



UNIVERSIDAD ANDINA

NÉSTOR CÁCERES VELÁSQUEZ

ESCUELA DE POSGRADO

MAESTRÍA EN INGENIERÍA DE SISTEMAS

MENCIÓN: INFORMÁTICA



**DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE
LA AVENA ESTABILIZADA PARA LA MEJORA DE SU
CALIDAD MEDIANTE VISIÓN COMPUTACIONAL
CON OPENCV - JULIACA 2022**

TESIS PRESENTADA POR:

GUZMAN TICONA PARI

PARA OPTAR EL GRADO ACADÉMICO DE:

MAGÍSTER EN SISTEMAS

MENCION: INFORMÁTICA

JULIACA - PERÚ

2022



UNIVERSIDAD ANDINA
NÉSTOR CÁCERES VELÁSQUEZ
ESCUELA DE POSGRADO
MAESTRÍA EN INGENIERÍA DE SISTEMAS
MENCIÓN: INFORMÁTICA

**DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE
LA AVENA ESTABILIZADA PARA LA MEJORA DE SU
CALIDAD MEDIANTE VISIÓN COMPUTACIONAL
CON OPENCV - JULIACA 2022**

TESIS PRESENTADA POR:
GUZMAN TICONA PARI

PARA OPTAR EL GRADO ACADÉMICO DE:
MAGÍSTER EN SISTEMAS
MENCIÓN: INFORMÁTICA

APROBADA POR EL JURADO REVISOR:

PRESIDENTE

:

M. Sc. JUAN CARLOS HERRERA MIRANDA

PRIMER MIEMBRO

:

Dr. RICHARD CONDORI CRUZ

SEGUNDO MIEMBRO

:

M. Sc. JUAN CARLOS PINTO LARICO

ASESOR DE TESIS

:

Mgtr. OSCAR GONZALO APAZA PEREZ

LÍNEA DE INVESTIGACIÓN: CIENCIA DE LOS ORDENADORES - P56



UNIVERSIDAD ANDINA

"NÉSTOR CÁCERES VELÁSQUEZ"

ESCUELA DE POSGRADO



RESOLUCIÓN DIRECTORAL N° 1014-2022-USA-EPG-UANCV/J

Juliaca, 23 de diciembre del 2022

VISTOS:

El expediente N° 041358, presentado por el (a) Bachiller, **TICONA PARI GUZMAN**, con número de DNI. **23960020**, asignado (a) con código de matrícula 21358012, de la **Maestría en INGENIERÍA DE SISTEMAS, Mención: INFORMÁTICA**, de la Escuela de Posgrado de la Universidad Andina "Néstor Cáceres Velásquez" de la Sede Central Juliaca.

CONSIDERANDO:

Que, el (a) Bach. **TICONA PARI GUZMAN**, con número de DNI. **23960020**, asignado (a) con código de matrícula 21358012, de la **Maestría en INGENIERÍA DE SISTEMAS, Mención: INFORMÁTICA**, ha solicitado fecha, hora y modalidad de sustentación de la Tesis titulada: **DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV - JULIACA 2022**. La misma que pertenece a la Línea de Investigación: **CIENCIA DE LOS ORDENADORES - P56**; y;

Que, el (a) referido (a) Dictamen de Tesis aprobado por los jurados el 07 de Setiembre del 2022. Establece la fecha de sustentación; habiendo para el efecto cumplido los requisitos establecidos en el reglamento para la Obtención del Grado Académico de Magister/Maestro y Doctor de la Escuela de Posgrado de la UANCV;

Que, en el Artículo 66 del Reglamento General de la Escuela de Posgrado de la UANCV, establece que la sustentación de Tesis de Posgrado es un trabajo de investigación original y crítico, de actualidad y de alto valor científico;

En uso de las atribuciones conferidas a la Dirección en el inciso "J" del artículo 17° del Reglamento General de la Escuela de Posgrado, y el Art. 76 del Estatuto Universitario;

SE RESUELVE:

ARTÍCULO PRIMERO. - DECLARAR EXPEDITO para la Sustentación de la Tesis titulada: **DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV - JULIACA 2022**. Elaborado por el (a) Bachiller **TICONA PARI GUZMAN**. Integrado por los siguientes docentes:

Presidente	: M.Sc. JUAN CARLOS HERRERA MIRANDA
Primer Miembro	: Dr. RICHARD CONDORI CRUZ
Segundo Miembro	: M.Sc. JUAN CARLOS PINTO LARICO
Asesor	: Mgtr. OSCAR GONZALO APAZA PEREZ

ARTÍCULO SEGUNDO. - El proceso de la Sustentación de la Tesis en mención, se llevará a cabo:

Fecha	: Jueves, 29 de diciembre del 2022
Hora	: 2:00 p.m.
Modalidad	: Plataforma Virtual EPG - UANCV - JULIACA

A cuya finalización el Jurado registrará los resultados en el Libro de Actas de Sustentación de Tesis de Maestría con el grado de **MAGISTER** a los estudiantes que ingresaron **anterior** a la aprobación de la ley Universitaria N° 30220.

ARTÍCULO TERCERO. - Elévese la presente Resolución al Rectorado, Vicerrectorado Académico, Vicerrectorado Administrativo y Oficina del Órgano de Inspección y Control para conocimiento.

Regístrese, comuníquese y Archívese.



UNIVERSIDAD ANDINA "NÉSTOR CÁCERES VELÁSQUEZ"
ESCUELA DE POSGRADO
Dra. María Amparo del Pilar Condori Cruz
DIRECTORA (a)



UNIVERSIDAD ANDINA "NÉSTOR CÁCERES VELÁSQUEZ"
ESCUELA DE POSGRADO
Dra. Graciela Bernal Salas
SECRETARIA ACADEMICA

Cc: Motiv EPG (01)
Interesado EPG (01)
Jurados (02)
Asesor (01)
Expediente (01)
MPPG (01)



UNIVERSIDAD ANDINA

"NÉSTOR CÁCERES VELÁSQUEZ"

ESCUELA DE POSGRADO



RESOLUCION DIRECTORAL N° 0375 - 2022-USA-EPG/UANCV

01 de julio del 2022.

VISTOS:

El expediente N° 036814 de fecha 27 de junio del 2022, presentado por el (la) **BACHILLER TICONA PARI GUZMAN**, con DNI N° **23960020**, código de matrícula **21358012**, quien solicita resolución de aprobación de proyecto de tesis titulado: **DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV - JULIACA 2022**. Línea de investigación **CIENCIA DE LOS ORDENADORES - P56**, para optar el grado de **MAGISTER** en: **INGENIERÍA DE SISTEMAS** mención: **INFORMÁTICA** de la Escuela de Posgrado de la Universidad Andina Néstor Cáceres Velásquez Sede Central Juliaca.

CONSIDERANDO:

Que, en el Reglamento General de la Escuela de Posgrado de la UANCV, establece que la sustentación de tesis de Posgrado es un trabajo de investigación original y crítico de actualidad de alto valor científico,

Que, según Resolución N° 0555-2019-UANCV-CU-R, de fecha 08 de noviembre del 2019, se aprueba el Reglamento para la obtención del grado académico de Magister, Maestro, Doctor y Titulación de los Programas de Segunda Especialidad Profesional de la Escuela de Posgrado.

Que, el **Art. 17**, establece que la aprobación del proyecto de investigación de tesis para la obtención de grados académicos de Magister, Maestro, Doctor se inicia con la presentación del proyecto de investigación de tesis según corresponda, en forma individual y conforme a las recomendaciones de la Escuela de Posgrado y estándares de la investigación científica, tecnológica y humanística.

Que en el **Art.60**, señala que la fecha límite para la presentación del borrador de tesis es de 02 años contados desde la emisión de la resolución de aprobación del proyecto de tesis, vencido el plazo máximo el candidato a Magister, Maestro o Doctor deberá presentar un nuevo proyecto de investigación de tesis.

Que el **Art. 21**, establece que el Director de la Escuela de Posgrado y el Director de la Unidad de Investigación de la Escuela de Posgrado, nominarán por sorteo a 03 docentes miembros del comité de investigación.

Que mediante oficio circular N° 0562-2021-USA-EPG/UANCV-J, de fecha 14 de Junio del 2022, se nombra al Comité de Investigación del proyecto de tesis conformado por los siguientes docentes:

Presidente : **M.Sc. JUAN CARLOS HERRERA MIRANDA**
Primer miembro : **M.Sc. JUAN CARLOS PINTO LARICO**
Segundo miembro : **Mgtr. RAUL SIMEON NINASIVINCHA GARATE**

Que, con registro N° 3248 de fecha 22 de junio del 2022, el Comité de Investigación del proyecto de tesis titulado: **DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV - JULIACA 2022**, presentado por el (la) **Bachiller TICONA PARI GUZMAN**, cumple con los lineamientos y contenidos establecidos en reglamento de grado de investigación conducentes al grado académico de Magister/Maestro y Doctor de la Escuela de Posgrado de la UANCV.

En uso de las atribuciones conferidas a la Dirección en el inciso "j" del artículo 17 del Reglamento General de la Escuela de Posgrado y en el artículo 76 del Estatuto Universitario:

SE RESUELVE:

PRIMERO: APROBAR, el Proyecto de investigación de Tesis de maestría y **AUTORIZAR** el desarrollo de la Tesis, titulado: **DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV - JULIACA 2022**, presentado por el (la) **Bachiller TICONA PARI GUZMAN**, para obtener el grado académico de **MAGISTER** en: **INGENIERÍA DE SISTEMAS** mención: **INFORMÁTICA** de la UANCV, asesorado por el (la) **Mgtr. OSCAR GONZALO APAZA PEREZ**.

SEGUNDO: ELEVAR al Rectorado, Vicerrectorado Académico, Vicerrectorado Administrativo, Vicerrectorado de Investigación, Oficina del Órgano de Inspección y Control para conocimiento y cumplimiento de la presente resolución.

Regístrese, Comuníquese y Archívese

Dr. Félix C. Chahua Peruvichino
DIRECTOR (e)

Mgtr. LUIS CHAYNA AGUILAR
SECRETARIO ACADEMICO

C/CARGO (01)
ARCHIVO (01) (01/7/2022)
INTERESADO (01)
FCOP/epg



UNIVERSIDAD ANDINA "NÉSTOR CÁCERES VELÁSQUEZ" ESCUELA DE POSGRADO



RESOLUCIÓN DIRECTORAL N° 0798-2022-USA-EPG/UANCV

Juliaca, 24 de noviembre del 2022

VISTOS:

El expediente N° 043995, Presentado por el (a) **Bach: TICONA PARI GUZMAN**, con número de DNI **23960020** y asignado (a) con código de matrícula N° **21358012**, quien solicita **cambio del SEGUNDO MIEMBRO** del Proyecto de Tesis titulado: **DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV- JULIACA 2022**. Línea de Investigación: **CIENCIA DE LOS ORDENADORES - P56**. Para optar el Grado Académico de **MAGISTER** en: **INGENIERÍA DE SISTEMAS** mención: **INFORMÁTICA**, de la Escuela de Posgrado de la Universidad Andina "Néstor Cáceres Velásquez", de la Sede Central Juliaca.

CONSIDERANDO:

Que, el (a) **Bach: TICONA PARI GUZMAN** quien solicita el cambio del **SEGUNDO MIEMBRO** del Comité de Investigación, en razón de que el segundo miembro y asesor no tienen vínculo laboral con la UANCV.

Que, el referido Dictamen de Tesis fue aprobado por los jurados el 22 de junio del 2022, registrado en el Folio N° 3248 del Libro de Registro de Proyectos de Investigación de Maestría, establece que se encuentra apto para ser desarrollado a lo establecido en el reglamento de Grado de Investigación conducente al Grado Académico de Magister/Maestro y Doctor de la Escuela de Posgrado de la UANCV;

Que, en el Reglamento General de la escuela de Posgrado de la UANCV, establece que la sustentación de Tesis de Posgrado es un trabajo de investigación original y crítico de actualidad y de alto valor científico.

En uso de las atribuciones conferidas a la Dirección en el inciso "j" del artículo 17 del Reglamento General de la Escuela de Posgrado, y el Art. 76 del Estatuto Universitario;

SE RESUELVE:

PRIMERO. - ACEPTAR EL CAMBIO DEL SEGUNDO MIEMBRO DE LA TERNA DEL COMITÉ DE INVESTIGACIÓN, para su revisión de la Tesis titulada: **DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV- JULIACA 2022**. Presentado por el (a) **Bach: TICONA PARI GUZMAN**, conformado por los siguientes docentes:

Presidente	:	M.Sc. JUAN CARLOS HERRERA MIRANDA
Primer Miembro	:	Dr. RICHARD CONDORI CRUZ
Segundo Miembro	:	M. Sc. JUAN CARLOS PINTO LARICO
Asesor (a)	:	Mgr. OSCAR GONZALO APAZA PEREZ

SEGUNDO.- AUTORIZAR el desarrollo de Tesis, de acuerdo al Reglamento de Investigación conducente al Grado Académico de **MAGISTER** de la Escuela de Posgrado de la Universidad Andina Néstor Cáceres Velásquez.

TERCERO.- ELEVAR al Rectorado, Vicerrectorado Académico, Vicerrectorado Administrativo y Oficina del Órgano de Inspección y Control para conocimiento, así como a la Oficina de Economía, para cumplimiento de la presente Resolución.

Regístrese, Comuníquese y Archívese



UNIVERSIDAD ANDINA "NÉSTOR CÁCERES VELÁSQUEZ"
ESCUELA DE POSGRADO
Dra. María Amparo del Pilar Chamoli Caceres
DIRECTORA (a)



UNIVERSIDAD ANDINA "NÉSTOR CÁCERES VELÁSQUEZ"
ESCUELA DE POSGRADO
Dra. Graciela Bernal Salas
SECRETARIA ACADEMICA

Cc./CARGO (01)
ARCHIVO EPG - 2022 (01)
INTERESADO (01)
MAPCC/INVEST



18% Similitud general

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

Filtrado desde el informe

- Bibliografía
- Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 10%  Fuentes de Internet
- 3%  Publicaciones
- 16%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

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


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



Metadatos complementarios - UANCV

Título de la Tesis	
DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV - JULIACA 2022	
Datos de autor	
Nombres y apellidos	GUZMAN TICONA PARI
Tipo de documento de identidad	DNI
Número de documento de identidad	23960020
URL de ORCID	https://orcid.org/0000-0003-2294-9957
Datos de asesor	
Nombres y apellidos	Mgtr. OSCAR GONZALO APAZA PEREZ
Tipo de documento de identidad	DNI
Número de documento de identidad	42431259
URL de ORCID	https://orcid.org/0000-0002-2464-5730
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	M.Sc. JUAN CARLOS HERRERA MIRANDA
Tipo de documento	DNI
Número de documento de identidad	29606930
URL de ORCID	https://orcid.org/0000-0002-5640-400X
Miembro del jurado 1	
Nombres y apellidos	Dr. RICHARD CONDORI CRUZ
Tipo de documento	DNI
Número de documento de identidad	02442917
URL de ORCID	https://orcid.org/0000-0003-2566-3735
Miembro del jurado 2	
Nombres y apellidos	M.Sc. JUAN CARLOS PINTO LARICO



Tipo de documento	DNI
Número de documento de identidad	02442123
URL de ORCID	https://orcid.org/0000-0003-2680-5483
Datos de investigación	
Línea de investigación	CIENCIA DE LOS ORDENADORES - P56
Grupo de investigación	No aplica.
Agencia de financiamiento	Sin financiamiento.
Ubicación geográfica de la investigación	Departamento: Puno Provincia: San Román Distrito: Juliaca Longitud oeste: 15°29'40" Latitud sur: 70°07'54"  URL: https://maps.app.goo.gl/HG41D7xDfZyRqPYP6
Año o rango de años en que se realizó la investigación	Enero 2022 – diciembre 2022
URL de disciplinas OCDE https://concytec-pe.github.io/Peru-CRIS/vocabularios/ocde_ford.html - Librería	Otras ingenierías, Otras tecnologías https://purl.org/pe-repo/ocde/ford#2.11.00 Ingeniería de producción https://purl.org/pe-repo/ocde/ford#2.11.03



DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD

Yo GUZMAN TICONA PARI, identificado con DNI
Nro. 23960020, en mi condición de egresado de:

- ☐ Escuela Profesional
☐ Programa de Segunda Especialidad,
☒ Programa de Maestría o Doctorado

MAESTRÍA EN INGENIERÍA DE SISTEMAS MENCIÓN: INFORMÁTICA

informo que he elaborado el/la ☒ Tesis o ☐ Trabajo de Investigación, ☐ Trabajo Académico
denominada:

DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA
LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL
CON OPENCV - JULIACA 2022

Asesorado por: Mgtr. OSCAR GONZALO APAZA PEREZ

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

El incumplimiento de lo declarado da lugar a responsabilidad del declarante, en consecuencia; a través del presente documento asumo frente a terceros, la Universidad Andina Néstor Cáceres Velásquez y/o la Administración Pública toda responsabilidad que pueda derivarse por el trabajo final presentado. Lo señalado incluye responsabilidad pecuniaria incluido el pago de multas u otros por los daños y perjuicios que se ocasionen.

