características extraídas. En capas iniciales, como la Capa 5 (*Conv*), las activaciones conservaron principalmente información local asociada con bordes, texturas y estructuras generales de la fibra. En la Capa 16 (*C3k2*), se observó un mayor enfoque sobre la estructura del hilo, los neps y las fibras sobresalientes asociadas con la vellosidad. Este comportamiento resulta consistente con el principio de representación jerárquica de las redes convolucionales y con estudios previos de inspección de defectos de pequeña escala, como Jiang et al. (2021), donde se destaca la importancia de mantener un equilibrio entre información semántica y resolución espacial.

Por este motivo, la Capa 16 fue seleccionada como el punto principal de observación para la auditoría mediante Eigen-CAM. Esta selección se sustentó tanto en su posición dentro de la jerarquía de representaciones como en la correspondencia observada experimentalmente entre sus activaciones y las regiones asociadas a los defectos de interés. Las capas más profundas, como la Capa 20 (*Conv*) y la Capa 22 (*C3k2*), fueron utilizadas como referencia para comparar el comportamiento de las representaciones de mayor abstracción.


Finalmente, para evitar que la interpretación dependiera únicamente de la inspección visual de los mapas de activación, las regiones resaltadas por Eigen-CAM fueron sometidas posteriormente a experimentos de ablación y perturbación. Estos experimentos permitieron evaluar si la modificación de las regiones identificadas como relevantes producía cambios coherentes en la respuesta del modelo.

3.7.3 Justificación de la selección del método


La elección de Eigen-CAM se fundamenta en su capacidad para proporcionar una auditoría visual robusta. La Tabla 16 resume los criterios técnicos que determinaron su selección definitiva.

Figura 24

Visualización de la progresión de atención en diferentes niveles de la arquitectura.



Análisis de activaciones en capas intermedias (Capa 5 y Capa 16).



Análisis de activaciones en capas profundas de salida (Capa 20 y Capa 22).

Tabla 16

Comparativa técnica para la selección del método de explicabilidad.

Criterio	Grad-CAM	Eigen-CAM (Seleccionado)
Mecanismo	Basado en gradientes (retropropagación).	Basado en activaciones (PCA).
Claridad Visual	Baja: Pixelación y ruido en capas profundas.	Alta: Mapas de calor nítidos y definidos.
Interpretación	Difícil: El ruido visual genera desconfianza.	Directa: Resalta la varianza real del defecto.
Confiabilidad	Sensible a la saturación de la red.	Robusto ante la profundidad arquitectónica.

3.8 Bucle de mejora iterativo

El diseño iterativo del proceso metodológico contempló un bucle de mejora explícito que fue ejecutado en tres iteraciones completas a lo largo de la investigación.

3.8.1 *Curación de datos*

La curación de datos fue la acción de mejora ejecutada de forma sistemática en las tres iteraciones del bucle metodológico. Este proceso consistió en el refinamiento del conjunto de datos e implicó las siguientes actividades:

1. **Revisión de anotaciones de bajo desempeño:** Se identificaron imágenes donde el modelo presentaba dificultades de segmentación. El análisis reveló que las versiones iniciales incluían ruido de fondo y vellosidades microscópicas que no correspondían a defectos comerciales bajo la norma ASTM D2255.
2. **Re-etiquetado bajo criterio experto:** Se corrigieron las máscaras manuales ajustando los polígonos a la morfología real del defecto. En esta fase, se eliminaron etiquetas que no cumplieran con los estándares de visibilidad industrial, depurando el dataset de información irrelevante.
3. **Incorporación de muestras críticas:** Se integraron nuevas capturas de neps pequeños y vellosidad de baja densidad para fortalecer la sensibilidad del sistema ante irregularidades sutiles.

Validación mediante el Gold Standard: Un hito fundamental en la maduración del dataset fue la transición hacia un conjunto de datos de referencia denominado *Gold Standard*. Inicialmente, el etiquetado se realizó de forma autónoma, lo que derivó en la inclusión de fibras detectadas mediante zoom digital que no representaban defectos reales en una inspección estándar. Tras una consulta técnica con especialistas del CITE Textil Camélidos Cusco, se rectificó el criterio de anotación para enfocarse únicamente en las irregularidades visibles a simple vista.

La evolución visual de este refinamiento se detalla en la Figura 25, donde se observa la transición técnica desde un etiquetado genérico hasta una segmentación de instancias especializada:


- **Etapa 1 (Captura inicial):** Se utilizó una máscara única de color amarillo que agrupaba neps y vellosidad, integrando involuntariamente píxeles del fondo y generando confusión en el aprendizaje de texturas. En esta fase, las vellosidades se etiquetaron realizando ampliaciones profundas en la imagen; no obstante, al regresar a la escala de inspección general, estas anotaciones no cumplían con los estándares de apariencia textil al incluir detalles imperceptibles que no afectaban la clasificación del hilo.
- **Etapa 2 (Refinamiento de contorno):** Se ajustó la máscara a color verde para aislar el defecto del ruido de fondo, mejorando la localización espacial. A pesar de este avance, la vellosidad permanecía vinculada a la clase del nep y el etiquetado continuaba basándose en fibras microscópicas detectadas mediante zoom, lo que carecía de coherencia con los criterios de severidad exigidos en una inspección visual estándar.
- **Etapa 3 (Segmentación de instancias final):** Se logró la separación absoluta de clases, permitiendo un diagnóstico multiclase efectivo. Las anotaciones se refinaron para incluir únicamente aquellas vellosidades visibles a simple vista, alineándose estrictamente con los umbrales de longitud validados por los expertos del CITE Textil Camélidos Cusco. Bajo esta configuración, el sistema diferencia con éxito el nep (instancia verde) de cada filamento de vellosidad (instancias rojas).

Figura 25


Evolución técnica del proceso de anotación



Etapa 1: Segmentación unificada.



Etapa 2: Refinamiento de contornos.



Etapa 3: Segmentación de instancias multiclase.

3.8.2 *Ajuste de la arquitectura y los hiperparámetros*

En paralelo a la curación de datos, cada iteración del bucle incluyó el análisis de los hiperparámetros de entrenamiento y la evaluación de variantes alternativas de la arquitectura, con el objetivo de identificar configuraciones que explotaran mejor la información disponible en el dataset refinado. Los ajustes realizados entre iteraciones incluyeron: modificación de la resolución de entrada, variación de los pesos de la función de pérdida, ajuste de la política de aumentación de datos y evaluación de distintas variantes de tamaño del modelo (*nano*, *small*, *large*).

3.9 Estructura y Funcionamiento del Sistema de Visión Computacional

Como etapa de evaluación dentro de la metodología, se desarrolló un entorno gráfico interactivo concebido exclusivamente como una plataforma de pruebas internas y validación experimental del modelo. Este sistema opera de manera directa mediante la ejecución de código Python, sirviendo como un entorno de simulación controlado para cargar y evaluar las muestras pertenecientes al 10 % del dataset reservado exclusivamente para el conjunto de prueba (*Test Set*), las cuales se mantuvieron totalmente aisladas y ajenas al proceso de entrenamiento. Esto permite al investigador realizar ensayos de laboratorio independientes, auditar visualmente el comportamiento práctico del algoritmo frente a muestras no observadas durante el aprendizaje y verificar la precisión de sus respuestas de manera directa antes de considerar cualquier implementación comercial.

3.9.1 *Especificaciones y Arquitectura del Software*

Para respaldar la concepción del sistema informático, se resumen sus requerimientos clave y la organización modular que estructura el software:

Requerimientos del Sistema

- **Ingesta y Acondicionamiento:** Carga directa de imágenes digitales de alta resolución y conformación del tensor de entrada sin requerir preprocesamiento manual por parte del

operario.

- **Inferencia y Segmentación:** Detección y delimitación espacial de instancias multiclase (*neps* y *vellosidad*) mediante máscaras poligonales de segmentación.
- **Diagnóstico y Evaluación:** Cuantificación automática de imperfecciones y categorización de conformidad del hilo según los umbrales de tolerancia técnica.
- **Rendimiento e Interfaz:** Visualización gráfica interactiva con latencia de respuesta en tiempo real y exportación de reportes de auditoría en formato estructurado (.csv).

Arquitectura por Subsistemas

Para garantizar modularidad y mantenibilidad, el software se estructura en cuatro subsistemas lógicos interconectados:

1. **Subsistema de Adquisición e Ingesta Digital:** Gestiona la carga de la imagen cruda, validación de formato y normalización para el procesamiento.
2. **Subsistema de Inferencia y Visión Computacional:** Aloja el motor de red neuronal (YOLO11m-seg) para extraer las características y generar las máscaras de cada defecto.
3. **Subsistema de Clasificación y Diagnóstico:** Aplica el motor de reglas de negocio sobre el conteo de instancias para emitir el veredicto técnico de calidad de la muestra.
4. **Subsistema de Interfaz y Reporte:** Despliega los resultados gráficos superpuestos en pantalla y administra la persistencia de los metadatos de auditoría.

