



UTMACH

FACULTAD DE CIENCIAS QUÍMICAS Y DE LA SALUD

CARRERA DE ALIMENTOS

**Predicción del índice de madurez de Musa Acuminata (banano orito)
mediante la aplicación de la inteligencia artificial**

**PAZ ZHUÑO CARLOS HUMBERTO
INGENIERO EN ALIMENTOS**

**IDROVO MOLINA KAROL NICOLE
INGENIERA EN ALIMENTOS**

**MACHALA
2024**



UTMACH

FACULTAD DE CIENCIAS QUÍMICAS Y DE LA SALUD

CARRERA DE ALIMENTOS

Predicción del índice de madurez de Musa Acuminata (banano orito) mediante la aplicación de la inteligencia artificial

**PAZ ZHUÑO CARLOS HUMBERTO
INGENIERO EN ALIMENTOS**

**IDROVO MOLINA KAROL NICOLE
INGENIERA EN ALIMENTOS**

**MACHALA
2024**



UTMACH

FACULTAD DE CIENCIAS QUÍMICAS Y DE LA SALUD

CARRERA DE ALIMENTOS

TRABAJOS EXPERIMENTALES

Predicción del índice de madurez de Musa Acuminata (banano orito) mediante la aplicación de la inteligencia artificial

**PAZ ZHUÑO CARLOS HUMBERTO
INGENIERO EN ALIMENTOS**

**IDROVO MOLINA KAROL NICOLE
INGENIERA EN ALIMENTOS**

MARTINEZ MORA EDISON OMAR

**MACHALA
2024**

Predicción del índice de madurez de Musa Acuminata (banano orito) mediante la aplicación de la inteligencia artificial

por Karol Nicole Idrovo Molina

Fecha de entrega: 08-ago-2024 09:36p.m. (UTC-0500)

Identificador de la entrega: 2429304814

Nombre del archivo: rito_mediante_la_aplicaci_n_de_la_inteligencia_artificial_2.pdf (1.23M)

Total de palabras: 13624

Total de caracteres: 73349

Predicción del índice de madurez de Musa Acuminata (banano orito) mediante la aplicación de la inteligencia artificial

INFORME DE ORIGINALIDAD

9%

INDICE DE SIMILITUD

8%

FUENTES DE INTERNET

3%

PUBLICACIONES

4%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	etheses.lib.ntust.edu.tw Fuente de Internet	<1 %
2	repositorio.upec.edu.ec Fuente de Internet	<1 %
3	www.yrpiyku.com Fuente de Internet	<1 %
4	Submitted to Escuela Politecnica Nacional Trabajo del estudiante	<1 %
5	repositorio.utc.edu.ec Fuente de Internet	<1 %
6	www.produccioncientificaluz.org Fuente de Internet	<1 %
7	Submitted to Universidad de Lima Trabajo del estudiante	<1 %
8	tesla.puertomaderoeditorial.com.ar Fuente de Internet	<1 %

9	www.journalbusinesses.com Fuente de Internet	<1 %
10	Submitted to Universidad Cesar Vallejo Trabajo del estudiante	<1 %
11	documentop.com Fuente de Internet	<1 %
12	rehip.unr.edu.ar Fuente de Internet	<1 %
13	repositorio.ufla.br Fuente de Internet	<1 %
14	buscador.una.edu.ni Fuente de Internet	<1 %
15	journal.uny.ac.id Fuente de Internet	<1 %
16	www.iis.org Fuente de Internet	<1 %
17	Jayita Dutta, Manasi Patwardhan, Parijat Deshpande, Shirish Karande, Beena Rai. "Zero-Shot Transfer Learned Generic AI models for prediction of ideally ripe climacteric fruits", Research Square Platform LLC, 2022 Publicación	<1 %
18	dspace.udla.edu.ec Fuente de Internet	<1 %

19

es.unionpedia.org

Fuente de Internet

<1 %

20

Daniel Vera-Aviles, Carmita Suarez-Capello,
Mercè Llugany, Charlotte Poschenrieder,
Paola De Santis, Milton Cabezas-Guerrero.
"Arthropod Diversity Influenced by Two Musa-
Based Agroecosystems in Ecuador",
Agriculture, 2020

Publicación

<1 %

21

[Submitted to University of Lincoln](#)

Trabajo del estudiante

<1 %

22

doczz.es

Fuente de Internet

<1 %

23

dspace.utpl.edu.ec

Fuente de Internet

<1 %

24

repositorio.upao.edu.pe

Fuente de Internet

<1 %

25

[Submitted to Taylor's Education Group](#)

Trabajo del estudiante

<1 %

26

repositorio.uteq.edu.ec

Fuente de Internet

<1 %

27

www.classcentral.com

Fuente de Internet

<1 %

28

www.m.growingscience.com

Fuente de Internet

<1 %

29	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1 %
30	repositorio.unp.edu.pe Fuente de Internet	<1 %
31	repositorio.utn.edu.ec Fuente de Internet	<1 %
32	revistasecauned.com Fuente de Internet	<1 %
33	sciendo.com Fuente de Internet	<1 %
34	Submitted to Universidad Politécnica Estatal de Carchi Trabajo del estudiante	<1 %
35	docplayer.es Fuente de Internet	<1 %
36	repositorij.kemija.unios.hr Fuente de Internet	<1 %
37	www.ijcaonline.org Fuente de Internet	<1 %
38	Submitted to Universidad Politecnica Salesiana del Ecuador Trabajo del estudiante	<1 %
39	Submitted to Universidad de Valladolid Trabajo del estudiante	<1 %