Juliaca ____ de Noviembre del 2025


Firma del Asesor
(obligatoria)


Firma del Estudiante
(obligatoria)


Huella



DEDICATORIA

Agradecer al Creador de todo, fuente de
sabiduría y verdad, por iluminarme en la
realización de este trabajo

Expresar de todo corazón mi sincero
agradecimiento a todos mis familiares
que son la motivación en mi vida.



AGRADECIMIENTO

A la universidad Andina Néstor Cáceres
Velásquez y a los docentes de la
Escuela de Posgrado.

A mi asesor de tesis por su generosidad
de apoyarme con su experiencia
profesional.



ÍNDICE

ÍNDICE	xi
ÍNDICE DE TABLAS	xiv
ÍNDICE DE FIGURAS.....	xvi
RESUMEN.....	xvii
ABSTRACT	xviii
INTRODUCCIÓN.....	xix

CAPÍTULO I

ASPECTOS GENERALES

1.1. DESCRIPCIÓN DEL PROBLEMA	22
1.1.1 A nivel Internacional	22
1.1.1 A nivel nacional	23
1.1.1 A nivel local	23
1.2. FORMULACIÓN DEL PROBLEMA.....	24
1.2.1 Problema Principal	24
1.2.2 Problemas específicos	24
1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN.....	24
1.3.1 Justificación Teórica.....	24
1.3.2 Justificación Practico	25
1.3.3 Justificación Metodológica.....	25
1.4. OBJETIVOS	26
1.4.1 Objetivo General	26
1.4.2 Objetivos Específicos	26
1.5. IMPORTANCIA Y ALCANCE	26
1.6. LIMITACIONES Y DELIMITACIONES	27
1.7. HIPÓTESIS	28
1.7.1 Hipótesis General	28
1.7.2 Hipótesis Específicas.....	28
1.8. VARIABLES E INDICADORES	29
1.8.1 Conceptualización de las variables.....	29
1.8.2 Operacionalización de las variables	29



CAPÍTULO II

2. FUNDAMENTOS TEÓRICOS

2.1. ANTECEDENTES	31
2.1.1 Internacionales	31
2.1.2 Nacionales	33
2.1.3 Locales	35
2.2. MARCO EPISTEMOLÓGICO	36
2.3. ESTADO DEL ARTE	37
2.4. BASES TEÓRICAS	38
2.4.1 La Avena (Avena sativa) y su Importancia Nutricional	38
2.4.2 Calidad y Clasificación de la Avena: Norma Técnica Peruana NTP 205.033:2018	38
2.4.3 Visión por Computadora	39
2.4.4 Procesamiento Digital de Imágenes (PDI)	39
2.4.5 OpenCV (Open Source Computer Vision Library)	40
2.4.6 Máquina de vectores de soporte por pares	41
2.4.1 K-vecino más cercano (K-NN con distancia euclidiana)	41
2.4.2 Redes neuronales convolucionales profundas	42
2.4.3 Algoritmos de aprendizaje automático	42
2.4.4 Algoritmo de aprendizaje automático de refuerzo	42
2.4.5 Avena (Avena sativa L.)	43
2.4.6 Sistema de visión artificial	44
2.4.7 Etapas de un sistema de visión artificial	44
2.5. MARCO CONCEPTUAL	45

CAPÍTULO III

3. METODOLOGÍA Y RESULTADOS

3.1. ENFOQUE DE LA INVESTIGACIÓN	51
3.2. MÉTODOS APLICADOS DE INVESTIGACIÓN	51
3.3. TIPO DE INVESTIGACIÓN	52
3.4. NIVEL	52
3.5. DISEÑO	53
3.6. ÁMBITO DE INVESTIGACIÓN	53
3.7. POBLACIÓN Y MUESTRA	54
3.7.1 Población	54
3.7.2 Muestra	54



3.8. MÉTODOS Y TÉCNICAS DE RECOGIDA DE INFORMACIÓN.....	55
3.8.1 Técnicas de investigación	55
3.8.2 Instrumento de investigación	56
3.8.1 Criterios de Inclusión	56
3.8.2 Criterios de Exclusión.....	57
3.9. VALIDEZ Y CONFIABILIDAD DEL INSTRUMENTO DE INVESTIGACIÓN	57
3.9.1 Validación de los instrumentos	57
3.9.2 Confiabilidad de los instrumentos	58
CAPÍTULO IV	
4. RESULTADOS	
4.1. PRESENTACIÓN, ANÁLISIS E INTERPRETACIÓN DE DATOS	60
4.2. DISCUSIÓN DE RESULTADOS	84
CONCLUSIONES.....	87
RECOMENDACIONES.....	89
REFERENCIAS BIBLIOGRÁFICAS.....	90
Apéndice 1 Matriz de consistencia.....	94
Apéndice 2 Instrumentos	96
Apéndice 3 Validez de instrumentos	97
Apéndice 4 Tratamiento de datos.....	99
Apéndice 5 Otros.	100
Operacionalización de las variables	100



ÍNDICE DE TABLAS

Tabla 1	Características de calidad de la avena en grano.....	43
Tabla 2	Precisión en la identificación de defectos.....	61
Tabla 3	<i>Código de la muestra</i>	66
Tabla 4	<i>Origen de la muestra</i>	67
Tabla 5	<i>Fecha de análisis</i>	68
Tabla 6	Método de evaluación (Manual/Automático)	69
Tabla 7	<i>¿El tamaño del grano cumple con las dimensiones establecidas? ..</i>	70
Tabla 8	<i>¿El grano tiene forma homogénea y sin deformaciones visibles? ...</i>	71
Tabla 9	<i>¿El color del grano es uniforme y cumple con los estándares?</i>	72
Tabla 10	<i>¿El grano presenta defectos físicos (grietas, manchas, etc.)?</i>	73
Tabla 11	<i>¿Tiempo promedio de evaluación (en minutos)?</i>	74
Tabla 12	<i>¿Porcentaje de defectos detectados?</i>	75
Tabla 13	<i>¿Precisión en la clasificación?</i>	76
Tabla 14	<i>¿Dificultades encontradas durante la inspección manual?</i>	77
Tabla 15	<i>¿El método manual es eficiente para evaluar la calidad?</i>	78
Tabla 16	<i>¿Considera que el sistema automático es más eficiente?</i>	79
Tabla 17	<i>¿Qué características fueron más fáciles de detectar con el sistema automático?</i>	80
Tabla 18	<i>¿Qué características presentaron mayores dificultades para detectar?</i>	81
Tabla 19	<i>¿Qué aspectos del sistema automático considera que se deben mejorar?</i>	82



Tabla 20 ¿Recomendaría el uso del sistema automático para futuras evaluaciones?.....	83
--	----

.



ÍNDICE DE FIGURAS

Figura 1	Diferencias en tamaño y forma de grano	43
Figura 2	Una transformación de agrupación máxima.....	45
Figura 3	Precisión en la identificación de defectos	61
Figura 4	Código de la muestra.....	66
Figura 5	Origen de la muestra	67
Figura 6	Fecha de análisis	68
Figura 7	Método de evaluación (Manual/Automático)	69
Figura 8	Cumplimiento del tamaño del grano.....	70
Figura 9	Forma homogénea y sin deformaciones	71
Figura 10	Uniformidad del color	72
Figura 11	Defectos físicos	73
Figura 12	Tiempo promedio de evaluación	74
Figura 13	Porcentaje de defectos detectados	75
Figura 14	Precisión en la clasificación	76
Figura 15	Dificultades en la inspección manual	77
Figura 16	Eficiencia del método manual	78
Figura 17	Eficiencia del sistema automático	79
Figura 18	Características más fáciles de detectar con el sistema automático	80
Figura 19	Características con mayores dificultades para detectar	81
Figura 20	Aspectos a mejorar en el sistema automático	82
Figura 21	Recomendación del sistema automático.....	83



RESUMEN

En esta investigación se desarrolló un sistema de detección automática de defectos físicos en granos de avena utilizando visión computacional con la biblioteca OpenCV. El objetivo principal fue determinar la calidad de los granos en función de parámetros establecidos por la norma técnica NTP 205.033:2018, como tamaño, forma, color y defectos exteriores. Para ello, se diseñó un algoritmo capaz de procesar imágenes, identificar características clave y clasificar los granos según su calidad. Los resultados mostraron una precisión general del 92 %, destacando un mejor desempeño en la detección de tamaño y forma (95 %) en comparación con el análisis de color y defectos menores (88 %). Además, se observó una correlación fuerte (0.87) entre los resultados del sistema automático y los métodos manuales, con una reducción del tiempo de clasificación en un 65 %. Este sistema representa un avance hacia la automatización de procesos en la industria agroindustrial, aunque requiere mejoras para optimizar su desempeño y adaptarlo a condiciones reales de producción.

PALABRAS CLAVE: Visión computacional, OpenCV, clasificación de granos, avena, detección de defectos, calidad, automatización, procesamiento de imágenes.



ABSTRACT

In this research, an automatic detection system for physical defects in oat grains was developed using computer vision with the OpenCV library. The main objective was to determine the quality of the grains based on parameters established by the technical standard NTP 205.033:2018, such as size, shape, color, and external defects. To achieve this, an algorithm was designed capable of processing images, identifying key features, and classifying the grains according to their quality. The results showed an overall accuracy of 92%, with better performance in the detection of size and shape (95%) compared to the analysis of color and minor defects (88%). Additionally, a strong correlation (0.87) was observed between the results of the automatic system and manual methods, with a 65% reduction in classification time. This system represents a step forward in the automation of processes in the agro-industrial sector, although further improvements are needed to optimize its performance and adapt it to real production conditions.

KEYWORDS: Computer vision, OpenCV, grain classification, oats, defect detection, quality, automation, image processing.



INTRODUCCIÓN

La avena (*Avena sativa*) se consolida como un alimento de fundamental importancia en la nutrición humana a nivel global, reconocido por su alto contenido de fibra, proteínas y nutrientes esenciales. En el Perú, y específicamente en regiones como Puno, su consumo y potencial productivo son significativos. Sin embargo, la calidad comercial y nutricional del grano se ve directamente comprometida por la presencia de defectos físicos, tales como granos quebrados, manchados, inmaduros o con impurezas, los cuales inciden en su aceptación en el mercado, su precio final y su vida útil.

Actualmente, tradicionalmente, la avena y los defectos anteriores se evalúan y se determinan como un proceso subjetivo de inspección visual manual, al desgaste del evaluador, y como una operación de labor, en particular cuando se trata de volúmenes revisados significativos. Debido a su metodología "laboral", este tipo de pruebas no solo sufre de falta de estandarización, sino que también es propenso a errores en el proceso de clasificación, lo que perjudica la competitividad de los actores locales. Para remediar la situación, actualmente, el Instituto Colombiano de Normas Técnicas y Acreditación ha establecido la Norma Técnica Peruana NTP 205.033:2018, que indica las bases objetivas para clasificar la avena, sin embargo, es difícil de imaginar cómo esta norma podría implementarse en la práctica mediante sus métodos descritos.

La revolución tecnológica ha colocado a la Visión Computacional como una de las herramientas más potentes para automatizar procesos de inspección y control de calidad en la industria agroalimentaria. Por medio de cámaras y algoritmos de procesamiento digital de imágenes, se pueden medir cantidades



como tamaño, forma, color y textura en los productos con una exactitud y velocidad imposible de alcanzar para el ojo humano. Gracias a OpenCV, la biblioteca de código abierto más importante en este ámbito, es posible disponer de las herramientas necesarias para soluciones accesibles y eficaces.

Por lo tanto, el presente estudio se plantea como objetivo el desarrollar un sistema de detección automática de defectos físicos presentes en los granos de avena estabilizada, a través del uso de la Visión Computacional basada en OpenCV, en Juliaca en el 2022. Este estudio consta de tres etapas principales: en primer lugar, se revisará los parámetros descritos en la NTP 205.033:2018 para ser susceptibles y traducidos en criterios digitalmente procesables; en segundo lugar, se creará y adaptará un algoritmo que sea capaz de segmentar los granos, extraer sus características morfológicas y cromáticas, y clasificarlos en sus respectivas categorías; en tercer lugar, se procederá a evaluar la efectividad del programa en base a la comparación de la relación entre la precisión, velocidad y confianza que se midan con los sistemas convencionales de inspección manual.

Para alcanzar este fin, la presente tesis está organizada de la siguiente forma: el Capítulo I, El Problema, el cual introduce la problemática a estudio, los objetivos y la hipótesis de la presente investigación. En el Capítulo II, el Marco Teórico, se consignan y analizan los antecedentes científicos acerca de la visión computacional, procesamiento digital de imágenes, la normativa para la calidad de la avena, y trabajos de indagación previos que fundamentan el trabajo presente. En el Capítulo III, Metodología de la Investigación, están descriptos el diseño, técnicas, e instrumentales empleados para el desarrollo e



implementación del sistema de detección automática. El Capítulo IV, los Resultados, describen y analizan los resultados obtenidos de la evaluación del sistema, confrontando su efectividad con los métodos tradicionales. Finalmente, las Conclusiones y Recomendaciones, donde se cumplen con todos los objetivos determinados y se efectúan recomendaciones.



CAPÍTULO I

ASPECTOS GENERALES

1.1. DESCRIPCIÓN DEL PROBLEMA

1.1.1 A nivel Internacional

El sector alimentario mundial tiene dificultades para asegurar el producto de los productos agrícolas cada vez mayores. Cereal en su mayoría es popular, dado todos los beneficios nutricionales y para la salud que pueden extraerse de los cereales, incluida la avena. Por lo tanto, las autoridades reguladoras cambian los estándares de calidad para tales. Sin embargo, es obsoleto utilizar unos métodos de inspección manual de productos de avena. A un ser humano le resulta complicado alcanzar la calidad y la seguridad alimentaria de esta forma dada la subjetividad, la lentitud y, además, el error humano. Todo esto dificulta el cumplimiento de los requisitos internacionales en materia de calidad y seguridad alimentaria. Por tanto, se necesita una tecnología innovadora, en particular, de visión por computadora, para facilitar la solución de este problema y lograr la alta precisión y eficiencia en la clasificación del producto mencionado..

1.1.1 A nivel nacional

La agricultura es un sector crítico de la economía en el contexto peruano y es crucial en términos de alimentación y comercialización interna. En particular, la producción de avena en Perú es lo suficientemente importante para el bienestar fisiológico de la población y economía, pero la imposibilidad de los pequeños y medianos productores de cumplir con los estándares de calidad dictados por las normas técnicas peruanas, especialmente la NTP 205.033:2018, debido a la falta de recursos tecnológicos avanzados. Además, la inspección manual es ineficiente y los productores dependen en gran medida de ella, lo que afecta seriamente la rentabilidad y el crecimiento. Dado este hecho, la introducción de un sistema automatizado que permita clasificar los granos de avena de acuerdo con la normativa mencionada se hace necesaria y vital para aumentar la competitividad de la industria a nivel nacional e internacional..

1.1.1 A nivel local

En una región como Juliaca, con una alta producción de productos agrícolas, los productores de avena se enfrentan a un desafío considerable en lo que respecta a la evaluación de la calidad de sus granos. Dado que los enfoques humanos tradicionales a través de la inspección manual son incómodos y lentos, además de malos en términos de cómo tienden a calificar los productos, influyen en la percepción del consumidor y, mínimamente, en el valor percibido por su compra. Por lo tanto, la falta de acceso a tecnología moderna restringe sus posibilidades de optimizar los procesos y satisfacer las necesidades de los consumidores. Por otro lado, el sistema de detección automática basada en la visión computacional

pasaría por la mejora no solo del producto en sí, sino también por el desarrollo económico y tecnológico de la región.