3.9.2 Módulo de Análisis de Imágenes y Diagnóstico Experimental

Este componente permite evaluar el desempeño del modelo en condiciones controladas a partir de archivos digitales estáticos, estructurándose en dos fases consecutivas:

Toma y clasificación de imágenes: El proceso inicia al introducir una fotografía de la muestra de hilado en la interfaz. En esta etapa, el sistema destaca por su versatilidad al recibir imágenes completamente crudas y directas de la captura, sin necesidad de que el usuario realice ningún

tipo de preprocesamiento, recorte o edición manual previa. De forma inmediata, el modelo de visión computacional procesa la muestra, aísla el fondo y ejecuta la segmentación de instancias.

Diagnóstico e información técnica: Concluida la segmentación, el sistema aplica los criterios de tolerancia. A partir del conteo de instancias, la interfaz calcula el nivel de calidad de la muestra y emite un veredicto experimental bajo tres estados de control:

- **Hilo Aceptado (Calidad Buena):** Muestras que registran una presencia mínima de defectos, manteniéndose estrictamente dentro de los límites de ≤ 1 nep y ≤ 4 vellosidades en promedio (Figura 26). Este rango se fundamenta en los criterios empíricos validados junto a la especialista (Castillo Yepes et al., 2022), definiendo una línea de base óptima y de alto valor agregado para hilados artesanales de titulación *Nm 5*.

Figura 26
Interfaz de pruebas procesando una muestra óptima.



- **Hilo Aceptado (Calidad Moderada):** Muestras que exhiben un nivel intermedio de imperfecciones tolerables, situándose en el rango de ≤ 3 neps y ≤ 7 vellosidades en promedio (Figura 27). Este umbral define el límite de tolerancia del sistema según los parámetros de clasificación sugeridos por la especialista (Castillo Yepes et al., 2022), permitiendo absorber la variabilidad intrínseca del hilado manual sin devaluar el producto.

Figura 27
Interfaz de pruebas identificando una densidad intermedia de defectos.



- **Hilo Rechazado (Calidad Mala):** Casos donde la concentración de defectos excede los límites máximos tolerables determinados por la especialista (Castillo Yepes et al., 2022) (> 3 neps o > 7 vellosidades en promedio), como se detalla en la Figura 28. Esta condición activa el descarte automático del algoritmo, ya que compromete severamente la resistencia mecánica a la tracción del material.

Figura 28
Interfaz de pruebas detectando una alta concentración de imperfecciones.



Simultáneamente, la interfaz despliega y registra el monitoreo técnico derivado del proceso de inferencia sobre las muestras del subconjunto de prueba (*Test Set*). Con el propósito de optimizar la gestión, análisis e interoperabilidad de la información, el sistema permite exportar estos metadatos técnicos en formatos estructurados (.csv o .txt). Dicho reporte consolida las características de inferencia propias de la muestra analizada: la cuantificación detallada de imperfecciones por clase (*neps* y *vellosidad*), los niveles de confianza promedio de predicción, el tiempo de inferencia computacional en milisegundos, la extensión de las máscaras de segmentación generadas y el veredicto final de aceptabilidad (*Hilo Aceptado* o *Hilo Rechazado*). Cabe precisar que las métricas de evaluación global del modelo (*TP*, *FP*, *FN*, *Precisión* y *Recall*) son consolidadas a nivel de arquitectura en el módulo de evaluación estadística del sistema, mientras que el archivo exportable se enfoca en el registro ordenado de las variables operativas y diagnósticas de cada ensayo.

CAPÍTULO IV

RESULTADOS

4.1 Evaluación y validación del entorno de captura

El cumplimiento del primer objetivo específico se validó mediante un análisis comparativo entre el prototipo inicial y el entorno de laboratorio final. Aunque el primer diseño (caja artesanal) permitió establecer los parámetros básicos de inspección, los resultados demostraron que la falta de una iluminación constante en todas las áreas del campo visual introducía ruido lumínico y sombras que afectaban la fidelidad de los bordes de las fibras.

4.1.1 *Comparativa de iluminacion y estabilidad*

Para asegurar la calidad de los datos de entrada, se evaluó la respuesta del sensor de 64 MP en ambos escenarios. Los hallazgos se resumen a continuación:

- **Prototipo artesanal:** Presentó fluctuaciones de intensidad lumínica superiores al 15 % entre el centro y los extremos de la muestra de hilo. Esto generaba artefactos de segmentación donde fibras de vello reales se perdían en zonas subexpuestas.
- **Cabina de luz de laboratorio:** Proporcionó una iluminación difusa homogénea. El uso de una fuente de luz estándar permitió una reflectancia uniforme en la fibra blanca de alpaca, incrementando la relación señal-ruido y facilitando que los modelos YOLO identifiquen texturas de escala micrométrica sin confusión por sombras proyectadas.

Como se observa en la Figura 29, se determinó que la cabina de luz es el entorno óptimo para garantizar la reproducibilidad científica del sistema, logrando una estabilidad de imagen necesaria para el entrenamiento.

Figura 29

Comparativa de los entornos de adquisición evaluados para la captura de fibra de alpaca.



Entorno artesanal con iluminación irregular.



Entorno de laboratorio (Cabina de luz) con iluminación homogénea.

4.2 Constitución y características del dataset de hilo artesanal


El cumplimiento del segundo objetivo específico se consolidó mediante la creación de un dataset especializado para la identificación de irregularidades en el hilado artesanal. Este recurso se constituye como una base de datos técnica inédita para la fibra de alpaca Huacaya en la región del Cusco .

4.2.1 Composición cuantitativa y selección de muestras

Como se observa en la Figura 30, para garantizar la transparencia y el rigor científico en la organización de los datos, el conjunto de imágenes fue gestionado íntegramente en la plataforma Roboflow, conformando un dataset definitivo de 500 imágenes de alta fidelidad diagnóstica seleccionadas bajo criterios de nitidez y representatividad de los defectos técnicos más recurrentes.

Figura 30

Gestión y organización del dataset de hilo artesanal en la plataforma Roboflow.



El proceso de anotación se rigió por los siguientes pilares técnicos:

- **Segmentación de instancias:** Cada defecto fue delimitado mediante máscaras poligonales en lugar de cajas convencionales. Este método permite una cuantificación exacta del área afectada, facilitando la evaluación de severidad .
- **Alineación con la Norma ASTM D2255:** La identificación de irregularidades se realizó bajo los criterios de apariencia exigidos internacionalmente para asegurar la competitividad del hilado .
- **Validación por expertos:** La veracidad del etiquetado contó con la supervisión de especialistas del CITE Textil Camélidos Cusco, garantizando que cada máscara represente fielmente un defecto real .

4.3 Reporte de resultados experimentales

El proceso de evaluación se basó en una metodología experimental evolutiva que comprendió diez entrenamientos distribuidos en dos fases. A continuación, se detallan los resultados de los modelos con mayor desempeño.

4.3.1 Fase 1: Experimentos preliminares con YOLOv8m-seg

De los 5 experimentos realizados se estableció el Experimento 3 como la línea base de rendimiento. Los resultados (Tabla 17) validaron la capacidad del modelo para segmentar neps, aunque evidenciaron una oportunidad de mejora en la detección de vellosidad mediante arquitecturas de nueva generación.

Tabla 17
Desempeño del modelo Fase 1: YOLOv8m-seg.

Clase	P	R	mAP@50	mAP@50-95
Global	0.510	0.518	0.479	0.139
Nep	0.713	0.684	0.727	0.218
Vellosidad	0.308	0.352	0.231	0.059

4.3.2 Fase 2: Experimentos principales con YOLO11

Como se detalla en la Tabla 18, durante la fase principal se analizaron las métricas de rendimiento obtenidas a partir de los subconjuntos de entrenamiento (*train*) y validación (*val*) pertenecientes al dataset consolidado del proyecto. A través de este análisis, se contrastaron los dos mejores resultados de un total de cinco experimentos ejecutados.

Tabla 18
Métricas globales: YOLO11m-seg vs. YOLO11l-seg.

Experimento	Bounding Box				Máscara			
	P	R	mAP@50	mAP@50-95	P	R	mAP@50	mAP@50-95
YOLO11m (Exp. 1)	0.787	0.617	0.713	0.341	0.744	0.589	0.654	0.237
YOLO11l (Exp. 2)	0.780	0.632	0.695	0.344	0.738	0.592	0.639	0.242

4.3.3 Análisis detallado por clase

El desglose por tipo de defecto que describe la Tabla 19 permite evaluar la especialización de cada modelo. *YOLO11m* destaca en la precisión de ambas clases, mientras que *YOLO11l* ofrece mejoras marginales en la sensibilidad (*Recall*).