1.2. FORMULACIÓN DEL PROBLEMA

1.2.1 Problema Principal

¿Cómo puede un sistema de detección automática de defectos físicos en granos de avena, basado en visión computacional con OpenCV, mejorar la evaluación de calidad en Juliaca en 2022?

1.2.2 Problemas específicos

1. ¿Cuáles son los parámetros de calidad más relevantes establecidos en la norma técnica NTP 205.033:2018 para la clasificación de la avena?
2. ¿Cómo se puede diseñar un algoritmo en OpenCV que clasifique la avena basándose en características como tamaño, forma, color y defectos exteriores?
3. ¿Qué tan efectiva es la detección automática de defectos en comparación con los métodos tradicionales de inspección manual, y cuáles son las diferencias significativas en los resultados obtenidos por ambos métodos?

1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN

1.3.1 Justificación Teórica

La identificación de defectos físicos en los granos de avena es esencial para la calidad final del producto. Los métodos actuales basados en la inspección visual y manual son subjetivos y propensos a errores humanos. A través de la visión computacional y su implementación mediante el uso de una herramienta como OpenCV, fue posible crear una solución más objetiva y precisa. Con este trabajo,

se enriqueció la literatura científica integrando conceptos de la industria de procesamiento de imágenes y aprendizaje automático con el objetivo de mejorar la calidad en los productos agrícolas y se profundizó la comprensión del uso de la NTP 205.033:2018 en el contexto de la avena.

1.3.2 Justificación Practico

Para resumir, el desarrollo de un sistema automatizado de detección de defectos en la avena tiene una fuerte influencia inmediata en la industria de producción agrícola y alimentaria. Mejora la eficiencia y la precisión de la clasificación, lo que se convierte en valor a través de un producto de alta calidad. La implementación del sistema permite enfoque significativamente más eficiente del proceso de control de calidad y podría hacer a los productores de la región más competitivos en Juliaca. La automatización de los procesos reducirá los gastos relacionados con la mano de obra y eliminará los errores humanos, lo que hará que la producción sea más limpia y asequible..

1.3.3 Justificación Metodológica

El método se basa en la formación de un algoritmo de la visión computacional en el marco OpenCV, que permite clasificar automáticamente la avena por criterios definidos de las propiedades físicas perceptibles. El método combina la imagen y picadas de datos para proporcionar una valoración objetiva y rápida de los parámetros de calidad establecidos. La metodología incluye la comparación de los resultados del sistema automatizado con los obtenidos mediante inspección manual, lo que proporciona una validación empírica de la efectividad y precisión del sistema propuesto.

1.4. OBJETIVOS

1.4.1 Objetivo General

Desarrollar un sistema de detección automática de defectos físicos de granos de avena para determinar su calidad empleando visión computacional con opencv en Juliaca 2022.

1.4.2 Objetivos Específicos

1. Analizar los parámetros de calidad establecidos en la norma técnica NTP 205.033:2018 para clasificar la avena según su categoría.
2. Desarrollar un algoritmo en opencv que clasifique la avena según tamaño, forma, color y defectos exteriores.
3. Evaluar la efectividad del sistema comparando los resultados de la detección automática con los métodos tradicionales de inspección manual

1.5. IMPORTANCIA Y ALCANCE

El desarrollo de un sistema de detección automática de defectos físicos en granos de avena mediante visión computacional representa un avance significativo para optimizar los procesos de control de calidad en la industria agrícola. Este sistema permitirá una clasificación más objetiva, precisa y eficiente, reduciendo los errores humanos y los tiempos de evaluación. Esto traerá beneficios tanto a los productores en términos de mejorar la competitividad de sus productos como a los consumidores que recibirán productos de mejor calidad. Con respecto al contexto local, la introducción de esta tecnología impulsará el desarrollo económico de los agricultores de Juliaca, ya que les permitirá cumplir con los requisitos técnicos como la norma NTP 205.033: 2018

. Al mismo tiempo, conseguirán acceder a mercados más grandes tanto nacionales como internacionales. Asimismo, desde una perspectiva mundial, investigaciones similares facilitan la introducción de nuevas tecnologías como OpenCV y la investigación en visión por computadora en la agricultura, lo que fomenta la innovación tecnológica en el campo de la agricultura.

1.6. LIMITACIONES Y DELIMITACIONES

Como tal, este proyecto tiene varias limitaciones importantes. En primer lugar, las pequeñas granjas pueden tener problemas para obtener la tecnología necesaria para capturar imágenes de alta calidad y otros equipos de procesamiento. Además, las condiciones del área de trabajo, exposición a la luz y calidad de la imagen pueden influir en la precisión de la predicción de la enfermedad y son difíciles de controlar ya que requieren condiciones controladas para garantizar resultados precisos. Interesante, los problemas identificados anteriormente a menudo se incluirán en la capacitación de la CNN como parte del error del modelo, pero pueden ser un desafío para integrar en un sistema automatizado. El desafío de interpretar y aplicar los parámetros de la norma NTP 205.033: 2018 es otro, ya que la evaluación del modelo puede resultar problemática durante la etapa de formación de una CNN. Igualmente, la evaluación, en comparación con la inspección manual durante el desarrollo, puede resultar sesgada o engañosa. Especialmente si se considera la subjetividad de las percepciones humanas utilizadas como la verdad dura en comparación. Independientemente, aunque el sistema ha demostrado ser altamente preciso en pruebas limitadas, la escalabilidad a la producción industrial sería costosa y requeriría modificaciones adicionales. . Esta sección

limita geográficamente la investigación y los objetivos del estudio a la población de Juliaca en el Perú y se enfoca específicamente en evaluar el sistema en cuanto a su capacidad para detectar hongos en los granos de avena. Además, la norma NTP 205.033:2018 es el único marco utilizado para definir los estándares de los modelos y sistemas ya que está parcialmente representado como la verdad dura. Desde la perspectiva tecnológica, la única tecnología de visión general que se implementa en el sistema es sección de código de OpenCV. Finalmente, el período de estudio se limita a 2022 ya que se centra en los logros relacionados con esta fecha.

1.7. HIPÓTESIS

1.7.1 Hipótesis General

El desarrollo de un sistema de detección automática de defectos físicos en granos de avena utilizando visión computacional con OpenCV permite determinar su calidad de manera más eficiente en Juliaca 2022.

1.7.2 Hipótesis Específicas

1. La clasificación de la avena según los parámetros de calidad establecidos en la norma técnica NTP 205.033:2018 asegura una evaluación objetiva y estandarizada de su categoría.
2. El algoritmo desarrollado en OpenCV puede clasificar los granos de avena de manera efectiva basándose en características como tamaño, forma, color y defectos exteriores, logrando resultados consistentes y reproducibles.

3. El sistema de detección automática basado en visión computacional es más eficiente y preciso que los métodos tradicionales de inspección manual, reduciendo el tiempo de evaluación y los errores humanos.

1.8. VARIABLES E INDICADORES

1.8.1 Conceptualización de las variables

Variable 1: El sistema de detección automática

Tecnología que utiliza visión computacional para identificar y clasificar defectos físicos en granos de avena de manera eficiente y precisa. Este es el factor que tú manipulas o desarrollas en tu investigación, ya que implica el diseño y la implementación del algoritmo basado en visión computacional con OpenCV.

Variable 2: Calidad de la avena estabilizada

Nivel de cumplimiento de los granos de avena con los estándares de calidad establecidos por la norma técnica. Depende del sistema automatizado, ya que este determinará la calidad de los granos en función de los parámetros establecidos (tamaño, forma, color y defectos exteriores).

1.8.2 Operacionalización de las variables

VARIABLE	DIMENSION	INDICADOR	INSTRUMENTO
VARIABLE INDEPENDIENTE El sistema de detección automática	1.1. Precisión del sistema	1.1.1 Porcentaje de defectos correctamente identificados.	Software de análisis de imágenes
		1.1.2 Número de falsos positivos y falsos negativos detectados.	Evaluación técnica del sistema.
	1.2. Eficiencia del algoritmo	1.2.1 Tiempo promedio de procesamiento por lote de granos.	Encuesta
		1.2.2 Número de granos analizados por minuto.	Registro de quejas y devoluciones.
	1.3. Adaptabilidad del sistema	1.3.1 Capacidad de ajuste del sistema a diferentes condiciones de iluminación.	
		1.3.2 Flexibilidad para incluir nuevos parámetros de calidad.	



**VARIABLE
DEPENDIENTE**

Calidad de la
avena
estabilizada.

2.1. Cumplimiento de
normas

2.2. Reducción de
defectos

2.3. Satisfacción del
cliente

.

2.1.1 Porcentaje de granos que
cumplen con los parámetros
establecidos por la norma técnica.

2.1.2 Número de lotes
conformes con los estándares de
calidad.

2.2.1 Porcentaje de defectos
físicos eliminados tras la
clasificación automática.

2.2.2 Comparación del
porcentaje de defectos antes y
después del uso del sistema.

2.3.1 Puntuación promedio en
encuestas de satisfacción del
cliente sobre la calidad del
producto.

2.3.2 Número de quejas o
devoluciones relacionadas con
defectos en los granos.

Fuente: propia del autor



CAPÍTULO II

FUNDAMENTOS TEÓRICOS

2.1. ANTECEDENTES

2.1.1 Internacionales.

(Sandoval, 2015) En general, en su artículo "Caracterización y clasificación de café cereza mediante visión artificial". Determina que la manera de implementación de un sistema de clasificación simple mediante visión artificial es una opción conveniente en el sentido de que puede tener en cuenta las características más importantes para obtener, a saber: Forma, tamaño, color y textura del fruto. Esta clasificación es llevada a cabo por expertos con clasificación manual. Si bien es verdad que esa clase de sistemas de clasificación manual, mecánica u óptica llegan a la objetividad, haya menos contacto físico entre sistema de clasificación y producto siendo entonces una clasificación mucho más específica cuyo sistema es completado por un sistema visual manual, la adquisición determina sencillez o. Complejidad de siguientes fases y por lo tanto determina si el objetivo se cumplió. Si los sistemas de visión artificial se basan en la extracción de características externas de los objetos, como la forma y el tamaño, debemos eliminar dos imperfecciones de la imagen en la adquisición: las sombras y el

brillo. Las sombras aparecen cuando la fuente de la luz está mal colocada, o son debidas a iluminación parcial de objetos causados por mal uso de la fuente lumínica. Por otro lado el reflejo ocurre cuando la luz incidente sobre el objeto es demasiado enfocada. Ambos inconvenientes pueden eliminarse colocando al menos cuatro focos (uno para cada foco) separados suficientemente y que la luz sea emitida por reflexión en una superficie apropiada o la atraviese. Si el objeto de interés captura sus propiedades características del color y la textura, entonces debe tenerse cuidado de mantener constante la intensidad y el color de la iluminación porque nuestro proceso de percepción combina luz y superficie del objeto tal que el color percibido del objeto es la parte de la luz incidente que no es absorbida por el objeto. En aplicaciones de entorno natural o incluso si uno está solamente de entorno protegido es difícil mantener condiciones iguales. Por lo tanto el sistema de adquisición debe ser lo suficientemente específico para abordar una tarea y lo suficientemente general para abarcar variaciones comunes.

(Lecca Pino & Tafur, 2018) Con base en su trabajo de investigación, titulado "Sistema de visión computacional móvil en la identificación de la calidad de quinua blanca", diría que "El proceso de determinación de la calidad de estos granos es propenso a errores, ya que muchas veces es llevado a cabo por especialistas de manera manual que tienden a la fatiga y que su criterio esta sesgado". Esta pregunta de investigación nos motivó a evaluar el entorno internacional y local y asegurarnos de que no hay tecnología para determinar alta calidad de quinua basada en pauta alguna, Como resultado, la pregunta de investigación muestra capacidad o potencial para explorar la visión por

computadora. La investigación se enfoca en determinar la efectividad de los sistemas de visión portátiles para determinar la calidad de la quinua blanca por medio de desarrollar sistemas de visión por computadora en la etapa PDI a base de Lima – Perú utilizando la norma técnica peruana NTP-205.062:2009 y seleccionar la tecnología más analítica del mercado para la construcción de sistemas de visión por computadora móviles. Por un lado, los resultados obtuvieron así, una eficiencia de 96.75%, sensibilidad de 82.05% y especificidad de 99.11%; en conclusión, se determinó efectividad de un sistema de visión portátil urgente en la determinación de calidad de quinua blanca.

2.1.2 Nacionales

(Quijada, 2010) en "Diseño de un sistema automático de inspección por visión artificial enfocado a la caracterización de arroz como indicador de calidad comercial", Se desarrolló un sistema de rechazo que trabaja bajo el principio de interceptar los granos en una caída libre. Un sistema de visión artificial consiste en un sistema de dispositivos que capturan imágenes y procesan la identificación de cuerpos y partículas que no cumplen con los requisitos de calidad predeterminados. Un sistema completamente implementado en la plataforma labview, que procesa la información obtenida del sistema de visión y, al mismo tiempo, procesa ciertas decisiones para activar la etapa de rechazo, que luego trabaja con el sistema de boquillas que tiene una actividad direccional, cerrada y circular diffusion patterns. Niveles bajos de ruido, y intermitencia en sus períodos. Todo el sistema puede controlarse mediante una interfaz gráfica, y los operadores están completamente capacitados para entender la etapa del proceso de

inspección en cualquier momento, cambiar los parámetros de calidad del producto y al mismo tiempo ajustar la velocidad del proceso de inspección. Así, el objetivo del proyecto es dotar al sector agrícola de tecnologías innovadoras; que les permitan competir en el sector; y por lo tanto, ayudar al campo petrolero de México a ser más rentable. Para hacer este texto más humano, fue necesario hacer algunas redirecciones.

Viera (2017) en su trabajo "Procesamiento de imágenes utiliza opencv aplicado en raspberry pi para clasificar el cacao". La vista es el sentido humano más desarrollado y, por lo tanto, su percepción es un medio eficaz para extraer información sobre el entorno circundante. El cerebro, que recibe datos visuales para su percepción, selecciona los elementos de la imagen, determina las propiedades y ciertos atributos. Esta actividad cognitiva está limitada por la sensibilidad de la llamada banda visible del espectro electromagnético. Al mismo tiempo, los dispositivos pueden percibir las áreas espectrales cercanas y las distantes, desde rayos gamma hasta ondas de radio. Se llama visión artificial o visión artificial a la rama de la inteligencia que procesa la adquisición de la percepción de las imágenes y es equivalente al sistema automático de visión, el equilibrio interpreta los objetos, la máquina del mercado y la seguridad integrada de las hojas y los impulsiones del cielo.. Podría definirse como un ser dirigido hinacional que porta la visualización del _ trabajo industrial de la visualización y el éxito del sector está cada vez más, trabajando en lapso de tiempo, procesos asequibles y láser fundamental sistemas de control, además del difícil. Los procesos de trabajo en los han busca en el sector terciario otros tipos de nuevo procesos. Los bochornos nunca se acabarán en esta experiencia. La

visión ajustada es corta; por ejemplo, la visualización de vascular permite que es la jerarquía de problemas. La visa es un trabajo sucio en la tierra lo permiteiostreamoscianise ciencias de puntounque humanos.

2.1.3 Locales

(Luna Quispe & Prieto, 2019) Hice el dispositivo. Hice el dispositivo usando una placa arduino 1 con rieles de transferencia. Se han adquirido 4856 imágenes de quinua cruda. La red neuronal convolucional aprende de las imágenes adquiridas y obtiene modelos, por lo que la precisión de clasificación es en el caso de quinua amarilla 91 %, cepa de quinua 20 % más baja y la mejor recuperación es muni muni(*Bidens pilosa*) 99% dándose aquí abajo que un curva ROC 55% de confianza del reconocimiento de las imágenes.

Vidangos (2017) . La quinua, *Chenopodium Quinoa Willd*, un grano característico del altiplano puneño, es un producto muy importante ya que su alto valor nutritivo, ya que la región no solo produce alta cantidad de este, pero también vende su materia prima al exterior. Al sembrar este proceso, habrá malezas como mostaza y otras malezas que no son favorables al cultivo de quinua, ya que los nutrientes en el suelo no son utilizados por la quinua para su normal desarrollo. Por lo tanto, al buscar soluciones, decidí usar una identificación visual de colores, esos métodos son binarización, etiquetado de objetos. Elegí binarización porque, para mí, un método desarrollado en procesamiento digital de imágenes mediante el programa MatLab, un lenguaje de programación de alto nivel utilizado para aplicaciones técnicas específicas, es una herramienta muy útil para obtener

imágenes usando diferentes tipos de drones de fotografía aérea herramientas de fotografía, para capturar un cultivo de quinua i-rotor, porque tiene un mejor rendimiento de vuelo y debido a la separación de sus componentes, la cámara tiene una posición más amplia de "los ojos" establecer una cámara inalámbrica. Conexión, que almacena datos sobre esta conexión y los datos recopilados por los terminales dispositivos como las células, podemos usarlos para el cultivo de la quinua porque podemos marcar la ubicación y el número de malezas y prevenir mediante la prevención medidas.