Tabla 19

Rendimiento por clase (Métrica de Máscara): *YOLO11m* vs. *YOLO11l*.

Clase	Métrica	YOLO11m-seg	YOLO11l-seg
Nep	Precisión (P)	0.841	0.875
	Recall (R)	0.697	0.688
	mAP@50	0.782	0.761
Vellosidad	Precisión (P)	0.647	0.601
	Recall (R)	0.480	0.496
	mAP@50	0.526	0.517

4.4 Justificación de selección del modelo y eficiencia operativa

La decisión final se fundamenta en el equilibrio entre precisión y demanda computacional. La Tabla 20 evidencia que el modelo *YOLO11m* es significativamente más eficiente para un despliegue industrial.

Tabla 20

Comparativa de eficiencia operativa.

Parámetro	YOLO11m (Exp. 1)	YOLO11l (Exp. 2)
Épocas totales ejecutadas	227	357
Mejor época del modelo	157	207
Paciencia (<i>patience</i>)	70	150
Tiempo total de entrenamiento	15.56 h	153.40 h
Latencia de inferencia (ms)	53.9 ms	70.5 ms

Conclusión de selección: Se selecciona el modelo **YOLO11m-seg** (Experimento 1) como la solución óptima. A pesar de las mejoras marginales de la versión *Large* en el *mAP@50-95*, la arquitectura *Medium* garantiza una precisión superior en el *mAP@50* global y una eficiencia operativa drásticamente mayor, reduciendo el tiempo de entrenamiento en un 90 % y la latencia en un 23.5 %.

4.5 Resultados Graficos

4.5.1 Resultados de segmentación de instancias

La evaluación del modelo **YOLO11m-seg** se realizó comparando las etiquetas manuales con las inferencias generadas por la red neuronal. En la Figura 31, se presentan las anotaciones originales que sirven como referencia técnica, mientras que en la Figura 32 se visualiza el desempeño del modelo en condiciones de validación.

Figura 31
Conjunto de etiquetas de validación (Ground Truth).





Figura 32
Resultados de la inferencia realizada por el modelo YOLO11m-seg.




- **Eficacia en Neps:** Los resultados para la Clase 0 son altamente precisos. El modelo segmenta con éxito las estructuras nodulares con una confianza de hasta 0.8, validando que la red identifica correctamente la saturación de píxeles característica de estos defectos.
- **Complejidad de la Vellosidad:** En la Clase 1, el sistema logra mapear las proyecciones radiales de fibra con una confiabilidad del 64.7 %. Se observa que el modelo es eficaz localizando la vellosidad, aunque la ambigüedad morfológica de los filamentos submili-métricos representa el mayor desafío para obtener máscaras de segmentación perfectas.

4.5.2 Análisis de las curvas Precisión–Recall

La Figura 33 ilustra la relación entre la precisión y la sensibilidad del modelo YOLO11m-seg. El área bajo la curva de cada clase representa el balance entre la capacidad de encontrar defectos y la certeza de los mismos.

Figura 33
Curvas Precisión–Recall global del modelo seleccionado.



- **Grado de confianza general del sistema:** El valor de $mAP@0,5$ de 0,713 funciona como la calificación final de la inteligencia artificial. Este número nos dice que el sistema es lo suficientemente maduro para trabajar en un entorno real, ya que logra un equili-

brio casi ideal: es lo suficientemente sensible para no dejar pasar los defectos, pero lo suficientemente inteligente para no dar falsas alarmas con el hilo que está en buen estado.


- **Efectividad detectando Neps:** Los neps son fáciles de ver para el ojo humano, y la IA también los identifica con gran éxito, logrando un puntaje de 0,730. La curva muestra que el sistema es sumamente seguro con esta clase: incluso cuando le pedimos que sea muy estricto, mantiene una precisión superior al 85 %.
- **Sensibilidad ante la Velloalidad:** Identificar la velloalidad es el reto más grande, ya que son pelos microscópicos y difíciles de capturar, lo que se refleja en su valor de 0,696. Sin embargo, la curva nos revela un comportamiento clave: cuando el sistema no está 100 % seguro de si un brillo en la imagen es un pelo suelto o un error de la foto, prefiere no marcarlo para evitar alertas innecesarias.

4.5.3 Análisis de la matriz de Confusión

La Figura 34 presenta la matriz de confusión para el modelo seleccionado.

Figura 34

Matriz de confusión — YOLO11m-seg.



- **Robustez en la detección de Neps:** La clase nep alcanzó una precisión del 84.1 %, sustentada por la identificación correcta de 104 instancias y una mínima tasa de falsas alarmas (solo 19 casos). Esta alta confiabilidad se debe a la morfología compacta y la firma espectral densa de los nudos, los cuales generan un contraste marcado frente al núcleo del hilo.
- **El desafío de la fibra fina:** El error más frecuente del sistema fue no detectar algunos pelos sueltos (813 casos de vellosidad omitidos). Esto no se debe a un fallo en el programa, sino a la propia naturaleza de la alpaca: sus fibras son tan delgadas y sus bordes tan irregulares que, a veces, se confunden visualmente con el fondo de la imagen según la luz o el enfoque. En la práctica, el modelo prefiere ser "precavido": solo marca la vellosidad cuando está muy seguro de que existe, evitando dar avisos falsos por simples manchas o ruido en la foto.
- **Discriminación de características y pureza de clases:** Un hallazgo de alto valor científico es la nula confusión cruzada entre las clases nep y vellosidad. Este aislamiento de características demuestra la efectividad de la arquitectura YOLO11m-seg para realizar una extracción de rasgos jerárquicos diferenciada; el sistema logra separar exitosamente neps y vellosidad basándose en la densidad espacial y la geometría de la máscara. Este éxito en la clasificación multiclase valida el rigor del proceso de etiquetado manual y la curación del dataset, confirmando que el modelo ha aprendido a emular el criterio experto del clasificador humano al distinguir tipos de defectos morfológicamente opuestos.


4.5.4 Evaluación del proceso de aprendizaje y convergencia

El rendimiento del modelo YOLO11m-seg fue monitoreado a través de las funciones de pérdida y métricas de precisión durante las 227 épocas ejecutadas. Para garantizar la capacidad de generalización del sistema ante la variabilidad del hilado artesanal de la región del Cusco, se aplicó una política de parada temprana (*early stopping*) con una paciencia de 70 épocas.

En la Figura 35, se presenta la evolución de las métricas críticas que justifican la selección de los pesos finales del modelo.

Figura 35

Análisis de convergencia y estabilidad del modelo seleccionado.



Interpretación del sobreajuste y eficiencia operativa

Como se observa en la Figura 35a, la pérdida de segmentación en el entrenamiento exhibe un descenso asintótico constante, validando que la arquitectura logró extraer las características morfológicas de los neps y vellosidades presentes en el dataset. No obstante, al analizar la pérdida de validación en la Figura 35b, se identifica un punto de inflexión alrededor de la época 30, a partir del cual el error comienza una tendencia ascendente moderada.

Este comportamiento, característico del sobreajuste en materiales biológicos complejos, fue gestionado mediante la selección de la **época 157** como la mejor variante del modelo (*Best Epoch*). El uso de una paciencia de 70 épocas permitió verificar que la pérdida de validación no regresaría a valores inferiores, confirmando que la época 157 ofrece el equilibrio óptimo entre aprendizaje y capacidad de generalización.

A pesar del incremento en la función de pérdida de validación, la métrica de rendimiento real *mAP@50* para máscaras mostrada en la Figura 35c se mantuvo estable y en crecimiento gradual hasta el final del proceso, alcanzando un valor superior al 60 %. Esto demuestra que el sobreajuste detectado es de carácter leve y no degrada la precisión diagnóstica del sistema. Finalmente, la eficiencia del modelo se valida con un tiempo de entrenamiento de 15.56 h

y una latencia de inferencia de **53.9 ms** por imagen, lo que equivale a un procesamiento de aproximadamente 18.5 FPS, garantizando su operatividad en tiempo real para la industria textil regional.

Evaluación final de integridad del modelo: Tras el análisis exhaustivo de la divergencia entre las funciones de pérdida de entrenamiento y validación, se concluye que el fenómeno de sobreajuste (*overfitting*) identificado es de carácter leve a moderado. Esta condición se atribuye principalmente a la naturaleza estocástica y la alta variabilidad biológica intrínseca de la fibra de alpaca Huacaya, donde factores como la distribución y las fluctuaciones aleatorias en el diámetro del hilo artesanal introducen una complejidad morfológica superior a la de fibras sintéticas. Asimismo, la ambigüedad visual de las vellosidades submilimétricas y su bajo contraste frente al fondo de captura facilitan que el modelo intente memorizar detalles específicos de la textura en lugar de rasgos universales del defecto. No obstante, esta condición no compromete la validez científica del sistema, ya que la métrica de rendimiento real *mAP@50* mantuvo una trayectoria de convergencia estable, demostrando que el modelo conserva una alta capacidad de generalización para la detección de defectos en entornos de producción reales.

4.6 Interpretación de resultados finales

El análisis final del modelo seleccionado, YOLO11m-seg, permite concluir su idoneidad para el entorno industrial basado en tres pilares técnicos:

- **Especialización morfológica (Precisión):** El sistema demuestra una alta fiabilidad en la detección de neps con precisión de 84.1 %, validando que la arquitectura captura con éxito estructuras nodulares. En vellosidad, aunque la segmentación es compleja por su naturaleza difusa, el modelo logra mapear tendencias críticas de riesgo de pilling con una precisión del 64.7 %, eliminando la subjetividad del inspector humano.
- **Eficacia en la cobertura (Recall):** El sistema garantiza la captura de aproximadamente 7 de cada 10 neps con un recall de 69.7 %, asegurando una purga efectiva de los nudos que más comprometen la calidad táctil. En cuanto a la vellosidad, el modelo identifica cerca del 48.0 % de las zonas afectadas; este rendimiento se sustenta como un avance

significativo dada la naturaleza filamentosa, el bajo contraste y la ambigüedad visual de las fibras individuales. Lograr esta cobertura permite mapear tendencias de irregularidad y riesgo de pilling que la inspección manual suele omitir por fatiga.

- **Superioridad operativa de la variante Medium:** Se confirma que el modelo YOLO11m es la opción óptima frente a la versión Large. No solo alcanzó una mayor precisión general $mAP@50$, sino que lo logró con un ahorro del 90 % en tiempo de entrenamiento y una latencia de 53.9 ms. Estos valores aseguran un procesamiento en tiempo real 18 FPS viable para dispositivos de recursos limitados en talleres locales.

Conclusión: La integración de un dataset robusto con la arquitectura YOLO11m-seg transforma la inspección artesanal en un proceso auditable y eficiente, logrando un equilibrio entre precisión diagnóstica y viabilidad computacional.

4.7 Auditoría del modelo mediante Explicabilidad (XAI)

El cumplimiento del cuarto objetivo específico se evaluó mediante la técnica Eigen-CAM, con el propósito de inspeccionar las representaciones internas del modelo y determinar si las detecciones de *neps* y vellosidad se concentran en regiones visualmente asociadas con las características morfológicas de los defectos.


4.7.1 Análisis detallado de activaciones: Capa 16 (C3k2)

La inspección de la **Capa 16**, correspondiente a un bloque C3k2 del *neck* de la red, permitió analizar las características utilizadas por el modelo para representar la estructura del hilado, como se muestra en la Figura 36. En comparación con las capas iniciales, esta representación presenta una mayor concentración de las activaciones sobre las regiones asociadas con los defectos de interés.

- **Localización de Neps:** Se observa una activación intensa, representada mediante tonos cálidos, sobre las aglomeraciones nodulares correspondientes a los *neps*. Esta concentración indica una mayor respuesta de la representación interna en las regiones donde se encuentra el defecto.

- **Segregación de Vellosidad:** El mapa de activación resalta las fibras que sobresalen del cuerpo principal del hilo, diferenciándolas parcialmente de la estructura central. Esto evidencia que la Capa 16 conserva información espacial suficiente para representar las características asociadas con la vellosidad.
- **Respuesta sobre el fondo:** Se observa una menor intensidad de activación en las regiones alejadas de los defectos, aunque persisten algunas respuestas residuales alrededor de la estructura del hilo. Este comportamiento permite diferenciar las zonas de mayor relevancia de aquellas con menor respuesta representacional.

Figura 36
Ampliación de la Capa 16 (C3k2).



Interpretación de las activaciones

Los resultados obtenidos muestran que la Capa 16 proporciona una representación adecuada para analizar visualmente las regiones asociadas con los defectos del hilado. A diferencia de las representaciones de menor nivel, las activaciones observadas presentan una mayor concentración sobre las estructuras relevantes, permitiendo inspeccionar la correspondencia entre las características visuales del hilo y las regiones consideradas por el modelo. Por tanto, esta capa se empleó como punto principal de observación para la auditoría mediante Eigen-CAM.

4.7.2 Validación mediante Experimentos de Ablación y Perturbación

Para evaluar si las regiones resaltadas por Eigen-CAM presentan una relación funcional con la predicción del modelo y no corresponden únicamente a coincidencias visuales, se realizaron experimentos de ablación y perturbación sobre una muestra del conjunto de prueba. Los resultados se presentan en la Figura 37.


- **Condición 1 (Línea Base – Original):** Corresponde al estado nominal de inferencia sobre una muestra del conjunto de prueba. El modelo YOLO11m-seg identifica las instancias de *neps* y vellosidad con una confianza máxima de 0,83. El mapa de Eigen-CAM presenta una mayor concentración de activaciones en las regiones correspondientes a la estructura del hilo y a las deformaciones asociadas con los defectos.
- **Condición 2 (Ablación por Desvanecimiento):** Se aplicó un enmascaramiento degradado sobre las regiones correspondientes a los defectos principales con el propósito de reducir su información visual. Como resultado, se observa una disminución de las activaciones de mayor intensidad en las regiones previamente resaltadas, especialmente sobre los *neps*. Se mantienen algunas activaciones alrededor del cuerpo del hilo, correspondientes a características de la estructura que permanecen visibles.
- **Condición 3 (Perturbación por Oclusión):** Se introdujeron bloques neutros de color plomo sobre una región del fondo y sobre un segmento del hilo sano. El mapa de Eigen-CAM muestra una reducción de la activación en las zonas ocluidas. Sin embargo, en la región lateral donde el *nep* permanece visible, el modelo conserva la activación y mantiene la detección con una confianza de 0,78.

En conjunto, los resultados muestran un comportamiento consistente con la hipótesis de relevancia de las regiones resaltadas por Eigen-CAM: la modificación de las regiones asociadas con los defectos produce una reducción de las activaciones correspondientes, mientras que la perturbación de regiones no asociadas directamente con el defecto permite conservar la detección cuando este permanece visible. Estos resultados proporcionan evidencia experimental

complementaria a la inspección visual de los mapas de activación y fortalecen la auditoría de explicabilidad del modelo.

Figura 37


Auditoría de explicabilidad del modelo YOLO11m-seg en la Capa 16 (C3k2) mediante experimentos de ablación y perturbación.



4.8 Síntesis Operativa del Sistema Integrado

Para consolidar el impacto tecnológico de esta investigación, la Figura 38 presenta el diagrama operativo final.

Figura 38
Diagrama integral del proceso transformativo de fibra.



Fase I: Preparación artesanal de la fibra

Esta etapa inicial abarca todo el tratamiento de la materia prima, desde el vellón crudo con impurezas hasta la obtención del hilo artesanal titulación Nm 5, tal como se ilustra en la secuencia superior de la Figura 38. El flujo comprende los procesos consecutivos de lavado, escarmenado o apertura manual, y cardado mecánico. Aunque este trabajo preserva el valor cultural y la exclusividad del hilado tradicional, su naturaleza manual genera de forma inevitable variaciones y defectos estructurales como *neps* y vellosidades, los cuales se convierten en los problemas de calidad específicos que el sistema debe resolver.

Fase II: Sistema automático de control de calidad - YOLO 11

Aquí se ejecuta la solución tecnológica mediante una estructura organizada en cuatro etapas consecutivas, identificadas como los Módulos A, B, C y D en la Figura 38. El proceso inicia con la captura óptica del hilo usando una cabina de luz. Luego, en la fase de *dataset*, se realiza la anotación digital de las muestras de hilo. Estos datos entrenan y alimentan la arquitectura YOLO 11 (basada en bloques C3k2, *Neck* y *Head* de segmentación), permitiendo que la interfaz en tiempo real reemplace la inspección visual humana por una evaluación cuantitativa, automatizada y repetible.

Fase III: Interpretabilidad e Inferencia - Eigen-CAM + YOLO 11

Como validación técnica esencial frente a instituciones supervisoras, la sección inferior de la Figura 38 detalla el análisis de explicabilidad del sistema. Utilizando Eigen-CAM sobre la Capa 16 (C3k2) del *backbone*, el sistema genera un mapa de activaciones que demuestra visualmente cómo el modelo discrimina el ruido del fondo y se enfoca estrictamente en la morfología del hilo. Esto respalda la transparencia y fiabilidad del resultado de la segmentación por instancia, el cual delimita con precisión los contornos de vellosidad y *neps* detectados en el cuerpo del tejido.