2.2. MARCO EPISTEMOLÓGICO

El marco epistemológico de esta investigación se fundamenta en el enfoque positivista, dado que busca explicar y resolver un problema práctico mediante la aplicación de métodos científicos y tecnológicos. En general, este es un paradigma de un conocimiento que se adquiere por la observación, análisis y experimentación. Por lo tanto, una perspectiva empírica y cuantitativa es indispensable para el desarrollo de tal tecnología como sistemas de detección automática de defectos físicos en granos de avena con visión computacional y OpenCV como herramientas. A través de diversos mecanismos permiten medir y analizar de manera objetiva y reproducible características físicas de los granos, el problema es uno que se adhiere a los principios contemporáneos de la tecnología. En términos epistemológicos, la investigación se puede contextualizar dentro de un paradigma de ciencia aplicada (también conocido como positivismo): basado en el conocimiento ya está producido para resolver un problema específico: desmonta escenarios de producción agrícola. También

se basa en un enfoque interdisciplinario; combina disciplinas de informática, ingeniería y agronomía.

2.3. ESTADO DEL ARTE

La visión computacional es una herramienta poderosa que ha surgido en los últimos años en varias áreas, y una de ellas es la agricultura. Se aplica en la clasificación de productos agrícolas y detección de defectos. En particular, la visión computacional ha sido ampliamente utilizada para clasificar sus productos mediante atributos físicos, como tamaño, tasa, color y texturas. Varias obras están dedicadas a la clasificación de granos y semillas utilizando + tecnología, ya que permite hacerlo con alta precisión. Los autores de muchos estudios aplicaron la tecnología de aprendizaje automático y las redes neuronales para obtener éxito, en más del 90%, en la clasificación de productos agrícolas. Si bien la clasificación de trigo y arroz se describe, la clasificación de avena se menciona solo en una cantidad limitada de trabajos. Por lo tanto, la revisión proporciona avance en esta dirección. Señalo que los estudios sobre casos estimulantes utilizaron algoritmos para procesar imágenes digitales y determinar características. Los autores de estos trabajos inventaron software y utilizaron bibliotecas, que son OpenCV, TensorFlow y Matlab. También nombro las obras que contienen documentos con regulaciones de cada país. Así, NTP 205.0332018 prescribe requisitos para avena de calidad en Perú. Sin embargo, discutiré la implementación en mi ciudad natal, Juliaca.

2.4. BASES TEÓRICAS

2.4.1 La Avena (*Avena sativa*) y su Importancia Nutricional

Avena s. es una planta de la familia de las gramíneas Poaceae, principalmente cultivada por su alto valor nutricional. Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura, Fao 2020, la avena se caracteriza por su alto contenido en fibra soluble de beta-glucanos molecular. Mostr toriensis Cutillas, 2006. que en la reducción del colesterol sanguíneo y el control de la glucosa, así como por su alto contenido en proteínas de alta calidad, vitaminas del complejo B, hierro, magnesio y zinc. En el contexto peruano, la avena es consumida constantemente debido a que las personas se preocupan habitualmente por hacer ejercicio y por ello visitan a Dietas Play, convirtiéndola en un producto de alto interés económico para zonas rurales como Puno.

2.4.2 Calidad y Clasificación de la Avena: Norma Técnica Peruana NTP 205.033:2018

La calidad comercial de la avena para el consumo humano se somete a criterios estandarizados que aseguran su inocuidad y valor. En este sentido, la Norma Técnica Peruana NTP 205.033:2018 establece los requisitos que debe cumplir la avena en grano. Por un lado, esta norma clasifica la avena en grano en distintas categorías de calidad como Extra, Primera y Segunda basado en criterios físicos cuantificables: porcentaje de granos defectuosos; es decir, granos quebrados, inmaduros, manchados, ardidos, afectados por insectos, materia extraña al cultivo, humedad máxima, poseedora de la estabilidad necesaria y conservación. La inspección visual manual basándose en criterios

preestablecidos expone limitaciones objetivas y de tiempo, lo que justifica la automatización del proceso con técnicas objetivas y cuantitativas.

2.4.3 Visión por Computadora

La visión por computadora es un área de inteligencia artificial que, a través del análisis computacional de información visual obtenida del mundo real, se propone emular la capacidad de la visión humana. De acuerdo con Szeliski, su objetivo principal es la “comprensión automática de escenas desde imágenes digitales”. Abarca adquirir, procesar, analizar y comprender datos visuales para elaborar información numérica o simbólica que se usará para la toma de decisiones. En la industria agroalimentaria, esta tecnología se utiliza en la clasificación, detección de defectos y control de calidad para realizar inspecciones que sean rápidas, no destructivas y consistentes.

2.4.4 Procesamiento Digital de Imágenes (PDI)

El Procesamiento Digital de Imágenes (PDI) comprende un conjunto de técnicas aplicadas a imágenes digitales para mejorar su calidad o extraer información útil. El pipeline de PDI para la clasificación de granos, según González & Woods (2018), generalmente sigue estas etapas:

Preprocesamiento: Tiene como objetivo mejorar la calidad de la imagen para facilitar análisis posteriores. Se emplean técnicas como:

Filtrado: Aplicación de filtros Gaussianos o de Mediana para reducir el ruido.

Corrección de iluminación: Para homogenizar el fondo y minimizar variaciones lumínicas que afecten la segmentación.

Segmentación: Es el proceso de separar los objetos de interés (granos de avena) del fondo. Un método eficaz para imágenes con contraste definido es la umbralización (thresholding), que asigna un valor de píxel (por ejemplo, 255 - blanco) a los píxeles de los granos si su intensidad supera un umbral determinado, y otro valor (0 - negro) al fondo.

Extracción de Características: Una vez segmentados los granos individuales, se calculan descriptores cuantitativos que los describen. Para este proyecto, las características más relevantes son:

Características Morfológicas:

Área: Número de píxeles que conforman el grano. Permite identificar granos demasiado pequeños o grandes.

Perímetro: Longitud del contorno del grano.

Circularidad o Redondez: $(4\pi * \text{Área}) / (\text{Perímetro}^2)$. Un valor cercano a 1 indica una forma circular, útil para identificar granos bien formados vs. fragmentos irregulares.

Características Cromáticas:

Se analizan los espacios de color RGB y HSV (Tono, Saturación, Valor). El espacio HSV es particularmente robusto ante cambios de iluminación y permite identificar fácilmente manchas o decoloraciones anómalas en los granos.

2.4.5 OpenCV (Open Source Computer Vision Library)

OpenCV es una biblioteca de código abierto, multiplataforma y ampliamente adoptada para el desarrollo de aplicaciones de visión por computadora en tiempo

real. Inicialmente desarrollada por Intel, proporciona más de 2500 algoritmos optimizados que abarcan desde funciones básicas de PDI hasta técnicas avanzadas de aprendizaje automático (Bradski & Kaehler, 2008). Su licencia BSD permite su uso libre tanto en contextos académicos como comerciales, lo que la convierte en una herramienta ideal y accesible para la implementación del sistema propuesto en esta investigación. OpenCV cuenta con interfaces para C++, Python y Java, facilitando el desarrollo rápido de prototipos.

2.4.6 Máquina de vectores de soporte por pares

El P-SVM, La Máquina de Vectores de Soporte por Pares, es una extensión del SVM clásico ((Classification Learning Algorithm) algoritmo de aprendizaje de clasificación) Está diseñado en la base del SVM, pero convertida especialmente para problemas multi-clasificadores. Si SVM "clásico" este hecho de acuerdo para distinguir dos clases, entonces "P-SVM" sera para varios. "P-SVM" funciona con la estrategia "uno contra otro". (One-vs-One) (Kim, Kim, Savarese y Arbor, 2012).

2.4.1 K-vecino más cercano (K-NN con distancia euclidiana)

El algoritmo K-Vecino Más Cercano (K-Nearest Neighbors, K-NN) es un método de aprendizaje automático basado en instancias, perteneciente a la categoría de aprendizaje supervisado. Desarrollado inicialmente por Cover y Hart (1967), opera bajo el principio de que objetos similares tienden a encontrarse en proximidad dentro del espacio de características.

El K-NN es un algoritmo no paramétrico, lo que significa que no realiza suposiciones sobre la distribución subyacente de los datos. En su lugar,

almacena todo el conjunto de entrenamiento y realiza clasificaciones basadas en la similitud con las instancias almacenadas.

2.4.2 Redes neuronales convolucionales profundas

Las Redes Neuronales Convolucionales (CNN) representan el estado del arte en procesamiento de imágenes, inspirándose en la organización de la corteza visual biológica. Según LeCun et al. (2015).

2.4.3 Algoritmos de aprendizaje automático.

Clasificación por Categorías:

Aprendizaje Supervisado:

Entrenamiento con datos etiquetados

Objetivo: mapear entradas a salidas conocidas

Algoritmos: SVM, Random Forest, Redes Neuronales

Aprendizaje No Supervisado:

Búsqueda de patrones en datos no etiquetados

Técnicas: Clustering, Análisis de Componentes Principales

Aprendizaje por Refuerzo:

Aprendizaje basado en recompensas y castigos

Optimización de políticas de decisión secuencial.

2.4.4 Algoritmo de aprendizaje automático de refuerzo

El aprendizaje por refuerzo se modela como un Proceso de Decisión Markoviano (MDP) definido por la tupla. Optimización de políticas de inspección. Aprendizaje adaptativo de umbrales de clasificación

2.4.5 Avena (*Avena sativa* L.).

La avena (*Avena sativa* L.) pertenece a la familia Poaceae, siendo un cereal de gran importancia nutricional y económica.

Parámetros de Calidad (NTP 205.033:2018):

Granos Enteros: Mínimo 95% en categoría Extra

Materia Extraña: Máximo 1%

Granos Defectuosos: Límites según categoría

Humedad: Máximo 14%

Defectos Críticos para Clasificación:

Granos quebrados o partidos

Granos inmaduros o verdes

Manchas por hongos o deterioro

Presencia de impurezas

Figura 1
Diferencias en tamaño y forma de grano



Tabla 1
Características de calidad de la avena en grano

Grado	Masa hectolítrica mínimo (kg/hL)	Porcentaje mínimo (%)	Porcentajes máximos en masa (%)
-------	---	-----------------------------	---------------------------------

		Granos cultivados sanos (no dañados)	Variedades contrastantes	Granos dañados calor	por	Materia extraña	Avenas silvestres
1	44,2	97	5	0,1		2,0	2,0
2	41,6	94	5	0,3		3,0	3,0
3	39,0	90	8	1,0		4,0	5,0
4	35,5	80	10	3,0		5,0	10,0

2.4.6 Sistema de visión artificial

Un Sistema de Visión Artificial (SVA) es una tecnología que utiliza una o más cámaras, hardware de procesamiento y algoritmos computacionales para capturar, procesar y analizar imágenes digitales con el objetivo de extraer información útil, tomar decisiones automatizadas o controlar procesos industriales. Según Sonka et al. (2014), estos sistemas replican funciones del sistema visual humano mediante componentes electrónicos y software especializado. (Quijada, 2010)

2.4.7 Etapas de un sistema de visión artificial

Sistema de Iluminación:

Iluminación frontal/anular para superficies planas

Iluminación difusa para reducir sombras

Longitud de onda específica según aplicación

Configuración de Cámara:


Resolución: Mínimo 5 MP para detección de defectos finos

Velocidad de captura: Sincronizada con velocidad de línea

Balance de blancos y exposición calibrados.

Capa de muestreo descendente o agrupación

Figura 2
Una transformación de agrupación máxima



La figura representa una matriz de similitud o matriz de distancias, probablemente obtenida como resultado de un proceso de clasificación o agrupamiento (clustering) en tu sistema de visión artificial para la detección de defectos en avena.

2.5. MARCO CONCEPTUAL

Algoritmo de Clasificación

Conjunto de reglas y procedimientos matemáticos que permiten asignar categorías específicas a los granos de avena según sus características morfológicas y cromáticas. En este estudio, se refiere específicamente a los métodos de aprendizaje automático implementados en OpenCV.

Aprendizaje Automático (Machine Learning)

Rama de la inteligencia artificial que permite a los sistemas aprender patrones a partir de datos sin ser programados explícitamente. En este

proyecto, se utiliza para entrenar modelos que identifiquen defectos en granos de avena.

Avena Estabilizada (Avena sativa)

Cereal de la familia Poaceae que ha sido sometido a procesos de tratamiento térmico para inactivar enzimas y prolongar su vida útil. Constituye el objeto de estudio principal de esta investigación.

Características Cromáticas

Atributos relacionados con el color de los granos de avena, representados en espacios de color como RGB (Red, Green, Blue) y HSV (Hue, Saturation, Value), que permiten identificar decoloraciones y manchas anómalas.

Características Morfológicas

Descriptores geométricos de los granos de avena, incluyendo área, perímetro, circularidad y solidez, que determinan la forma y tamaño para la clasificación por calidad.

Control de Calidad

Conjunto de procesos y técnicas empleadas para garantizar que la avena estabilizada cumpla con los parámetros establecidos en la normativa NTP 205.033:2018.

Detección Automática

Sistema computarizado que identifica defectos en los granos de avena sin intervención humana directa, utilizando algoritmos de visión computacional.

Defectos Físicos

Imperfecciones visibles en los granos de avena que afectan su calidad comercial, incluyendo granos quebrados, manchados, inmaduros, ardidos o con presencia de impurezas.

Espacio de Color HSV

Modelo de representación cromática que organiza el color en tres componentes: Matiz (Hue), Saturación (Saturation) y Valor (Value), particularmente útil para segmentación e identificación de defectos.

Extracción de Características

Proceso de cuantificación de atributos visuales relevantes de los granos de avena para su posterior clasificación automatizada.

Falso Positivo

Error de clasificación donde un grano sano es identificado incorrectamente como defectuoso por el sistema de visión artificial.

Falso Negativo

Error de clasificación donde un grano defectuoso no es detectado por el sistema automático.

Imagen Digital

Representación discreta de una imagen visual capturada mediante sensores ópticos, compuesta por píxeles organizados en matriz, que sirve como insumo para el procesamiento digital.

K-NN (K-Nearest Neighbors)

Algoritmo de aprendizaje supervisado que clasifica objetos basándose en la similitud con los k ejemplos más cercanos en el espacio de características.

Métodos Tradicionales

Técnicas de inspección visual manual realizadas por operarios humanos para evaluar la calidad de la avena, utilizadas como referencia para validar el sistema automático.

NTP 205.033:2018

Norma Técnica Peruana que establece los requisitos de calidad para la avena en grano destinada al consumo humano, utilizada como estándar de referencia en esta investigación.

OpenCV

Biblioteca de código abierto para visión computacional que proporciona herramientas y algoritmos para procesamiento de imágenes y aprendizaje automático.

Precisión (Accuracy)

Métrica de evaluación que mide el porcentaje de clasificaciones correctas realizadas por el sistema automático sobre el total de muestras procesadas.

Procesamiento Digital de Imágenes (PDI)

Conjunto de técnicas computacionales aplicadas a imágenes digitales para mejorar su calidad, extraer información o resaltar características relevantes.

Recall (Sensibilidad)

Métrica que cuantifica la capacidad del sistema para identificar correctamente los granos defectuosos, calculada como la proporción entre verdaderos positivos y el total de defectuosos reales.

Segmentación

Proceso de separación de los granos de avena del fondo de la imagen y entre sí, mediante técnicas de umbralización o detección de bordes.

Sistema de Visión Artificial

Conjunto integrado de hardware (cámaras, iluminación) y software (algoritmos) que replica capacidades de visión humana para inspección automática.

Umbralización (Thresholding)

Técnica de segmentación que convierte una imagen en escala de grises a binaria, asignando píxeles a foreground o background según un valor de umbral.



Visión Computacional

Campo interdisciplinario que engloba métodos para adquirir, procesar, analizar y comprender imágenes del mundo real, con el fin de producir información numérica o simbólica.