DISCUSIONES

1. Análisis de resultados respecto a los objetivos

El cumplimiento de las metas técnicas y científicas de esta investigación se evidencia a través de la integración de los siguientes hitos:

- **Optimización del entorno de adquisición:** El primer objetivo específico se alcanzó mediante la transición de una caja cerrada artesanal hacia una cabina de luz de laboratorio. Esta decisión técnica permitió estandarizar la iluminación LED y el fondo neutro, lo que resultó crítico para obtener imágenes con la nitidez necesaria para capturar el hilo artesanal de escala micrométrica, superando las limitaciones de distribución lumínica de las pruebas iniciales.
- **Consolidación del Dataset:** La creación de un dataset con 30,768 instancias anotadas mediante segmentación de instancias permitió cumplir con el segundo objetivo. El uso de máscaras poligonales en lugar de cajas delimitadoras fue fundamental para representar la naturaleza de la vellosidad y la forma nodular de los neps, proporcionando una base de entrenamiento con alta fidelidad morfológica que no se habría logrado con métodos de detección clásica.
- **Eficacia en la selección de algoritmos:** Respecto al tercer objetivo, la evaluación comparativa determinó que el modelo YOLO11m-seg es la arquitectura más efectiva. Lograr un Mask mAP@50 de 0.654 y una precisión global de 0.744 valida la capacidad del sistema para automatizar el control de calidad. El equilibrio entre la detección de neps 84.1 % de precisión y la velocidad operativa asegura que se ha cumplido el propósito general de reducir la subjetividad en la producción artesanal.
- **Validación mediante explicabilidad:** El cuarto objetivo se cumplió satisfactoriamente mediante la técnica Eigen-CAM. La auditoría del flujo de atención demostró que el modelo ignora el ruido de fondo y se concentra en las características físicas

reales del hilo artesanal, garantizando que los resultados del sistema sean interpretables y confiables para el operario final.

2. Discusión de resultados respecto a los antecedentes

Al contrastar los hallazgos de esta tesis con la literatura científica y tecnológica existente, se identifican puntos de convergencia y avances significativos:

- **Superación de la brecha de accesibilidad:** A diferencia de los sistemas tradicionales como el USTER Tester o prototipos industriales de alto costo, esta propuesta demuestra que es posible alcanzar una fiabilidad competitiva utilizando hardware comercial de bajo costo. Mientras que estudios como el de Pereira et al. (2023) alcanzaron 45.45 FPS utilizando cámaras CMOS industriales especializadas, los 18 FPS obtenidos en esta investigación mediante un dispositivo móvil resultan técnicamente suficientes para el ritmo natural del hilado artesanal, validando la portabilidad del sistema para los talleres de Cusco.
- **Resiliencia ante hilos artesanales naturales complejos:** Gran parte de los antecedentes centran su validación en materiales homogéneos como el algodón o productos sintéticos. Esta investigación logra procesar el hilo artesanal de alpaca, cuya variabilidad biológica representa un desafío superior. El uso de aprendizaje profundo con YOLO11 demuestra ser más resiliente que los métodos de procesamiento clásico basados en umbrales fijos o algoritmos heurísticos, los cuales suelen fallar ante la naturaleza estocástica del hilo artesanal natural.
- **Análisis crítico de la sensibilidad en vellosidad:** Un hallazgo relevante es el recall del 48.0 % en la clase vellosidad. Al compararlo con la alta exactitud reportada por Jing et al. (2018) en hilos estándar, se observa que en la fibra de alpaca, la delgadez microscópica de los filamentos y el bajo contraste con el fondo exigen que el modelo adopte un comportamiento "precavido". Esta decisión algorítmica prioriza evitar falsas alarmas por ruido visual o brillo de la fibra blanca, asegurando que las detecciones sean auditables mediante Eigen-CAM.

- **Eficiencia operativa multiclase:** Mientras que trabajos previos como el de Haleem et al. (2021) se enfocaron en la detección de neps mediante algoritmos rígidos como Viola-Jones, esta investigación resuelve con éxito el análisis multiclase (vellosidad y neps) de forma simultánea. La nula confusión cruzada entre clases en la matriz de confusión valida el rigor del proceso de curación del dataset y confirma que la arquitectura de una sola etapa es óptima para la detección autónoma de defectos morfológicamente opuestos.

3. Validación mediante estándares de calidad industrial

Más allá del rendimiento algorítmico, la utilidad práctica de este sistema se valida al contrastar las detecciones de neps y vellosidad con los criterios de severidad de la norma ASTM D2255. Aunque el propósito central de esta investigación no es la certificación normativa, el uso de este estándar como marco de referencia permite situar los resultados en un contexto comercial real.

- **Análisis de aceptabilidad:** Al utilizar el Grado B como estándar de alta calidad objetivo y el Grado C como línea base de aceptabilidad técnica, el sistema permite que el evaluador identifique si la carga de irregularidades detectadas se mantiene dentro de los límites de uniformidad permitidos.
- **Aplicabilidad industrial:** Este contraste demuestra que la visión computacional, al identificar los mismos defectos críticos que define la normativa internacional, es una herramienta de diagnóstico viable para reducir la brecha entre la producción artesanal y los estándares industriales exigidos, permitiendo tomar decisiones basadas en evidencia técnica y no en la subjetividad visual.

CONCLUSIONES

Según los resultados obtenidos mediante el trabajo de investigación se obtienen las siguientes conclusiones:

1. Se logró desarrollar e implementar con éxito un sistema de visión computacional capaz de automatizar el control de calidad en el hilado artesanal de alpaca. Los resultados demuestran que la integración de inteligencia artificial permite transitar de una inspección subjetiva y manual hacia un monitoreo digital objetivo, logrando una precisión global de 0.744 en la segmentación de defectos y asegurando la estandarización técnica del producto final.
2. El diseño del entorno de adquisición fue determinante para la fidelidad de los datos. La transición hacia una cabina de luz de laboratorio garantizó una iluminación LED homogénea y un fondo de contraste controlado, factores que resultaron fundamentales para que la cámara capturara con nitidez las irregularidades del hilo artesanal, minimizando el ruido visual desde la etapa de entrada de datos.
3. La construcción del dataset especializado permitió establecer un estándar de referencia inexistente para el hilo artesanal de alpaca en la región. El etiquetado de 30,768 instancias mediante segmentación de instancias proporcionó al modelo una base de aprendizaje robusta, permitiendo que el sistema reconozca no solo la ubicación de los defectos, sino también su extensión superficial exacta, superando las capacidades de los métodos de detección convencional.
4. La evaluación algorítmica determinó que el modelo YOLO11m-seg es la solución tecnológica óptima para el entorno artesanal. Con un Mask mAP@50 de 0.654 y una velocidad de procesamiento de 18 cuadros por segundo, la arquitectura ofrece un equilibrio superior entre precisión técnica y eficiencia operativa, demostrando que es posible realizar inspecciones complejas en tiempo real utilizando hardware accesible y de bajo costo.

5. El análisis de explicabilidad mediante Eigen-CAM validó científicamente la confiabilidad del sistema. Se comprobó que el flujo de atención del modelo se centra estrictamente en la morfología de los neps y la vellosidad, descartando sesgos por texturas de fondo. Esto asegura que las decisiones del sistema son transparentes y se basan en criterios físicos reales, facilitando su aceptación y uso por parte de los productores textiles locales.

RECOMENDACIONES

1. Se recomienda la expansión del dataset mediante la inclusión de diversas titulaciones de hilo artesanal y la integración de nuevas clases de análisis de calidad. Se sugiere que futuras investigaciones incorporen la detección de parámetros como la uniformidad del hilo, el nivel de torsión y otras irregularidades estructurales, extendiendo las capacidades del sistema más allá de la identificación de neps y vellosidad. Si bien el presente estudio se centró en la titulación Nm 5, la adición de otros grosores y atributos físicos permitirá que el modelo mantenga su precisión ante la variabilidad del hilado.
2. Se recomienda profundizar en la modificación de la arquitectura del modelo, trascendiendo el uso de configuraciones preestablecidas. Futuras investigaciones podrían abrir la caja negra de la red neuronal, personalizando las capas de extracción de características (*backbone*) y los cabezales de segmentación (*head*) para optimizar la respuesta ante la morfología específica de las imperfecciones en la fibra de alpaca. Este diseño de arquitectura a medida permitiría ajustar la capacidad de la red para reconocer patrones intrincados, mejorando la sensibilidad frente a irregularidades que, por su escala y similitud con el entorno, resultan difíciles de capturar con arquitecturas genéricas.
3. Se sugiere la migración del sistema hacia arquitecturas de hardware dedicado y dispositivos de computación en el borde (como NVIDIA Jetson Nano o Raspberry Pi). La implementación en plataformas integradas permitiría ejecutar el control de calidad en tiempo real directamente en la línea de producción, facilitando una respuesta inmediata ante la aparición de defectos y asegurando un flujo de trabajo continuo y automatizado dentro del taller artesanal.
4. Es recomendable el desarrollo de una aplicación móvil con una interfaz simplificada diseñada específicamente para el operario. Esta herramienta debe transformar las métricas complejas de visión computacional en indicadores visuales de fácil interpretación, permi-

tiendo que el personal realice auditorías rápidas y tome decisiones sobre la clasificación del hilo artesanal de manera intuitiva y eficiente.

5. Se recomienda a las entidades gubernamentales y académicas de la región del Cusco promover la adopción de estas tecnologías de automatización mediante programas de transferencia técnica. La creación de centros de certificación digital para el hilo artesanal, basados en el sistema desarrollado, elevaría la competitividad de las asociaciones locales en el mercado internacional al garantizar productos con estándares de calidad objetivos y verificables.

BIBLIOGRAFÍA

- ASTM International (2017). D2255/d2255m-02(2017)e1: Standard test method for grading spun yarns for appearance. Technical report, ASTM International, West Conshohocken, PA.
- Castillo Yepes, L. E., Figueroa Quispe, W. A., and Puma Huaman, B. (2022). Finura al hilado y características de la fibra de alpaca huacaya blanca de la zona norte región puno 2019. *Revista de Investigaciones Científicas*, 4(1):25–34.
- CITE Camélidos Sudamericanos (2021). *Manual de Clasificación de la Fibra de Alpaca*. Ministerio de Comercio Exterior y Turismo (MINCETUR), Puno, Perú. Basado en la Norma Técnica Peruana NTP 231.301.2014.
- Ghiasi, G., Cui, Y., Srinivas, A., Qian, R., Lin, T.-Y., Cubuk, E. D., Le, Q. V., and Zoph, B. (2021). Simple copy-paste is a strong data augmentation method for instance segmentation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 5914–5923.
- Girshick, R., Donahue, J., Darrell, T., and Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 580–587. IEEE.
- Gonzalez, R. C. and Woods, R. E. (2018). *Digital Image Processing*. Pearson, New York, USA, 4 edition.
- Goswami, N. G. (2026). Ux for the “trust”: How explainable ai (xai) shapes fairness in ai. *Medium*. Consultado el 25 de abril de 2026.
- Haleem, N., Bustreo, M., and Del Bue, A. (2021). A computer vision based online quality control system for textile yarns. *Computers in Industry*, 133:103550.

- Hussain, M. (2024). YOLOv1 to YOLOv8: Unveiling each variant – a comprehensive review of YOLO. *IEEE Access*, 12:42816–42833.
- Ioffe, S. and Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, pages 448–456. PMLR.
- Jiang, P.-T., Zhang, C.-B., Hou, Q., Cheng, M.-M., and Wei, Y. (2021). Layercam: Exploring hierarchical class activation maps for localization. *IEEE Transactions on Image Processing*, 30:5875–5888.
- Jing, J., Huang, M., Li, P., and Ning, X. (2018). Automatic measurement of yarn hairiness based on the improved mrmrf segmentation algorithm. *The Journal of The Textile Institute*, 109(6):740–749.
- Jocher, G., Chaurasia, A., and Qiu, J. (2023). Ultralytics yolov8. Referencia principal para la pérdida DFL y arquitectura anchor-free.
- Khanam, R. and Hussain, M. (2024). YOLO11: An overview of the key architectural enhancements.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553):436–444.
- Li, Z., Zhong, P., Tang, X., Chen, Y., Su, S., and Zhai, T. (2020). A new method to evaluate yarn appearance qualities based on machine vision and image processing. *IEEE Access*, 8:30928–30937.
- Ministerio de Desarrollo Agrario y Riego (2023). 329 familias de criadores de Cusco logran comercializar directamente fibra alpaca a la industria textil. Accedido el 19 de abril de 2026.
- Muhammad, M. B. and Yeasin, M. (2020). Eigen-CAM: Class activation map using principal components. In *2020 International Joint Conference on Neural Networks (IJCNN)*, pages 1–7. IEEE.

- Padilla, R., Netto, S. L., and Da Silva, E. A. (2020). A survey on performance metrics for object-detection algorithms. *2020 international conference on systems, signals and image processing (IWSSIP)*, pages 209–214.
- Pereira, F., Macedo, A., Pinto, L., Soares, F., Vasconcelos, R., Machado, J., and Carvalho, V. (2023). Intelligent computer vision system for analysis and characterization of yarn quality. *Electronics*, 12(1):37.
- Rao, S. N. (2024). Yolov11 architecture explained: Next-level object detection with enhanced speed and accuracy. Publicado el 22 de octubre de 2024.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788. IEEE.
- Samek, W., Montavon, G., Vedaldi, A., Hansen, L. K., and Müller, K.-R. (2019). *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning*, volume 11700 of *Lecture Notes in Computer Science*. Springer, Cham, Switzerland.
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D. (2020). Grad-CAM: Visual explanations from deep networks via gradient-based localization. *International Journal of Computer Vision*, 128(2):336–359.
- Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4):427–437.
- Uster Technologies AG (2022). *USTER® TESTER 6: The Total Testing Center - Technical Data*. Uster Technologies AG, Uster, Switzerland. Document No. 05.22, Available online: www.uster.com.
- Yaseen, M. (2023). What is yolov8: An in-depth exploration of the internal features of the next-generation object detector. *National University of Computer and Emerging Sciences, Lahore*. Análisis técnico de la arquitectura Ultralytics.

Zhang, H., Cisse, M., Dauphin, Y. N., and Lopez-Paz, D. (2017). mixup: Beyond empirical risk minimization. *arXiv preprint arXiv:1710.09412*.


Zuiderveld, K. (1994). Contrast limited adaptive histogram equalization. In *Graphics gems IV*, pages 474–485. Academic Press Professional, Inc.

ANEXOS

A. Dataset gold standard

Figura 39

Muestra representativa del Dataset.



B. Algoritmos y configuraciones del sistema

B.1 Preprocesamiento y Aumentación de datos

Ecualización adaptativa (CLAHE)

Se aplicó CLAHE sobre el canal de luminosidad en el espacio de color para resaltar texturas finas de la fibra en condiciones de iluminación variable.

```
# Definicion de rutas del conjunto de datos de entrenamiento
img_dir="/home/laad-server/hilado/Hilado-Artesanal-12/train/images"
lbl_dir="/home/laad-server/hilado/Hilado-Artesanal-12/train/labels"

# Configuracion del objeto CLAHE
clahe = cv2.createCLAHE(
    clipLimit=2.0,
    tileGridSize=(8, 8)
)
```

```

# Recorrido de las imagenes en el directorio
for img_path in glob.glob(os.path.join(img_dir, "*.jpg")):
    base_name = os.path.basename(img_path)
    lbl_path = os.path.join(lbl_dir, os.path.splitext(base_name)[0]
        + ".txt")

    if not os.path.exists(lbl_path):
        continue

    # Verificacion de la presencia de Neps (Clase 0)
    with open(lbl_path, "r") as f:
        has_nep = any(line.strip().startswith("0") for line in f)

    if not has_nep:
        continue

    img = cv2.imread(img_path)
    if img is None:
        continue

    # Conversion al espacio de color LAB y separacion de canales
    lab = cv2.cvtColor(img, cv2.COLOR_BGR2LAB)
    l, a, b = cv2.split(lab)

    # Aplicacion de CLAHE al canal de luminosidad
    l_clahe = clahe.apply(l)
    lab_clahe = cv2.merge((l_clahe, a, b))
    img_clahe = cv2.cvtColor(lab_clahe, cv2.COLOR_LAB2BGR)

    # Almacenamiento de la imagen aumentada y copia de su etiqueta

```

```

new_img_name = "aug_clahe_" + base_name
cv2.imwrite(os.path.join(img_dir, new_img_name), img_clahe)

shutil.copy(
    lbl_path,
    os.path.join(lbl_dir, "aug_clahe_" + os.path.basename(
        lbl_path))
)

print("CLAHE_aplicado_con_exito_a_imagenes_con_Neps.")