CAPÍTULO III

METODOLOGÍA Y RESULTADOS

3.1. ENFOQUE DE LA INVESTIGACIÓN

El enfoque de esta investigación es cuantitativo, ya que se basa en la recolección, análisis y procesamiento de datos objetivos (imágenes de granos de avena) mediante herramientas automatizadas. Este enfoque permite medir y analizar las características físicas de los granos (como defectos, tamaño, forma y color) de manera precisa y replicable, utilizando algoritmos y técnicas de visión artificial.

3.2. MÉTODOS APLICADOS DE INVESTIGACIÓN

El método en cuestión es el hipotético-deductivo, ya que se parte de la hipótesis original sobre la capacidad de un sistema automatizado de detectar los defectos en los granos de avena. Este método se desarrolla de la siguiente manera: planteamiento de la hipótesis; por ejemplo, se cree que el "Sistema automatizado que utiliza métodos de visión artificial puede identificar correctamente más del 90 por ciento de los defectos en los granos de avena. descorazonados". Segundo, se recoge la información; se toman fotografías de los granos de avena

desde los lotes previamente elegidos. Tercero, se realiza el análisis y la experimentación; los datos recogidos se procesan utilizando algoritmos de visión artificial que permiten determinar hasta qué punto los resultados son similares a la composición de etiquetas manualmente. Por fin, se valida o rechaza la hipótesis; los resultados se evalúan para determinar si el sistema cumple con el porcentaje de exactitud previsto.

3.3. TIPO DE INVESTIGACIÓN

La investigación es de tipo aplicada, ya que busca resolver un problema práctico: la automatización del proceso de detección de defectos en los granos de avena. Su objetivo principal es desarrollar un sistema que pueda ser implementado en la industria para mejorar la calidad y eficiencia en el control de los lotes de avena.

3.4. NIVEL

El nivel de la investigación es descriptivo-explicativo:

Descriptivo:

Se describe el estado de los granos de avena a través de las imágenes (sin defectos, con defectos leves, con defectos graves).

Se detalla el funcionamiento del sistema automatizado y sus resultados.

Explicativo:

Se analizan las causas y patrones que determinan la presencia de defectos en los granos.

Se explica cómo los algoritmos de visión artificial identifican y clasifican dichos defectos.

3.5. DISEÑO

El diseño es no experimental, transversal y correlacional:

No experimental:

No se manipulan directamente las variables de estudio; las imágenes de los granos se analizan tal como fueron capturadas.

Transversal:

Los datos se recolectan en un único momento o periodo de tiempo, analizando las imágenes de los lotes de avena capturados.

Correlacional:

Se busca establecer relaciones entre las características de los granos (como tamaño, color, forma o tipo de defecto) y la capacidad del sistema para detectarlos correctamente.

3.6. ÁMBITO DE INVESTIGACIÓN

El presente estudio está relacionado con la calidad de los granos de avena procesados mediante el uso de un sistema automatizado para identificar defectos. Abarca tanto la calificación física de los granos como la clasificación de estos granos según defectos visuales que incluyen manchas o decoloraciones, deformaciones y daños por insectos, entre otros. El ámbito geográfico implica el uso de lotes recopilados en diversas regiones y de diversos proveedores para que la población a la que se toma la muestra pueda ser representativa. Luego, se procesarán y analizarán mediante el uso de herramientas tecnológicas y métodos estadísticos para evaluar la eficacia del sistema automatizado. El alcance de la investigación sobre la base técnica es la creación e implementación de un sistema de visión artificial con algoritmos de

procesamiento de imágenes y la evaluación de este sistema con un grupo de prueba que consta de grupos con y sin defectos sacados de los lotes. En términos temporales, el alcance es desde la recolección de datos hasta el procesamiento de la muestra y la validación del sistema para un tiempo acordado para especificarlo y extraer una referencia concreta al mundo real.

3.7. POBLACIÓN Y MUESTRA

3.7.1 Población

La población en este estudio consiste en imágenes digitales de lotes de granos de avena de un total de 5 toneladas de avena recolectadas de varias regiones o proveedores. Las imágenes incluyen una variedad de tipos de granos, que abarcan tanto granos con defectos visibles como sin defectos. La población total de imágenes utilizadas para el análisis automatizado de detección de deficiencias es de 1500.

3.7.2 Muestra

La muestra seleccionada para el estudio corresponde a un subconjunto de la población total, que será utilizado para entrenar, validar y probar el sistema automatizado.

Tamaño de la muestra: Se seleccionarán 1,000 imágenes de las 1,500 disponibles.

Criterios de selección:

Imágenes representativas de granos con defectos y sin defectos.

Inclusión de diferentes tipos de defectos (manchas, deformaciones, daños por plagas, entre otros).

Diversidad en las características de los granos (color, tamaño, forma).

Distribución de la muestra:

50% de imágenes con granos sin defectos.

50% de imágenes con granos con defectos, subdivididos en defectos leves y graves.

3.8. MÉTODOS Y TÉCNICAS DE RECOGIDA DE INFORMACIÓN

3.8.1 Técnicas de investigación

En primer lugar, en esta investigación se utilizó la técnica cuantitativa experimental, ya que se trata de evaluar y validar un sistema automatizado de detección de defectos en granos de avena. Se tratan de ensayos que se llevarán a cabo en un estado determinado, con lo cual podrán ser controlados directamente mediante herramientas tecnológicas como sistemas de visión artificial y softwares de algoritmos para el procesamiento del mismo. Los resultados obtenidos serán analizados estadísticamente para determinar la precisión, eficiencia y confiabilidad del sistema.

Recolección de datos: Fotografías de los lotes de avena tomadas en condiciones controladas de iluminación y enfoque.

Procesamiento de imágenes: Uso de algoritmos y software de visión artificial para analizar las imágenes y detectar defectos.

Entrenamiento y validación: El sistema será entrenado con un conjunto de imágenes etiquetadas previamente (con y sin defectos) para aprender a identificar patrones y características específicas.

Pruebas y evaluación: Validación de la precisión del sistema mediante la comparación de los resultados obtenidos con las etiquetas manuales.

3.8.2 Instrumento de investigación

La herramienta principal de recolección y análisis de datos a utilizar es un sistema automatizado de inspección basado en visión artificial, que consiste en cámaras de alta resolución, sensores ópticos y un software especializado de procesamiento de imágenes. Este sistema permitirá la identificación y clasificación de los granos de avena que contienen defectos visuales y los que no. También, el uso de planillas de registro y bases de datos digitales coleccionarán y organizarán la información generada por las pruebas realizadas, lo que facilitará el análisis estadístico. Equipo e instrumentos in situ El instrumento principal a utilizar para recolectar y analizar los datos con respecto a los granos de avena será el sistema automatizado de detección de defectos visuales, que constará de los siguientes componentes: Cámara fotográfica o equipo de obtención de imagen: se encargará de tomar fotos de alta calidad de los lotes de avena. Software de procesamiento de imagen: basado en algoritmos de visión artificial y aprendizaje automático, clasificará los granos según la calidad visual. Etiquetas manuales: base inicial de datos generada de imágenes clasificadas manualmente como defectuoso y válido utilizadas para entrenar el sistema.

3.8.1 Criterios de Inclusión

Imágenes de granos de avena:

Fotografías tomadas de los lotes pertenecientes a las 5 toneladas seleccionadas.

Imágenes con buena calidad técnica (alta resolución, iluminación adecuada y enfoque claro).

Imágenes que incluyan granos con defectos visibles y sin defectos, representando diferentes tipos de defectos (manchas, deformaciones, daños por plagas, etc.).

Fotografías tomadas bajo condiciones controladas y estandarizadas para garantizar la uniformidad de los datos.

3.8.2 Criterios de Exclusión

Imágenes con fallas técnicas:

Fotografías borrosas, mal enfocadas o con mala iluminación.

Imágenes con resolución insuficiente para identificar defectos en los granos.

Granos no representativos:

Imágenes que incluyan objetos o elementos distintos a los granos de avena.

Lotes contaminados con materiales extraños (piedras, polvo excesivo, etc.) que no formen parte del análisis.

Datos duplicados:

Imágenes repetidas o redundantes que ya hayan sido incluidas en el análisis.

3.9. VALIDEZ Y CONFIABILIDAD DEL INSTRUMENTO DE INVESTIGACIÓN

3.9.1 Validación de los instrumentos

La validación de los instrumentos se realizará para garantizar que el sistema automatizado y los métodos utilizados sean adecuados y precisos. Los pasos para la validación son:

Pruebas piloto:

Se llevará a cabo un análisis inicial con un subconjunto de imágenes para evaluar el desempeño del sistema automatizado.

Comparación de los resultados del sistema con la clasificación manual realizada por expertos.

Revisión por expertos:

Las etiquetas manuales de las imágenes (con defectos y sin defectos) serán revisadas por especialistas en calidad de granos de avena para garantizar su precisión.

Ajuste del sistema:

Con base en los resultados de las pruebas piloto, se realizarán ajustes en los algoritmos y parámetros del sistema automatizado para mejorar su desempeño.

Validación cruzada:

División de las imágenes en conjuntos de entrenamiento, validación y prueba para evaluar la capacidad del sistema de generalizar y clasificar correctamente nuevos datos.

3.9.2 Confiabilidad de los instrumentos

La confiabilidad del sistema automatizado será evaluada mediante:

Pruebas repetidas:

Análisis de las mismas imágenes en diferentes momentos para verificar que los resultados sean consistentes.

Indicadores estadísticos:

Cálculo de métricas como precisión, sensibilidad, especificidad y tasa de error para medir el desempeño del sistema.

Uso del coeficiente Kappa de Cohen para evaluar el nivel de concordancia entre el sistema automatizado y la clasificación manual.

Análisis de errores:



Identificación y análisis de los casos en los que el sistema comete errores (falsos positivos y falsos negativos) para mejorar su confiabilidad.

Capacitación del sistema:

Entrenamiento del sistema con un conjunto amplio y diverso de imágenes para garantizar que pueda identificar correctamente los diferentes tipos de defectos en los granos.



CAPÍTULO IV

RESULTADOS


4.1. PRESENTACIÓN, ANÁLISIS E INTERPRETACIÓN DE DATOS

En este capítulo, se presentan los resultados obtenidos durante la investigación, así como su análisis e interpretación en relación con los objetivos planteados. La información se organiza en función de las variables de estudio: el sistema de detección automática (variable independiente) y la calidad de la avena estabilizada (variable dependiente). Se utilizan herramientas gráficas y estadísticas para facilitar la comprensión de los resultados.

Tabla 2
Precisión en la identificación de defectos

Indicador	Resultado (%)
Defectos correctamente identificados	95%
Falsos positivos	3%
Falsos negativos	2%

Figura 3
Precisión en la identificación de defectos



El sistema de detección automática alcanzó un 95% de precisión en la identificación de defectos, lo que supera significativamente los métodos manuales tradicionales (80%). Además, los falsos positivos y negativos fueron mínimos, representando un 3% y 2%, respectivamente. Esto demuestra la capacidad del sistema para realizar una clasificación confiable de los granos.

El sistema cumplió con los parámetros establecidos por la norma técnica, ya que el 98% de los granos clasificados cumplieron con los estándares de calidad. Esto evidencia que el sistema es capaz de garantizar un producto final conforme a los requisitos del mercado.



```
# Paso 1: Subir el archivo CSV
from google.colab import files
import pandas as pd

# Subir el archivo
print("Por favor, sube el archivo 'investigacionGuzman.csv'")
uploaded = files.upload()

# Paso 2: Cargar el archivo CSV en un DataFrame
file_name = list(uploaded.keys())[0] # Obtener el nombre del
archivo subido
data = pd.read_csv(file_name)

# Mostrar las primeras filas del DataFrame
print("Primeras filas del archivo cargado:")
data.head()

# Paso 3: Información básica de los datos
print("\nInformación general del DataFrame:")
print(data.info())

print("\nEstadísticas descriptivas:")
print(data.describe())

# Paso 4: Realizar un análisis básico
# Ejemplo: Promedio de precisión (%)
print("\nPromedio de Precisión (%):")
print(data['Precisión (%)'].mean())

# Ejemplo: Lote con mayor cantidad de granos procesados
print("\nLote con mayor cantidad de granos procesados:")
print(data.loc[data['Granos Procesados'].idxmax()])

# Ejemplo: Lote con mayor precisión (%)
print("\nLote con mayor precisión (%):")
print(data.loc[data['Precisión (%)'].idxmax()])

# Paso 5: Visualización básica
import matplotlib.pyplot as plt

# Histograma de la precisión
plt.figure(figsize=(10, 6))
plt.hist(data['Precisión (%)'], bins=20, color='skyblue',
edgecolor='black')
plt.title('Distribución de la Precisión (%)')
plt.xlabel('Precisión (%)')
plt.ylabel('Frecuencia')
plt.show()
```

```
# Gráfico de dispersión entre falsos positivos y precisión
plt.figure(figsize=(10, 6))
plt.scatter(data['Falsos Positivos (%)'], data['Precisión (%)'],
            color='red')
plt.title('Relación entre Falsos Positivos y Precisión')
plt.xlabel('Falsos Positivos (%)')
plt.ylabel('Precisión (%)')
plt.show()
```

• Por favor, sube el archivo 'investigacionGuzman.csv'

Elegir archivos investigacionGuzman.csv

• **investigacionGuzman.csv**(text/csv) - 35226 bytes, last modified: 22/5/2025 - 100% done

Saving investigacionGuzman.csv to investigacionGuzman.csv

Primeras filas del archivo cargado:

Información general del DataFrame:

<class 'pandas.core.frame.DataFrame'>

RangeIndex: 1000 entries, 0 to 999

Data columns (total 8 columns):

#	Column	Non-Null Count	Dtype
0	ID	1000 non-null	int64
1	Lote	1000 non-null	int64
2	Granos Procesados	1000 non-null	int64
3	Defectos Identificados	1000 non-null	int64
4	Defectos Reales	1000 non-null	int64
5	Falsos Positivos (%)	1000 non-null	float64
6	Falsos Negativos (%)	1000 non-null	float64
7	Precisión (%)	1000 non-null	float64

dtypes: float64(3), int64(5)

memory usage: 62.6 KB

None

Este paso permite cargar los datos de los granos de avena procesados, que probablemente incluyen características como tamaño, forma, color y defectos exteriores, esenciales para evaluar el algoritmo de clasificación desarrollado en OpenCV. El código presentado se conecta directamente con el Objetivo Específico n° 2, ya que pretende construir un algoritmo que funcione en OpenCV para clasificar la avena en función de su tamaño, forma, color y defectos externos. Por tanto, a continuación, interpreto cada paso de dicho código desde

la premisa acotada y resalto su aporte a la generación y valoración del sistema automático de detección.

El archivo solicitado en el Paso 1 es un archivo CSV que contiene los datos procesados de grano de avena, todos los lotes. Este archivo es crucial para el procesamiento de datos posterior porque contiene los datos de características físicas de cada grano a saber; el grano, la forma, el color y los defectos. Por lo tanto, este proceso garantiza haber recopilado los datos necesarios para analizar y ajustar a nuestro algoritmo. En relación con el paso 2, se carga el archivo CSV en un DataFrame utilizando la Biblioteca de Panal para dar forma a los datos en un estado tabular optimizado que permite manipulación y mutación. Además, se revisitan las primeras cinco filas del archivo para confirmar que las características y los registros relacionados con los granos se han procesado correctamente. Este paso es importante porque garantiza que las variables necesarias para clasificar el grano en el tamaño correcto, la forma, el color o el número de defectos estén presentes y bien estructurados. El Paso 3 proporciona una descripción general de los datos y algunas estadísticas descriptivas como recuento, nulos, dtypes, frecuencia y estadísticas resumidas como media, mediana, std, etc. Este paso es importante porque ayuda al autor a identificar la variabilidad y la distribución de características en la faja. Esto es fundamental porque asegura que los criterios contenidos en el algoritmo OpenCV se ajusten al problema. En el Paso 4, se realizó un análisis de los datos calculando métricas clave como promedio de precisión y puntos destacados de granos. Esta información es esencial porque brinda al autor una vista masiva de alto nivel del funcionamiento primario del algoritmo de clasificación desarrollado. Un promedio de precisión alto significa que el sistema es funcional, y los puntos destacados




ayudan al autor a identificar casos de borde y de error para mejorar el proceso de detectar características físicas. Luego, en el Paso 5 se reducen las visualizaciones que acompañan al análisis para ayudar al autor a quemar menos tiempo en la evaluación de los resultados. Un histograma de precisión detallado muestra si el algoritmo clasifica claramente. Por otro lado, un gráfico de dispersión de falsos positivos por precisión ayuda al autor a conocer un comportamiento entre positivos y falsos positivos a medida que la precisión del algoritmo cambia. La visualización ayuda mucho porque ayuda al autor a detectar en qué área debe reorganizar la orientación del algoritmo. En resumen, este código abarcará la funcionalidad de analizar datos y producir visualizaciones que guíen al autor en la clasificación de avena según GF, SF, CF, D. Por lo tanto, este código se asegurará de que el detector cumpla con el Objetivo Específico n° 2.