```

Recorte y duplicado estratificado de Neps

Para mitigar el desbalance de clases, se implementó un recorte enfocado en las regiones de interés donde se detectaron *neps*, multiplicando la presencia de estas instancias críticas.

```

# 1. Rutina de extraccion espacial y ajuste de poligonos
def ultra_balance_neps(lines, img, x1, y1, base_name, w, h):
    # Extraccion de la region fija de 640x640 pixeles
    crop_img = img[y1:y1+640, x1:x1+640]

    # Recalculo dinamico de las coordenadas de las mascaras
    poligonales
    new_labels = adjust_polygons(lines, x1, y1, 640, 640, w, h)

    # Almacenamiento del recorte original y generacion de copias
    multiplicadoras
    cv2.imwrite(f"v5_nep_{base_name}.jpg", crop_img)
    for c in range(4):
        cv2.imwrite(f"v5_copy_{c}_{base_name}.jpg", crop_img)

# 2. Rutina de busqueda y sobremuestreo estrategico en el Dataset

```

```

os.makedirs(os.path.join(train_images, "neps_boost"), exist_ok=True)

for label_file in os.listdir(train_labels):
    with open(os.path.join(train_labels, label_file), 'r') as f:
        lines = f.readlines()

    # Filtrado selectivo: Identificacion de la clase de interes
    if any(line.startswith('1_') for line in lines):
        img_name = label_file.replace('.txt', '.jpg')

        # Replicacion controlada de archivos para optimizar el
        # cargador de datos
        for i in range(3):
            new_img_name = f"boost_{i}_{img_name}"
            new_lbl_name = f"boost_{i}_{label_file}"

            shutil.copy(os.path.join(train_images, img_name),
                        os.path.join(train_images, new_img_name)
                        )
            shutil.copy(os.path.join(train_labels, label_file),
                        os.path.join(train_labels, new_lbl_name)
                        )

print("Proceso_de_balanceo_estratificado_completado_con_exito.")

```

B.2 Configuración de entrenamiento (Hiperparámetros)

Se configuró el modelo YOLO11m-seg priorizando la precisión de segmentación y la robustez contra el *overfitting* mediante regularización específica.

```

from ultralytics import YOLO

# Optimizacion de la gestion de fragmentos de memoria en PyTorch

```

```

os.environ["PYTORCH_CUDA_ALLOC_CONF"] = "expandable_segments:True"

# Inicializacion del modelo base de segmentacion
model = YOLO("yolo11m-seg.pt")

# Configuracion del proceso de entrenamiento controlado
results = model.train(
    data="/home/laad-server/hilado/Hilado-Artesanal-12/data.yaml",
    imgsz=1344,
    batch=2,
    amp=True,
    epochs=400,
    patience=70,
    optimizer='AdamW',
    lr0=0.0005,

# Ponderacion estrategica de las funciones de perdida
    cls=3.5,
    box=10.0,
# Tecnicas de aumentacion de datos en tiempo de ejecucion (Online)
    copy_paste=0.7,
    mosaic=1.0,
    mixup=0.2,
    degrees=20.0,
# Mecanismos de regularizacion contra el sobreajuste
    dropout=0.15,
    val=True,
    device=0,
    seed=42
)

```

B.3 Algoritmo de generación de mapas de calor (Eigen-CAM)

Se implementó una arquitectura basada en hooks para extraer las activaciones y procesarlas mediante la descomposición de varianza de Eigen-CAM,

```
import torch
import numpy as np
import cv2

# 1. Extraccion de activaciones mediante Hooks
target_layer = model.model[16] # Capa C3k2 focalizada
target_layer.register_forward_hook(get_hook(16))

# 2. Logica Eigen-CAM (PCA)
def calculate_eigen_cam(feature_map):
    fmap = feature_map[0].detach().cpu().numpy()
    C, H, W = fmap.shape
    fmap_reshaped = fmap.reshape(C, -1)

    # Proyeccion sobre el primer componente principal (PC1)
    cov = np.cov(fmap_reshaped)
    eigvals, eigvecs = np.linalg.eig(cov)
    principal_comp = eigvecs[:, np.argmax(eigvals)]

    cam = principal_comp @ fmap_reshaped
    return (cam - cam.min()) / (cam.max() - cam.min() + 1e-6)

# 3. Superposicion de Heatmap sobre fibra de alpaca
cam_map = calculate_eigen_cam(features[16])
heatmap = cv2.applyColorMap(np.uint8(255 * cam_resized), cv2.
    COLORMAP_JET)
overlay = cv2.addWeighted(heatmap, 0.5, original_img, 0.5, 0)
```

C. Difusión científica: póster Sinapsis 2025

Figura 40

Póster científico presentado en Sinapsis 2025.

Desarrollo e implementación de un sistema inteligente de control de calidad para el proceso de hilado artesanal de fibra de alpaca, basado en técnicas de visión computacional

Fran Anthony Hanco Champi¹ Carlos Fernando Montoya Cubas¹ Harley Vera Olivera¹ José Mauricio Díaz Jurado² Jhordan Berrocal Cueto²

¹Universidad Nacional de San Antonio Abad del Cusco - UNSAAC

²CITetextil Camélidos Cusco

IX ENCUENTRO DE CIENTÍFICOS PERUANOS EN EUROPA
Sinapsis 2025

CITetextil camélidos

Cusco



Introducción

Tras el cardado, el hilado artesanal presenta imperfecciones y defectos que comprometen la calidad del hilo resultante. La inspección manual resulta lenta y subjetiva, por lo que este trabajo propone un sistema automatizado de visión computacional que permite detectar y segmentar imperfecciones de manera más eficiente. De esta forma, se busca optimizar el control de calidad, reducir errores humanos y fortalecer la competitividad de la industria textil de alpaca.



Figura 1: Dataset propio de la etapa de hilado de fibra de alpaca, con 1,530 imágenes capturadas y anotadas para defectos como neps y vellosidad mediante segmentación.

Metodología

Flujo metodológico



Figura 2: Flujo metodológico de la investigación

Resultados Preliminares

Métricas de rendimiento

Cuadro 1: Resultados de validación - YOLOv8m-seg

Clase	Box			Mask		
	P	R	F1	P	R	F1
General	0.678	0.560	0.613	0.623	0.558	0.589
Nep	0.697	0.692	0.694	0.922	0.912	0.917
Vellosidad	0.659	0.428	0.520	0.323	0.205	0.252

Matriz de confusión




Figura 4: Matriz de confusión - Proceso de hilado

Modelos

Arquitectura YOLOv8



Figura 3: Arquitectura base YOLOv8 para segmentación

En la Figura 3. YOLOv8 integra bloques C2f, ligeros y rápidos, se pueden ajustar sus capas:

- **Backbone:** reemplazar algunos bloques por variantes avanzadas como C3K2 o C2PSA, que capturan mejor defectos pequeños.
- **Neck:** reforzar la fusión multiescala ajustando conexiones y resoluciones.

Conclusiones y Trabajo Futuro

Conclusiones

- La detección de vellosidad presentó limitaciones, con valores bajos de recall (no logra identificar correctamente los casos reales de esta clase).
- Los resultados resaltan la importancia de contar con un dataset especializado y bien anotado.

Trabajo futuro

- Desarrollar una versión customizada de YOLOv8 que incorpore atención y refinadores de máscara para mejorar la segmentación de bordes.
- Se plantea integrar técnicas de explicabilidad, como Grad-CAM, que permitan visualizar qué regiones de la imagen influyen en las predicciones.

Referencias

- [1] R. Sapkota, D. Ahmed, M. Karkee, Comparing YOLOv8 and Mask R-CNN for object segmentation in complex orchard environments", arXiv:2312.07935, 2023.

Agradecimientos

Agradecemos a CITetextil Camélidos Cusco por las muestras y equipos, a la LAAD - UNSAAC por el apoyo institucional, y de manera especial al Dr. Raúl Valdivia Saravia y a la Ing. Lita Esther Castillo Yepes por su valiosa orientación técnica en fibra de alpaca.