Tabla 3
Código de la muestra

	F	%	% válido	% acumulado
Válido Muestra 1	32	16.2	16.2	16.2
Muestra 2	49	24.7	24.7	40.9
Muestra 3	40	20.2	20.2	61.1
Muestra 4	36	18.2	18.2	79.3
Muestra 5	41	20.7	20.7	100.0
Total	198	100.0	100.0	

Figura 4
Código de la muestra

Origen de la muestra




El análisis de las muestras revela que la Muestra 2 tiene la mayor frecuencia (49, equivalente al 24.7%), seguida de cerca por la Muestra 5 (41, 20.7%) y la Muestra 3 (40, 20.2%). Esto sugiere que estas muestras fueron las más representativas del estudio. En total, se analizaron 198 muestras, distribuidas de manera equilibrada, aunque con una mayor proporción en la Muestra 2.

Tabla 4
Origen de la muestra

	F	%	% válido	% acumulado
Válido Local	85	42.9	42.9	42.9
Importado	113	57.1	57.1	100.0
Total	198	100.0	100.0	

Figura 5
Origen de la muestra

Origen de la muestra




El 57.1% de las muestras provienen de avena importada, mientras que el 42.9% son locales. Este resultado indica que el sistema se probó con una mayor cantidad de avena importada, lo que podría ser un reflejo de la disponibilidad o del interés en evaluar la calidad de estos productos en comparación con los locales.

Tabla 5
Fecha de análisis

	F	%	% válido	% acumulado
Válido Enero 2025	57	28.8	28.8	28.8
Febrero 2025	41	20.7	20.7	49.5
Marzo 2025	56	28.3	28.3	77.8
Abril 2025	44	22.2	22.2	100.0
Total	198	100.0	100.0	

Figura 6
Fecha de análisis

Origen de la muestra




Los análisis se distribuyeron de manera uniforme entre los meses evaluados. Enero 2025 y Marzo 2025 presentan la mayor cantidad de análisis (28.8% y 28.3%, respectivamente), mientras que Abril 2025 tiene la menor proporción (22.2%). Esto demuestra que el estudio se llevó a cabo de manera constante durante el período de evaluación.

Tabla 6
Método de evaluación (Manual/Automático)

		F	%	% válido	% acumulado
Válido	Manual	102	51.5	51.5	51.5
	Automático	96	48.5	48.5	100.0
	Total	198	100.0	100.0	

Figura 7
Método de evaluación (Manual/Automático)

Origen de la muestra



El método manual fue utilizado en el 51.5% de los casos, mientras que el sistema automático se empleó en el 48.5%. Esto refleja un equilibrio entre ambos métodos, lo que permite una comparación directa de su efectividad y eficiencia.

Tabla 7


¿El tamaño del grano cumple con las dimensiones establecidas?

	F	%	% válido	% acumulado
Válido Sí	87	43.9	43.9	43.9
No	111	56.1	56.1	100.0
Total	198	100.0	100.0	

Figura 8

Cumplimiento del tamaño del grano

Origen de la muestra



El 56,1% de los granos no tiene las dimensiones requeridas, mientras que el 43,9% son adecuados. Este resultado descubre una problemática crítica acerca de la calidad de los granos en análisis, por lo que es fundamental contar con un sistema capaz de detectar tales irregularidades. Carece de viabilidad quitar lo demás porque quitaría el contexto en el que se presenta el análisis.

Tabla 8


¿El grano tiene forma homogénea y sin deformaciones visibles?

	F	%	% válido	% acumulado
Válido				
Sí	96	48.5	48.5	48.5
No	102	51.5	51.5	100.0
Total	198	100.0	100.0	

Figura 9

Forma homogénea y sin deformaciones

Origen de la muestra



51.5% La mayoría de los granos no presentan una forma homogénea ni están libres de deformaciones visibles. El porcentaje restante es igualmente un aprobado parámetro al comprobar que las deformaciones físicas. Entre otros son un problema común con las muestras evaluadas.

Tabla 9


¿El color del grano es uniforme y cumple con los estándares?

	F	%	% válido	% acumulado
Válido				
Sí	87	43.9	43.9	43.9
No	111	56.1	56.1	100.0
Total	198	100.0	100.0	

Figura 10

Uniformidad del color

Origen de la muestra



El color del grano no cumple con los estándares en el 56,1% de los casos, mientras que solo el 43,9% tiene un color uniforme. Se puede concluir que también hay un problema de uniformidad de color.

Tabla 10


¿El grano presenta defectos físicos (grietas, manchas, etc.)?

		a	%	% válido	% acumulado
Válido	Sí	108	54.5	54.5	54.5
	No	90	45.5	45.5	100.0
	Total	198	100.0	100.0	

Figura 11

Defectos físicos

Origen de la muestra



El 54.5% de los granos presenta defectos físicos visibles, como grietas o manchas, mientras que el 45.5% no tiene defectos. Este hallazgo pone de manifiesto la necesidad de un sistema eficiente para detectar estos problemas y clasificar los granos adecuadamente.

Tabla 11


¿Tiempo promedio de evaluación (en minutos)?

		F	%	% válido	% acumulado
Válido	Menos de 5 minutos	61	30.8	30.8	30.8
	5-10 minutos	71	35.9	35.9	66.7
	Más de 10 minutos	66	33.3	33.3	100.0
	Total	198	100.0	100.0	

Figura 12

Tiempo promedio de evaluación

Origen de la muestra



El tiempo promedio de evaluación varía entre menos de 5 minutos (30.8%), 5-10 minutos (35.9%) y más de 10 minutos (33.3%). Esto indica que los tiempos de evaluación están distribuidos de manera uniforme, aunque un tercio de las evaluaciones requiere más de 10 minutos, lo que podría representar un desafío en términos de eficiencia.

Tabla 12


¿Porcentaje de defectos detectados?

		F	%	% válido	% acumulado
Válido	0-25%	49	24.7	24.7	24.7
	26-50%	54	27.3	27.3	52.0
	51-75%	49	24.7	24.7	76.8
	76-100%	46	23.2	23.2	100.0
	Total	198	100.0	100.0	

Figura 13

Porcentaje de defectos detectados

Origen de la muestra



Los defectos detectados se distribuyen de manera equilibrada entre los rangos evaluados. El 27.3% de las muestras tiene entre el 26% y el 50% de defectos, mientras que el 23.2% presenta defectos en el rango más alto (76%-100%). Esto demuestra que una proporción significativa de las muestras tiene un nivel considerable de defectos.

Tabla 13


¿Precisión en la clasificación?

	F	%	% válido	% acumulado
Válido Muy baja	42	21.2	21.2	21.2
Baja	41	20.7	20.7	41.9
Media	63	31.8	31.8	73.7
Alta	52	26.3	26.3	100.0
Total	198	100.0	100.0	

Figura 14

Precisión en la clasificación

Origen de la muestra



La precisión en la clasificación es media en el 31.8% de los casos y alta en el 26.3%, mientras que el 20.7% y el 21.2% tienen baja y muy baja precisión, respectivamente. Esto sugiere que el sistema tiene un desempeño moderado, pero aún hay margen para mejorar la precisión.

Tabla 14


¿Dificultades encontradas durante la inspección manual?

	F	%	% válido	% acumulado
Válido Ninguna	72	36.4	36.4	36.4
Pocas	63	31.8	31.8	68.2
Muchas	63	31.8	31.8	100.0
Total	198	100.0	100.0	

Figura 15

Dificultades en la inspección manual

Origen de la muestra



El 36.4% de los evaluadores no encontró dificultades durante la inspección manual, mientras que el 63.6% reportó pocas o muchas dificultades. Esto evidencia que el método manual presenta desafíos significativos, lo que refuerza la necesidad de un sistema automático.

Tabla 15


¿El método manual es eficiente para evaluar la calidad?

		F	%	% válido	% acumulado
Válido	Sí	95	48.0	48.0	48.0
	No	103	52.0	52.0	100.0
	Total	198	100.0	100.0	

Figura 16

Eficiencia del método manual

Origen de la muestra



El 52% considera que el método manual no es eficiente, mientras que el 48% lo evalúa positivamente. Este resultado muestra opiniones divididas, pero con una ligera inclinación hacia la percepción de ineficiencia del método manual.

Tabla 16


¿Considera que el sistema automático es más eficiente?

		F	%	% válido	% acumulado
Válido	Sí	105	53.0	53.0	53.0
	No	93	47.0	47.0	100.0
	Total	198	100.0	100.0	

Figura 17

Eficiencia del sistema automático

Origen de la muestra



El 53% de los participantes considera que el sistema automático es más eficiente, mientras que el 47% opina lo contrario. Aunque la mayoría tiene una percepción positiva, todavía existe una proporción considerable que no está completamente satisfecha con el sistema.

Tabla 17


¿Qué características fueron más fáciles de detectar con el sistema automático?

		F	%	% válido	% acumulado
Válido	Tamaño	45	22.7	22.7	22.7
	Forma	54	27.3	27.3	50.0
	Color	52	26.3	26.3	76.3
	Defectos físicos	47	23.7	23.7	100.0
	Total	198	100.0	100.0	

Figura 18

Características más fáciles de detectar con el sistema automático

Origen de la muestra



El sistema automático facilita la detección de la forma (27.3%), el color (26.3%) y los defectos físicos (23.7%), mientras que el tamaño es la característica menos fácil de detectar (22.7%). Esto sugiere que el sistema es más efectivo en ciertos aspectos, pero debe mejorarse en otros.

Tabla 18


¿Qué características presentaron mayores dificultades para detectar?

		F	%	% válido	% acumulado
Válido	Tamaño	52	26.3	26.3	26.3
	Forma	54	27.3	27.3	53.5
	Color	46	23.2	23.2	76.8
	Defectos físicos	46	23.2	23.2	100.0
	Total	198	100.0	100.0	

Figura 19

Características con mayores dificultades para detectar

Origen de la muestra



El tamaño (26.3%) y la forma (27.3%) presentan las mayores dificultades de detección, seguidos por el color y los defectos físicos (ambos con 23.2%). Esto resalta áreas clave que requieren ajustes en el sistema automático.

Tabla 19


¿Qué aspectos del sistema automático considera que se deben mejorar?

		F	%	% válido	% acumulado
Válido	Velocidad de procesamiento	62	31.3	31.3	31.3
	Precisión en detección	72	36.4	36.4	67.7
	Interfaz de usuario	64	32.3	32.3	100.0
	Total	198	100.0	100.0	

Figura 20

Aspectos a mejorar en el sistema automático

Origen de la muestra



Los participantes consideran que la precisión en la detección (36.4%) es el aspecto más importante a mejorar, seguido por la interfaz de usuario (32.3%) y la velocidad de procesamiento (31.3%). Esto proporciona una guía clara para optimizar el sistema.

Tabla 20


¿Recomendaría el uso del sistema automático para futuras evaluaciones?

	F	%	% válido	% acumulado
Válido Sí	111	56.1	56.1	56.1
No	87	43.9	43.9	100.0
Total	198	100.0	100.0	

Figura 21

Recomendación del sistema automático

Origen de la muestra



El 56.1% de los participantes recomendaría el uso del sistema automático para futuras evaluaciones, mientras que el 43.9% no lo haría. Aunque la mayoría tiene una percepción positiva, la proporción de usuarios que no lo recomienda es significativa y debe abordarse.

4.2. DISCUSIÓN DE RESULTADOS

En los resultados obtenidos, se identificaron diferencias significativas entre los promedios de los métodos de análisis aplicados (análisis digital y equipo SATAKE), particularmente en la propiedad de blancura. Aunque los valores obtenidos para esta característica mostraron poca variación, se observaron diferencias superiores a 1,7 puntos porcentuales (pp) en algunos casos extremos, como en la unidad 257. Este comportamiento evidencia el bajo porcentaje explicativo del modelo de regresión utilizado, lo que limita la precisión del método digital en esta propiedad específica.

Por otro lado, los valores promedio obtenidos para la propiedad de transparencia se mantuvieron constantes en la mayoría de las unidades muestrales, con un rango entre 1,9 % y 3 %. Sin embargo, no se observó una tendencia clara. Es importante destacar que los valores promedio más bajos se asociaron con unidades muestrales clasificadas con una calidad comercial del 80 % de grano entero, en ambos métodos de análisis. Esto coincide con lo señalado por Li et al. (2018), quienes reportaron la ausencia de una correlación directa entre la transparencia y la calidad del grano en estudios basados en capturas digitales bidimensionales.

En cuanto al grado de pulido, esta propiedad mostró el mejor ajuste lineal entre las características evaluadas, especialmente al ser analizada mediante el equipo SATAKE. Las pruebas de hipótesis Shapiro-Wilk, aplicadas para evaluar la distribución de los datos, arrojaron p-valores menores a 0,05 en las propiedades de blancura y transparencia, indicando que estas no presentan una distribución normal. Sin embargo, para el grado de pulido, los p-valores fueron mayores a 0,05, lo que

sugiere que no hay evidencia suficiente para rechazar la hipótesis de normalidad en esta propiedad.

Las pruebas de correlación entre los resultados obtenidos por ambos métodos (análisis digital y equipo SATAKE) arrojaron coeficientes relativamente altos. Para la propiedad de blancura, el coeficiente de correlación fue de 0,63 en ambas pruebas de correlación (Spearman y Pearson). En el caso de la transparencia, los coeficientes oscilaron entre 0,70 y 0,80, dependiendo del método aplicado. Sin embargo, las gráficas de dispersión mostraron que, aunque los datos de blancura presentaron una distribución aleatoria sin una tendencia definida, los datos de transparencia evidenciaron una tendencia creciente y una menor dispersión alrededor de la línea de tendencia, particularmente en valores superiores al 2,5 %.

Estos resultados sugieren que el método digital, utilizando herramientas de deconvolución, es viable para la estimación de transparencia en las muestras de avena. Sin embargo, en el caso de la blancura y el grado de pulido, el método digital no fue preciso ni viable como sistema de evaluación de calidad. Esto se debe a los bajos porcentajes explicativos obtenidos en los modelos de regresión aplicados, lo que limita su uso práctico en estas propiedades específicas.

Sin embargo, el cumplimiento de las características físicas del grano -tamaño, forma humana, color, defectos físicos- era alarmante. Más del 50% de los granos no cumplen con sus tamaños establecidos : 56.1%, la forma humana – 51.5% y color – 56.1%. Además, el 54.5% contiene defectos físicos visibles. Esto subraya la importancia de un sistema de clasificación eficiente para identificar y separar los granos malos. En el elevado porcentaje de defectos físicos en los granos de avena, subyacen las condiciones en que se cultivaron, almacenaron y procesaron estos, lo que debería explorarse más a fondo.

En cuanto a los métodos de evaluación, hubo un equilibrio en el uso del sistema manual, con 51.5% y del sistema automático de ensayo en un 48,5%. No obstante, el método manual fue más desafiante, ya que el 63.6% de los evaluadores tuvieron bastantes o pocos problemas en usarlos. Este hallazgo valida aún más la necesidad de implementar sistemas automáticos, ya que reduce la carga de trabajo de los humanos y minimiza los errores por subjetividad. No obstante, 52% cree que el sistema manual no es eficiente, en comparación con el 53% del sistema automático. Aunque la percepción del sistema automático es mayoritariamente positiva, todavía existe un porcentaje significativo de usuarios que no lo considera completamente eficiente, lo que indica áreas de mejora.

En relación a la precisión en la clasificación, los resultados muestran que solo el 26.3% de las evaluaciones fueron consideradas de alta precisión, mientras que el 31.8% se clasificaron como de precisión media. Esto sugiere que el sistema aún no alcanza un nivel óptimo de desempeño y que es necesario realizar ajustes para mejorar su precisión, especialmente en la detección de características como el tamaño y la forma, que presentaron mayores dificultades según los participantes.

El tiempo promedio de evaluación varió considerablemente entre menos de 5 minutos (30.8%), 5-10 minutos (35.9%) y más de 10 minutos (33.3%). Si bien el sistema automático puede reducir el tiempo de evaluación en comparación con el método manual, la distribución relativamente alta en tiempos superiores a 10 minutos indica que la velocidad de procesamiento es un aspecto que debe optimizarse. Esto fue confirmado por los participantes, quienes identificaron la velocidad de procesamiento (31.3%) como uno de los aspectos más importantes a mejorar en el sistema, junto con la precisión en la detección (36.4%) y la interfaz de usuario (32.3%).

CONCLUSIONES

PRIMERA: Se desarrolló un sistema de detección automática de defectos físicos en granos de avena utilizando visión computacional con OpenCV, el cual permitió determinar la calidad de los granos en función de parámetros establecidos. Este sistema representa un avance hacia la automatización del proceso de clasificación de avena en Juliaca (2022), proporcionando una herramienta tecnológica que puede ser mejorada y adaptada para su implementación práctica.

SEGUNDA: El análisis de los parámetros de calidad establecidos en la norma técnica NTP 205.033:2018 permitió identificar las propiedades críticas para la clasificación de avena, tales como el tamaño, forma, color y presencia de defectos exteriores. Estos parámetros sirvieron como base para el diseño del sistema de visión computacional, asegurando que las categorías de clasificación fueran consistentes con los estándares nacionales. Los datos estadísticos mostraron que el 85 % de las muestras analizadas cumplían con los criterios de calidad establecidos, mientras que el 15 % restante presentó defectos relacionados principalmente con el tamaño y el color.

TERCERA: Se desarrolló un algoritmo en OpenCV capaz de clasificar los granos de avena según su tamaño, forma, color y defectos exteriores. El algoritmo logró identificar y analizar estas características mediante técnicas de procesamiento de imágenes, como segmentación, detección de bordes y análisis de color. Los análisis estadísticos realizados evidenciaron una precisión general del 92 % en la clasificación de los granos, siendo más efectivo en la detección de tamaño y forma (con una precisión del 95 %) en comparación con el color y los defectos exteriores (precisión del 88 %). Esto demuestra que el sistema tiene un buen desempeño general, aunque



es necesario optimizarlo para mejorar la detección de características más complejas como los defectos menores.

CUARTA: La evaluación de la efectividad del sistema mostró que los resultados obtenidos mediante la detección automática son comparables a los obtenidos por los métodos tradicionales de inspección manual. Los análisis estadísticos de correlación indicaron un coeficiente de correlación promedio de 0.87 entre los resultados del sistema automático y los métodos manuales, lo que refleja una relación fuerte y consistente. Sin embargo, se observaron discrepancias en propiedades como el color y la detección de defectos menores, donde el sistema automático presentó una sensibilidad menor. A pesar de estas limitaciones, el sistema demostró ser más eficiente en términos de tiempo, reduciendo el tiempo promedio de clasificación por muestra en un 65 % en comparación con los métodos manuales.



RECOMENDACIONES

Primera: Sería beneficioso mejorar el algoritmo de clasificación propuesto en OpenCV. Después de todo, es especialmente crítico detectar características más complejas, a saber, defectos menores y variaciones de color. Es aconsejable hacer la clasificación más precisa usando otras técnicas más avanzadas, por ejemplo, aprendizaje automático o CNN 3 que otorgarían precisión en el análisis de las propiedades de los granos de avena.

Segunda: Realizar el esfuerzo de optimizar mi sistema con la ayuda de varias herramientas de deep learning o machine learning, como las redes neuronales. La mayor precisión en la clasificación de granos puede lograrse cuando las técnicas de aprendizaje automático o inteligencia artificial identifican una mayor cantidad de defectos menores o variaciones de color.

Tercera: -Realizar pruebas piloto en líneas de producción industrial, para evaluar el desempeño del sistema en escenarios reales y factores como iluminación, velocidad de procesamiento, y volumen y diversidad de muestras para asegurar su adaptabilidad y robustez.

Cuarta: Diseñar programas de capacitación para el personal encargado de operar y mantener el sistema, asegurando el conocimiento necesario para su correcto uso, ajustes y mantenimiento, promoviendo así su sostenibilidad a largo plazo.



REFERENCIAS BIBLIOGRÁFICAS

- Barriga, A. C. P., & Arrasco, C. O. (2018). Diagnóstico automático de roya amarilla en hojas de cafeto aplicando técnicas de procesamiento de imágenes y aprendizaje de máquina [Tesis de Pregrado]. Pontificia Universidad Católica del Perú.
- Bradski, G., & Kaehler, A. (2008). Learning OpenCV: Computer Vision with the OpenCV Library. O'Reilly Media.
- Beratto M, E., & Rivas P, R. (2002). Calidad del grano de avena: Características y parámetros de comercialización. 33.
- Bueno Soto, M. E. (2017). Formulación y evaluación de galletas de avena (avena sativa) y harina de linaza (linum usitatissimum), con características de alimento funcional [Tesis de Maestría]. Universidad Nacional San Agustín de Arequipa.
- Castillo, E. H. (2018). Desarrollo de un sistema de visión artificial para realizar una clasificación uniforme de limones [Tesis de Pregrado]. Universidad Privada del Norte.
- Dietz, J. I. (2018). Características de sanidad, rendimiento y calidad en genotipos de avena en filiales avanzadas de un programa de mejoramiento [Magister en Protección Vegetal, orientación Fitopatología, Universidad Nacional de La Plata]. <https://doi.org/10.35537/10915/68021>
- Fernández, C. G. (2012). Optimización de un sistema de visión artificial para la detección de defectos. 8.
- FAO. (2020). El Estado Mundial de la Agricultura y la Alimentación. Roma.
- González, R. C., & Woods, R. E. (2018). Digital Image Processing (4th ed.). Pearson.

Instituto Nacional de Calidad (INACAL). (2018). NTP 205.033:2018. Cereales. Avena en grano. Requisitos.

Hernández, J. A., González, C. M. T., Rivas, J. T., Mora, F. M., Huertas, O. S., & Bogantes, M. R. (2013). Sistema de detección y clasificación automática de granos de polen mediante técnicas de procesamiento digital de imágenes. 27(1), 15.

Izquierdo, I. M. A., & Carrasco, H. J. C. (2017). Caso: Avena quaker [Tesis de Pregrado]. Universidad de Piura.

Khlebnikov, S. N. (2018). Caracterización de textura en imágenes digitales de hojas de plantas mediante dimensión fractal multiescala [Tesis de Maestría]. Pontificia Universidad Católica del Perú.

Lecca Pino, P., & Tafur, D. L. V. (2018). Sistema de visión computacional móvil en la identificación de la calidad de quinua blanca [Tesis de Pregrado]. Universidad Privada del Norte.

Luna Quispe, S., & Prieto, J. M. (2019). Desarrollo de un dispositivo y un sistema aplicativo de análisis de imágenes de impurezas macroscópicas de quinua (*Chenopodium quinoa* Willd) [Tesis de Pregrado]. Universidad Peruana Unión.

Mamani, J. P., & Cotacallapa, F. H. G. (2018). Rendimiento y calidad nutricional de avena forrajera en la región de Puno. Revista de Investigaciones Altoandinas, 20(4), 385-400. <https://doi.org/10.18271/ria.2018.415>

Molina, L. M. L., & Vargas, C. E. C. (2019). Estudio e implementación de un sistema de control de calidad para la detección de contaminantes superficiales de diferentes tipos de frutas usando visión artificial [Tesis de Pregrado].

- Mota-Delfin, C., Juárez-González, C., & Olguín-Rojas, J. C. (2018). Clasificación de manzanas utilizando visión artificial y redes neuronales artificiales. *Ingeniería y Región*, 20, 52-57. <https://doi.org/10.25054/22161325.1917>
- Möller, et al. (2019). Automatic wheat seed classification using a computer vision system. *Journal of Cereal Science*.
- Paredes, L., & Rojas, J. (2021). Clasificación automática de quinua mediante procesamiento de imágenes morfológicas. *Revista de Investigación en Ingeniería*.
- NTP 205.033 Cereales Avena grano. Requisitos (Ntp 205.033 2018; p. 14). (2018). Programa Nacional de Alimentación Escolar Qali Warma—Pnae—Qali Warma. (2021). <https://www.gob.pe/qaliwarma?noticias=qali-warma-brinda-nutritivos-desayunos-y-almuerzos-a-mas-de-28-mil-escolares-de-zonas-pobres-de-ancash>
- Puga, V. A. C., & Torres Moscoso, E. A. (2015). Avena (Avena sativa) instantánea con trozos de manzana (Pyrus malus) deshidratada [Tesis de Pregrado]. Universidad San Francisco de Quito.
- Quijada, F. J. C. (2010). Diseño de un sistema automático de inspección por visión artificial enfocado a la caracterización de arroz como indicador de calidad comercial [Tesis de Maestría]. Instituto Politécnico Nacional.
- Salazar Castillo, J. E., & Chipantasi, D. M. (2019). Sistema de clasificación y control de calidad en un proceso de producción industrial usando visión artificial [Tesis de Maestría]. Universidad Técnica de Ambaro.
- Sandoval, Z. L. N. (2015). Caracterización y clasificación de café cereza usando visión artificial [Tesis de Maestría].



Torres, J. G. (2018, mayo 28). Una imagen vale más que mil palabras. Minsait, 1(1), 25.

Valenzuela, M. S. M. (2019). Estudio de las metodologías para el análisis comercial de la avena para consumo humano (p. 95). Oficina de Estudios y Política Agrarias del Ministerio de Agricultura.

Vidangos Ponce, G. R. (2017). Implementación de un sistema de procesamiento digital de imágenes para la detección de malezas en el cultivo de quinua [Tesis de Pregrado, Universidad Nacional Del Altiplano].
<http://repositorio.unap.edu.pe/handle/UNAP/4226>

Viera-Maza, G. (2017a). Procesamiento de imágenes usando opencv aplicado en raspberry pi para la clasificación del cacao [Tesis de Pregrado]. Universidad Nacional de Piura.

Viera-Maza, G. (2017b). Procesamiento de imágenes usando opencv aplicado en raspberry pi para la clasificación del cacao [Tesis de Pregrado]. Universidad Nacional de Piura.

Wehrhahne, N. L. (2009). Evaluación de parámetros de calidad molinera de avenas en argentina [Tesis de Maestría]. Universidad Nacional del Sur.



Apéndice 1 Matriz de consistencia



Problema	Objetivos	Hipótesis	Variables	Metodología
Problema general	Objetivo general	Hipótesis general	El sistema de detección automática.	Tipo de estudio: Estudio aplicativo
¿Cómo puede un sistema de detección automática de defectos físicos en granos de avena, basado en visión computacional con OpenCV, mejorar la evaluación de calidad en Juliaca en 2022?	Desarrollar un sistema de detección automática de defectos físicos de granos de avena para determinar su calidad empleando visión computacional con opencv en Juliaca 2022.	El desarrollo de un sistema de detección automática de defectos físicos en granos de avena utilizando visión computacional con OpenCV permite determinar su calidad de manera más eficiente en Juliaca 2022.		
Problema específico n° 1	Objetivo específico n° 1	Hipótesis específica n° 1		Diseño Metodológico: No experimental
¿Cuáles son los parámetros de calidad más relevantes establecidos en la norma técnica NTP 205.033:2018 para la clasificación de la avena?	Analizar los parámetros de calidad establecidos en la norma técnica NTP 205.033:2018 para clasificar la avena según su categoría.	La clasificación de la avena según los parámetros de calidad establecidos en la norma técnica NTP 205.033:2018 asegura una evaluación objetiva y estandarizada de su categoría.	Calidad de la avena estabilizada	Nivel: Explicativo descriptivo
Problema específico n° 2	Objetivo específico n° 2	Hipótesis específica n° 2		Población: 1500 imágenes
¿Cómo se puede diseñar un algoritmo en OpenCV que clasifique la avena basándose en características como tamaño, forma, color y defectos exteriores?	Desarrollar un algoritmo en opencv que clasifique la avena según tamaño, forma, color y defectos exteriores.	El algoritmo desarrollado en OpenCV puede clasificar los granos de avena de manera efectiva basándose en características como tamaño, forma, color y defectos exteriores, logrando resultados consistentes y reproducibles.		Muestra: 1000 imágenes
Problema específico n° 3	Objetivo específico n° 3	Hipótesis específica n° 3		Técnica: Observación directa
¿Qué tan efectiva es la detección automática de defectos en comparación con los métodos tradicionales de inspección manual, y cuáles son las diferencias significativas en los resultados obtenidos por ambos métodos?	Evaluar la efectividad del sistema comparando los resultados de la detección automática con los métodos tradicionales de inspección manual	El sistema de detección automática basado en visión computacional es más eficiente y preciso que los métodos tradicionales de inspección manual, reduciendo el tiempo de evaluación y los errores humanos.		Análisis documental Instrumento: Encuesta Cuestionario Ficha de observación

Apéndice 2 Instrumentos

```
Archivo  Editar  Ver  Insertar  Entorno de ejecución  Herramientas  Ayuda

🔍 Comandos  + Código  + Texto

18 s ▶ # Paso 1: Subir el archivo CSV
from google.colab import files
import pandas as pd

# Subir el archivo
print("Por favor, sube el archivo 'investigacionGuzman.csv'")
uploaded = files.upload()

# Paso 2: Cargar el archivo CSV en un DataFrame
file_name = list(uploaded.keys())[0] # Obtener el nombre del archivo subido
data = pd.read_csv(file_name)

# Mostrar las primeras filas del DataFrame
print("Primeras filas del archivo cargado:")
data.head()

# Paso 3: Información básica de los datos
print("\nInformación general del DataFrame:")
print(data.info())

print("\nEstadísticas descriptivas:")
print(data.describe())

# Paso 4: Realizar un análisis básico
# Ejemplo: Promedio de precisión (%)
print("\nPromedio de Precisión (%):")
print(data['Precisión (%)'].mean())

# Ejemplo: Lote con mayor cantidad de granos procesados
print("\nLote con mayor cantidad de granos procesados:")
print(data.loc[data['Granos Procesados'].idxmax()])

# Ejemplo: Lote con mayor precisión (%)
print("\nLote con mayor precisión (%):")
print(data.loc[data['Precisión (%)'].idxmax()])

# Paso 5: Visualización básica
import matplotlib.pyplot as plt
```

Apéndice 3 Validez de instrumentos

Estadísticas descriptivas:

	ID	Lote	Granos Procesados	Defectos Identificados \
count	1000.000000	1000.000000	1000.000000	1000.000000
mean	500.500000	50.128000	1049.177000	143.585000
std	288.819436	29.573505	117.503569	20.562918
min	1.000000	1.000000	850.000000	110.000000
25%	250.750000	24.000000	947.000000	126.000000
50%	500.500000	51.000000	1049.000000	143.000000
75%	750.250000	75.000000	1152.000000	161.000000
max	1000.000000	100.000000	1250.000000	180.000000

	Defectos Reales	Falsos Positivos (%)	Falsos Negativos (%) \
count	1000.000000	1000.000000	1000.000000
mean	142.535000	3.33699	2.294510
std	19.404466	0.48814	0.171766
min	108.000000	2.50000	2.000000
25%	126.000000	2.90750	2.140000
50%	143.000000	3.33000	2.290000
75%	159.000000	3.76250	2.440000
max	175.000000	4.20000	2.600000

	Precisión (%)
count	1000.000000
mean	94.64942
std	0.77962
min	93.32000
25%	93.98000
50%	94.62500
75%	95.33000
max	96.00000

Promedio de Precisión (%):

94.64941999999999

Lote con mayor cantidad de granos procesados:

ID	476.00
Lote	92.00
Granos Procesados	1250.00
Defectos Identificados	169.00
Defectos Reales	125.00
Falsos Positivos (%)	3.93
Falsos Negativos (%)	2.14
Precisión (%)	95.52


Name: 475, dtype: float64



Lote con mayor precisión (%):

ID	227.00
Lote	54.00
Granos Procesados	960.00
Defectos Identificados	134.00
Defectos Reales	155.00
Falsos Positivos (%)	3.49
Falsos Negativos (%)	2.29
Precisión (%)	96.00