Financiado por:



D. Informe de aprobación de aspectos bioéticos

Figura 41


Carta de aprobación Comité de Bioética

	Comité de Bioética Institucional y Sub Comités de Bioética de la UNSAAC
Código: CBI-UNSAAC2025-012	
INFORME FINAL DE ASPECTOS BIOÉTICOS DEL PROYECTO	
Datos del Investigador que solicita la opinión del CBI-UNSAAC	
Nombre: HARLEY VERA OLIVERA.	
Facultad: Facultad de Ingeniería Eléctrica, Electrónica, Informática y Mecánica	
Escuela: Escuela Profesional de Ingeniería Informática y de Sistemas	
Universidad: Universidad Nacional de San Antonio Abad del Cusco	
Correo electrónico: harley.vera@unsaac.edu.pe	
Datos del Proyecto de investigación	
Título: "Desarrollo e implementación de un sistema de control de calidad en el proceso de hilado de fibra de alpaca utilizando visión computacional"	
Fecha de ingreso: 2025-04-16	
Fecha de emisión de informe final: 03-10-2025	
Resultado de la evaluación a aspectos bioéticos: <u>APROBADO.</u>	
Observaciones: El proyecto presentado a consideración del Comité de Bioética Institucional en Investigación de la Universidad Nacional de San Antonio Abad del Cusco (CBI-UNSAAC), ha sido evaluado por el CBI-UNSAAC y el Subcomité de Bioética de Estudios con Animales, Vegetales y/o material Genético no Humano, quienes solicitaron observaciones, que fueron levantadas en el plazo establecido por el responsable del trabajo de investigación, dando su opinión favorable.	
Atentamente,	
	 UNIVERSIDAD NACIONAL DE SAN ANTONIO ABADEL CUSCO COMITÉ DE BIOÉTICA DRA. TATIANA DEL CASTILLO DE LOAYZA PRESIDENTE
Mg. Tatiana Del Castillo de Loayza. Presidente del Comité de Bioética Institucional de la UNSAAC comite.bioetica@unsaac.edu.pe	

E. Galería completa de activaciones Eigen-CAM

Figura 42


Visualización integral de las activaciones en Eigen-Cam



F. Galería completa de activaciones Grad-CAM

Figura 43

Visualización integral de las activaciones en Grad-Cam



G. Análisis de costos de infraestructura y presupuesto comparativo

En la industria textil global, el estándar de referencia para la caracterización y evaluación objetiva de la calidad del hilo corresponde a sistemas mecatrónicos de laboratorio cerrados, siendo la serie **USTER TESTER 6** (Modelo UT6-S800/A) (Uster Technologies AG, 2022) el equipo instrumental dominante. A continuación, se presenta la ficha técnica detallada de este equipo industrial y el análisis de costos comparativo frente al prototipo de visión computacional desarrollado.

G.1 Ficha Técnica Detallada del Sistema Industrial USTER TESTER 6

La Tabla 21 detalla de manera individual todas las especificaciones operativas, módulos sensores, parámetros medidos, requisitos de cómputo e instalación del sistema **USTER TESTER 6** (Uster Technologies AG, 2022).

Tabla 21

Ficha técnica y especificaciones detalladas del USTER TESTER 6 (Modelo UT6-S800/A)

Categoría / Módulo	Especificaciones Técnicas y Parámetros Operativos (Uster Technologies AG, 2022)
Sensor Capacitivo CS (Regularidad y Masa)	Capaz de medir variaciones de masa en hilos, mechas y cintas en el rango de 1 tex a 12 ktex (Uster Technologies AG, 2022). Cuantifica irregularidad $U\%$, coeficiente de variación CV_m, $CV_m(L)$ (cortes de 1, 3, 10, 50 y 100 m) e índice I (Uster Technologies AG, 2022). Conteo de Imperfecciones: ■ Puntos delgados (<i>thin places</i>): umbrales de -30%, -40%, -50%, -60% (Uster Technologies AG, 2022). ■ Puntos gruesos (<i>thick places</i>): umbrales de $+35\%$, $+50\%$, $+70\%$, $+100\%$ (Uster Technologies AG, 2022). ■ Motas / Neps: umbrales de sensibilidad de $+140\%$, $+200\%$, $+280\%$, $+400\%$ (Uster Technologies AG, 2022).
Sensor Óptico OH (Vello-sidad Global)	Medición óptica de vello-sidad (H) y desviación estándar de vello-sidad (sh) en fibras cortas en un rango de 5 a 1,000 tex (Uster Technologies AG, 2022).
Sensor Óptico HL (Longi-tud de Vello-sidad)	Clasificación espectral de fibras salientes en 7 clases individuales de longitud (1, 2, 3, 4, 6, 8 y 10 mm) y cálculo del índice acumulativo $S3u$ (fibras ≥ 3 mm) en rango de 5 a 100 tex (Uster Technologies AG, 2022).

Tabla 21

Ficha técnica y especificaciones detalladas del USTER TESTER 6 (Modelo UT6-S800/A)

Categoría / Módulo		Especificaciones Técnicas y Parámetros Operativos (Uster Technologies AG, 2022)
Sensor Multifuncio- nal OM (Geometría y Torsión)		Apariencia: Medición de diámetro medio del hilo ($\emptyset$), variación de sección transversal (CV_{2D}), redondez (forma) y densidad (Uster Technologies AG, 2022). Torsión: Identificación de nivel de torsión (T/m, $T/inch$) y desviación ΔTu (Uster Technologies AG, 2022).
Sensor Óptico OI (Impu- rezas y Polvo)		Conteo y clasificación fotométrica de partículas de basura ($> 500 \mu m$) y polvo ($< 500 \mu m$) en hilos de algodón y mezclas (5 a 200 tex) (Uster Technologies AG, 2022).
Sensor FA y Módulo FYP		Sensor FA: Medición de título absoluto del hilo (5 a 100 tex) bajo norma ISO 2060 (Uster Technologies AG, 2022). Módulo FYP: Evaluación de hilos fantasía (<i>Fancy Yarn Profile</i>), distancia y masa de efectos (Uster Technologies AG, 2022).
Unidad de Control y Pro- cesamiento		Computador industrial Intel con triple disco duro interno de respaldo (500 GB de almacenamiento de pruebas) y sistema Windows (Uster Technologies AG, 2022). Incluye software <i>Uster Tester 6 Touch</i> y servidor <i>Uster Quality Expert</i> para comparación automática contra la base de datos mundial <i>Uster Statistics</i> (Uster Technologies AG, 2022).
Velocidad y Automatiza- ción		Velocidad de tracción continua programable de 10 a 800 m/min (Uster Technologies AG, 2022). La versión automática (S800/A) incluye alimentador y cambiador automático de hasta 24 posiciones de bobinas (Uster Technologies AG, 2022).

Tabla 21

Ficha técnica y especificaciones detalladas del USTER TESTER 6 (Modelo UT6-S800/A)

Categoría / Módulo	Especificaciones Técnicas y Parámetros Operativos (Uster Technologies AG, 2022)
Requerimientos de Instalación y Clima	Climatización exigida: Ambiente estrictamente controlado bajo ISO 139 ($20 \pm 2^{\circ}\text{C}$ de temperatura y $65 \pm 4\%$ de humedad relativa) (Uster Technologies AG, 2022). Neumática: Suministro de aire comprimido seco (ISO 8573.1 Clase 3), presión de entrada de 6 a 10 bar y consumo de 12 a 18 m³/h (Uster Technologies AG, 2022). Eléctrica y Peso: 100–240 VAC, 50/60 Hz, potencia máx. 1,000 VA con sistema UPS de 1 kVA (Uster Technologies AG, 2022). Peso total del sistema: 249 kg (Uster Technologies AG, 2022).

G.2 Cuadro Comparativo de Presupuesto e Infraestructura

La Tabla 22 detalla la estructura de costos.

Tabla 22

Cuadro comparativo de costos de infraestructura y presupuesto del prototipo

Componente / Infraestructura Requerida	Cant.	Costo Unit. (S/.)	Total Parcial (S/.)
1. Alternativa Industrial Tradicional (Uster Tester 6 S800/A)			
Equipo instrumental óptico-capacitivo cerrado	1	150,000.00	150,000.00
Soporte técnico, importación, instalación y calibración de fábrica	Global	Est. 18,000.00	18,000.00
Subtotal Alternativa Industrial			S/. 168,000.00
2. Sistema de Visión Computacional Propuesto (Prototipo Industrial de Taller)			
Módulo de cómputo de alto rendimiento en el borde (NVI-DIA Jetson AGX Orin 32GB / Industrial Edge AI)	1	10,500.00	10,500.00
Sistema dual de cámaras industriales de alta velocidad	2	4,800.00	9,600.00
Juego de lentes telecéntricos de precisión (baja distorsión) y filtros de polarización cruzada	1	3,800.00	3,800.00
Sistema de iluminación LED estroboscópica de alto CRI con controlador de pulsos y sincronismo	1	3,400.00	3,400.00
Módulo de tracción electromecánica de precisión, servomotores AC, galgas de tensión y encoders ópticos	Global	8,200.00	8,200.00
Controlador lógico programable (PLC Siemens S7-1200), módulos I/O remotos y conmutador PROFINET	1	5,400.00	5,400.00
Sensores de paso de hilo, barreras infrarrojas de alta respuesta y sistema neumático de limpieza anti-pelusa	Global	1,800.00	1,800.00
Gabinete industrial IP65 de aluminio extruido, mesa antivibratoria de laboratorio y chasis reforzado	Global	4,800.00	4,800.00
Sistema de alimentación ininterrumpida (UPS Online Doble Conversión 2 kVA) y acondicionador de línea	1	2,200.00	2,200.00
Estación de trabajo HMI táctil industrial en acero inoxidable	1	5,800.00	5,800.00
Patrón óptico de calibración micrométrica (Target USAF 1951)	1	2,500.00	2,500.00
Subtotal Infraestructura del Prototipo			S/. 58,000.00