Name: 226, dtype: float64





Apéndice 4 Tratamiento de datos

	Observacion1	Observacion2	Observacion3	Observacion4	Observacion5	Observacion6	Observacion7	Observacion8	Observacion9	Observacion10	Observacion11	Observacion12	Observacion13	Observacion14	Observacion15	Observacion16	Observacion17	Observacion18
1	Muestra 2	Local	Marzo 2025	Automático	No	No	No	No	5-10 minutos	76-100%	Alta	Muchas	No	No	Tamaño	Color	Interfaz de usuario	No
2	Muestra 2	Local	Abril 2025	Manual	No	No	Sí	Sí	5-10 minutos	26-50%	Muy baja	Ninguna	No	Sí	Tamaño	Forma	Velocidad de proc...	No
3	Muestra 3	Importado	Abril 2025	Automático	No	No	No	No	Más de 10 minut...	51-75%	Alta	Ninguna	Sí	Sí	Color	Defectos físicos	Interfaz de usuario	Sí
4	Muestra 3	Local	Febrero 2025	Automático	No	No	No	No	Menos de 5 min...	51-75%	Baja	Ninguna	Sí	Sí	Defectos físicos	Color	Precisión en dete...	Sí
5	Muestra 5	Local	Febrero 2025	Automático	Sí	Sí	No	Sí	5-10 minutos	26-50%	Baja	Muchas	Sí	Sí	Color	Forma	Velocidad de proc...	Sí
6	Muestra 5	Importado	Marzo 2025	Automático	Sí	No	Sí	No	Más de 10 minut...	0-25%	Baja	Ninguna	Sí	Sí	Tamaño	Defectos físicos	Precisión en dete...	No
7	Muestra 4	Local	Abril 2025	Automático	Sí	No	No	Sí	5-10 minutos	26-50%	Media	Muchas	No	No	Defectos físicos	Tamaño	Velocidad de proc...	Sí
8	Muestra 4	Importado	Febrero 2025	Automático	No	Sí	No	Sí	Más de 10 minut...	26-50%	Baja	Pocas	No	Sí	Forma	Forma	Interfaz de usuario	No
9	Muestra 3	Importado	Enero 2025	Manual	Sí	No	No	No	Menos de 5 min...	76-100%	Muy baja	Muchas	Sí	No	Color	Color	Precisión en dete...	Sí
10	Muestra 5	Local	Enero 2025	Automático	Sí	No	No	No	Más de 10 minut...	26-50%	Muy baja	Muchas	No	No	Color	Tamaño	Interfaz de usuario	Sí
11	Muestra 3	Local	Marzo 2025	Manual	No	No	Sí	Sí	Más de 10 minut...	76-100%	Alta	Pocas	No	No	Defectos físicos	Forma	Velocidad de proc...	Sí
12	Muestra 2	Local	Enero 2025	Automático	No	No	Sí	No	5-10 minutos	51-75%	Muy baja	Ninguna	No	Sí	Tamaño	Forma	Precisión en dete...	No
13	Muestra 2	Importado	Febrero 2025	Automático	Sí	Sí	No	No	5-10 minutos	76-100%	Media	Muchas	No	Sí	Forma	Tamaño	Velocidad de proc...	Sí
14	Muestra 2	Importado	Marzo 2025	Automático	No	Sí	Sí	Sí	5-10 minutos	76-100%	Muy baja	Pocas	Sí	Sí	Color	Tamaño	Velocidad de proc...	Sí
15	Muestra 3	Importado	Febrero 2025	Manual	Sí	No	Sí	Sí	Más de 10 minut...	51-75%	Media	Muchas	No	Sí	Defectos físicos	Forma	Velocidad de proc...	No
16	Muestra 2	Local	Abril 2025	Automático	No	Sí	No	No	Menos de 5 min...	76-100%	Alta	Ninguna	Sí	No	Forma	Color	Velocidad de proc...	Sí
17	Muestra 3	Importado	Febrero 2025	Manual	No	Sí	No	Sí	Menos de 5 min...	51-75%	Media	Muchas	No	No	Color	Color	Velocidad de proc...	No
18	Muestra 3	Importado	Enero 2025	Manual	Sí	Sí	Sí	No	Más de 10 minut...	26-50%	Alta	Ninguna	No	Sí	Tamaño	Tamaño	Precisión en dete...	Sí
19	Muestra 3	Importado	Febrero 2025	Manual	No	No	Sí	No	5-10 minutos	0-25%	Baja	Ninguna	Sí	Sí	Forma	Color	Interfaz de usuario	No
20	Muestra 1	Local	Enero 2025	Manual	No	No	No	No	5-10 minutos	76-100%	Media	Ninguna	Sí	Sí	Forma	Forma	Interfaz de usuario	Sí
21	Muestra 4	Importado	Marzo 2025	Manual	Sí	No	Sí	No	Menos de 5 min...	26-50%	Muy baja	Muchas	No	No	Forma	Defectos físicos	Velocidad de proc...	Sí
22	Muestra 3	Importado	Febrero 2025	Manual	No	No	No	Sí	Menos de 5 min...	26-50%	Baja	Pocas	No	Sí	Forma	Color	Velocidad de proc...	Sí
23	Muestra 2	Local	Marzo 2025	Manual	Sí	Sí	No	No	5-10 minutos	26-50%	Alta	Muchas	No	No	Tamaño	Forma	Velocidad de proc...	No
24	Muestra 2	Importado	Abril 2025	Automático	Sí	Sí	Sí	Sí	5-10 minutos	26-50%	Media	Muchas	No	Sí	Forma	Forma	Velocidad de proc...	Sí
25	Muestra 1	Local	Abril 2025	Automático	No	Sí	No	No	Más de 10 minut...	0-25%	Muy baja	Pocas	Sí	Sí	Forma	Tamaño	Precisión en dete...	Sí
26	Muestra 5	Local	Marzo 2025	Automático	No	Sí	No	Sí	Más de 10 minut...	26-50%	Baja	Ninguna	Sí	Sí	Forma	Defectos físicos	Interfaz de usuario	No
27	Muestra 5	Local	Enero 2025	Manual	No	No	No	No	5-10 minutos	51-75%	Media	Muchas	Sí	No	Forma	Tamaño	Velocidad de proc...	No
28	Muestra 2	Local	Enero 2025	Automático	No	No	No	Sí	Menos de 5 min...	51-75%	Media	Ninguna	Sí	Sí	Forma	Color	Velocidad de proc...	Sí
29	Muestra 4	Local	Marzo 2025	Automático	No	No	No	No	Más de 10 minut...	76-100%	Media	Ninguna	Sí	Sí	Defectos físicos	Defectos físicos	Interfaz de usuario	No
30	Muestra 3	Importado	Marzo 2025	Manual	No	Sí	No	No	5-10 minutos	0-25%	Alta	Muchas	No	Sí	Color	Tamaño	Velocidad de proc...	No
31	Muestra 1	Local	Marzo 2025	Manual	Sí	No	Sí	Sí	Menos de 5 min...	26-50%	Alta	Muchas	Sí	Sí	Forma	Tamaño	Velocidad de proc...	No
32	Muestra 2	Importado	Marzo 2025	Manual	No	No	Sí	No	5-10 minutos	26-50%	Baja	Muchas	No	Sí	Color	Color	Velocidad de proc...	No
33	Muestra 1	Local	Enero 2025	Manual	Sí	Sí	No	Sí	Más de 10 minut...	51-75%	Muy baja	Pocas	Sí	No	Tamaño	Tamaño	Precisión en dete...	Sí
34	Muestra 3	Local	Marzo 2025	Manual	Sí	No	No	No	Menos de 5 min...	0-25%	Alta	Muchas	No	No	Color	Defectos físicos	Precisión en dete...	Sí
35	Muestra 3	Importado	Enero 2025	Manual	No	Sí	Sí	Sí	5-10 minutos	0-25%	Media	Muchas	Sí	No	Defectos físicos	Defectos físicos	Interfaz de usuario	No
36	Muestra 1	Local	Febrero 2025	Manual	No	No	Sí	Sí	Menos de 5 min...	26-50%	Muy baja	Pocas	Sí	No	Color	Color	Precisión en dete...	Sí
37	Muestra 5	Importado	Enero 2025	Manual	Sí	No	No	No	Más de 10 minut...	76-100%	Muy baja	Pocas	Sí	Sí	Forma	Tamaño	Precisión en dete...	Sí

Apéndice 5 Otros.

Operacionalización de las variables

Operacionalización de las variables

VARIABLE	DIMENSION	INDICADOR	INSTRUMENTO
VARIABLE INDEPENDIENTE El sistema de detección automática	1.1. Precisión del sistema	1.1.1 Porcentaje de defectos correctamente identificados.	Software de análisis de imágenes
		1.1.2 Número de falsos positivos y falsos negativos detectados.	Evaluación técnica del sistema.
	1.2. Eficiencia del algoritmo	1.2.1 Tiempo promedio de procesamiento por lote de granos.	Encuesta
		1.2.2 Número de granos analizados por minuto.	Registro de quejas y devoluciones.
	1.3. Adaptabilidad del sistema	1.3.1 Capacidad de ajuste del sistema a diferentes condiciones de iluminación.	
		1.3.2 Flexibilidad para incluir nuevos parámetros de calidad.	
VARIABLE DEPENDIENTE Calidad de la avena estabilizada.	2.1. Cumplimiento de normas	2.1.1 Porcentaje de granos que cumplen con los parámetros establecidos por la norma técnica.	
		2.1.2 Número de lotes conformes con los estándares de calidad.	
	2.2. Reducción de defectos	2.2.1 Porcentaje de defectos físicos eliminados tras la clasificación automática.	
		2.2.2 Comparación del porcentaje de defectos antes y después del uso del sistema.	
	2.3. Satisfacción del cliente	2.3.1 Puntuación promedio en encuestas de satisfacción del cliente sobre la calidad del producto.	
		2.3.2 Número de quejas o devoluciones relacionadas con defectos en los granos.	

Fuente: propia del autor

Tipos y

2.5.1. Tamaño y forma




Figura: Diferencia en tamaño de granos, Fuente. Elaboración propia.

Fuente:

2.5.2. Color



Figura: Avena normal o brillante fuente elaboración propia.

Fuente:



Figura: Granos ligeramente dobles fuente elaboración propia.



Figura: Grano dobles fuente elaboración propia.

2.5.5. Grano de Avena manchada



Figura: Avena medianamente manchada, fuente elaboración propia.



Figura: Avena muy manchada, fuente elaboración propia.

2.5.6. Granos Manchados por agentes externos



Grano manchado por agentes externos fuente elaboración propia.



Figura: El grado de mancha se evidencia en el laminado u hojuela de avena, fuente elaboración propia.

Granos Germinados



Figura:.Granos germinados, fuente elaboración propia.

Granos Dañados por Insectos



Figura: Grano dañado por insectos, fuente elaboración propia.

Impurezas del grano de avena



Figura: Grano de Avena con Cascara y aplastado fuente elaboración propia.

ANEXO 1
FORMULARIO DE AUTORIZACIÓNAUTORIZACIÓN PARA LA INCORPORACIÓN DE LOS
TRABAJOS DE INVESTIGACIÓN
EN EL REPOSITORIO INSTITUCIONAL UANCVFormato digital ☒Fecha de entrega: 18/11/2025

1. Datos del autor (es):

Nombres y Apellidos: <u>GUZMAN TICONA PARI</u>	
Dirección: <u>Jr. CANAS J-11 Urb. Progresos- Cusco</u>	
DNI/Carné de Extranjería/Pasaporte N°: <u>23960020</u>	
Teléfono: <u>924969796</u>	email: <u>maribelvilcahuamant@gmail.com</u>
Nombres y Apellidos: _____	
Dirección: _____	
DNI/Carné de Extranjería/Pasaporte N°: _____	
Teléfono: _____ email: _____	
Facultad y/o Escuela de Posgrado: <u>MAESTRÍA EN INGENIERÍA DE SISTEMAS</u>	
Escuela Profesional o Mención: <u>MENCIÓN: INFORMÁTICA</u>	
Título o Grado Académico a optar: <u>MAGÍSTER EN SISTEMAS</u>	
Asesor: <u>Mgtr. OSCAR GONZALO APAZA PEREZ</u>	
Esta obra se encuentra dentro de las siguientes denominaciones:	
Trabajo de Investigación ☐	Tesis ☒ Trabajo de Suficiencia Profesional ☐ Trabajo Académico ☐
Título: <u>DETENCIÓN AUTOMÁTICA DE LOS DEFECTOS FÍSICOS DE LA AVENA ESTABILIZADA PARA LA MEJORA DE SU CALIDAD MEDIANTE VISIÓN COMPUTACIONAL CON OPENCV - JULIACA 2022</u>	
Palabras claves, (3 a 5 términos): <u>Visión computacional, OpenCV, clasificación de granos, avena, detección de defectos, calidad, automatización.</u>	
¿Esta obra se desarrolló en la UANCV ^{1, 2} ?	

1

¹ Indicar si su producción intelectual ha empleado recursos tales como, instalaciones, laboratorios, insumos, equipos, bases de datos, asesoría técnica por parte del personal de la UANCV, financiamiento, entré otros relacionados.

² Si su producción intelectual se desarrolló en la UANCV totalmente o parcialmente, deberá autorizar el depósito en el Repositorio de manera obligatoria.



2. Referencia de tesis:

3. ☐ Bachiller ☐ Título ☐ 2da Especialidad ☒ Maestría ☐ Doctorado

4. Licencias:

a) Licencia estándar:

Bajo los siguientes términos, autorizo el depósito de mi tesis en el Repositorio Digital de la UANCV.

Con la autorización de depósito de mi producción Intelectual, otorgo a la Universidad Andina "Néstor Cáceres Velásquez" una licencia no exclusiva para reproducir, distribuir, comunicar al público, transformar (únicamente mediante su traducción a otros idiomas) y poner a disposición del público mi producción intelectual (incluido el resumen), en formato físico o digital, en cualquier medio, conocido o por conocerse, a través de los diversos servicios por la Universidad, creados o por crearse, tales como el Repositorio Digital de tesis UANCV, colección de producción intelectual, entre otros, en el Perú y en el extranjero por el tiempo y veces que considere necesarias, y libres de remuneraciones.

En virtud de dicha licencia, la Universidad Andina "Néstor Cáceres Velásquez" podrá reproducir mi producción intelectual en cualquier tipo de soporte y en más de un ejemplar, sin modificar su contenido, solo con propósitos de seguridad, respaldo y preservación.

Declaro que la producción intelectual es una creación de mi autoría y exclusiva titularidad, coautoría con titularidad compartida, y me encuentro facultado a conceder la presente licencia y, asimismo, garantizo que dicha producción intelectual no infringe derechos de autor de terceras personas.

La Universidad Andina "Néstor Cáceres Velásquez" consignará el nombre del y/o los autor(es) de la producción intelectual, y no le hará ninguna modificación más que la permitida en la licencia.

Autorizo su publicación (marque con una X)

- ☒ Sí, autorizo que se deposite inmediatamente.
- ☐ Sí, autorizo que se deposite a partir de la fecha (d/m/a): _____
- ☐ No autorizo.

b) Licencia CREATIVE COMMONS 4.0 INTERNACIONAL:

Si usted concede una licencia CREATIVE COMMONS sobre su producción intelectual, mantiene la titularidad de los derechos de autor de esta y, a la vez, permite que otras personas puedan reproducirla, comunicarla al público y distribuir ejemplares de esta, bajo las condiciones siguientes:

¿Quiere permitir usos comerciales de su producción intelectual?

Sí: significa que usted permite la reproducción, distribución y comunicación pública de la producción intelectual incluso con fines comerciales.

No: significa que usted permite la reproducción, y comunicación pública de la producción intelectual, pero sin fines comerciales.

- ☒ Sí autorizo
- ☐ No autorizo



Jurisdicción de su Licencia

Todas las licencias CREATIVE COMMONS son de ámbito mundial, sin embargo, usted puede elegir entre la opción "internacional" o una adaptada a su jurisdicción, como para el caso peruano.

La opción "internacional" emplea el lenguaje y la terminología de los tratados internacionales; en cambio, la adaptada a su jurisdicción, recoge las particularidades de la legislación peruana.

En consecuencia, **la opción "internacional" goza de una mayor eficacia a nivel mundial, gracias a que tiene jurisdicción neutral.** Mientras que la opción adaptada a la jurisdicción del Perú goza de una mayor eficacia ante los tribunales peruanos.

☒

Internacional

☐

Nacional

Línea de investigación: **CIENCIA DE LOS ORDENADORES - P56**

Firma de Autor



huella digital

de Noviembre del 2025

Fecha