40

ciencialatina.org

Fuente de Internet

<1 %

41

futur.upc.edu

Fuente de Internet

<1 %

42

vdocuments.mx

Fuente de Internet

<1 %

43

www.mdpi.com

Fuente de Internet

<1 %

44

www.nuevoviernes-nuevolibro.es

Fuente de Internet

<1 %

45

www.revistaespacios.com

Fuente de Internet

<1 %

46

Submitted to Institución Tecnológica
Metropolitana de Medellín

Trabajo del estudiante

<1 %

47

Lariza Flores Ydraac, Miguel Ángel Fernández
Villavicencio, Erika Heredia Ponce. "Valores
Cefalométricos craneofaciales en niños
preescolares del Jardín de Niños CENDI
UNAM", Revista Odontológica Mexicana, 2004

Publicación

<1 %

48

Raquel Mejía-Sánchez, Eduardo Cárcamo-
Zepeda, Evelyn Martínez, René Padilla et al.
"Valoración de la experiencia virtual de
estudiantes universitarios: Un estudio
fenomenológico", PsyArXiv, 2022

<1 %

49	repositorio.itb.edu.ec Fuente de Internet	<1 %
50	www.deposita.ibict.br Fuente de Internet	<1 %
51	ejournal.uin-suska.ac.id Fuente de Internet	<1 %
52	manualzz.com Fuente de Internet	<1 %
53	www.reciamuc.com Fuente de Internet	<1 %
54	www.researchgate.net Fuente de Internet	<1 %
55	Submitted to Universidad Adolfo Ibáñez Trabajo del estudiante	<1 %
56	dspace.unitru.edu.pe Fuente de Internet	<1 %
57	medium.com Fuente de Internet	<1 %
58	pdfcookie.com Fuente de Internet	<1 %
59	reliefweb.int Fuente de Internet	<1 %
60	repositorio.unesum.edu.ec	

Fuente de Internet

<1 %

61

repositorioinstitucional.uabc.mx

Fuente de Internet

<1 %

62

uta.edu.ec

Fuente de Internet

<1 %

63

www.iattc.org

Fuente de Internet

<1 %

64

www.labc.usb.ve

Fuente de Internet

<1 %

65

www.theinsightpartners.com

Fuente de Internet

<1 %

66

Jeffrey J. Roth, William Hughes. "Dam Maintenance and Rehabilitation II", CRC Press, 2019

Publicación

<1 %

67

energia.mecon.gov.ar

Fuente de Internet

<1 %

68

eprints.soton.ac.uk

Fuente de Internet

<1 %

69

eprints.ucm.es

Fuente de Internet

<1 %

70

eur-lex.europa.eu

Fuente de Internet

<1 %

71	http://200.13.202.26/proyectos/pdf/951680089inf.pdf	<1 %
	Fuente de Internet	
72	library.ciat.cgiar.org	<1 %
	Fuente de Internet	
73	repositorio.up.edu.pe	<1 %
	Fuente de Internet	
74	revclinesp.es	<1 %
	Fuente de Internet	
75	revistaespacios.com	<1 %
	Fuente de Internet	
76	vm36.upi.edu	<1 %
	Fuente de Internet	
77	www.coursehero.com	<1 %
	Fuente de Internet	
78	www.oregon.gov	<1 %
	Fuente de Internet	
79	www2.deloitte.com	<1 %
	Fuente de Internet	
80	Jorge Abel Recio Recio. "Técnicas de extracción de características y clasificación de imágenes orientada a objetos aplicadas a la actualización de bases de datos de ocupación del suelo", Universitat Politecnica de Valencia, 2009	<1 %
	Publicación	

81	Ziba Parsa, Sahar Roozbehi, Mehdi Hosseinifarahi, Mohsen Radi, Sedigheh Amiri. " Integration of pomegranate peel extract (PPE) with calcium sulphate (CaSO): A friendly treatment for extending shelf-life and maintaining postharvest quality of sweet cherry fruit ", Journal of Food Processing and Preservation, 2020 Publicación	<1 %
82	cloud.google.com Fuente de Internet	<1 %
83	dis.um.es Fuente de Internet	<1 %
84	dspace.vutbr.cz Fuente de Internet	<1 %
85	http://200.13.202.26/proyectos/pdf/971472021inf.pdf Fuente de Internet	<1 %
86	journal.yrpiiku.com Fuente de Internet	<1 %
87	play.google.com Fuente de Internet	<1 %
88	repositorio.ucv.edu.pe Fuente de Internet	<1 %
89	sedici.unlp.edu.ar Fuente de Internet	<1 %

90	www.cfs.gov.hk Fuente de Internet	<1 %
91	www.colibri.udelar.edu.uy Fuente de Internet	<1 %
92	www.collegeparentcentral.com Fuente de Internet	<1 %
93	www.iniap.gob.ec Fuente de Internet	<1 %
94	www.medicinaoral.com Fuente de Internet	<1 %
95	www.monografias.com Fuente de Internet	<1 %
96	www.mql5.com Fuente de Internet	<1 %
97	www.sabiia.cnptia.embrapa.br Fuente de Internet	<1 %
98	www.scribd.com Fuente de Internet	<1 %
99	www.tailoy.com.pe Fuente de Internet	<1 %
100	MA Pérez-Chavarría, HH Hidalgo-Silva, FJ Ocampo-Torres. "Time series prediction using artificial neural networks", Ciencias Marinas, 2002 Publicación	<1 %

101

"Data Analytics and Computational Intelligence: Novel Models, Algorithms and Applications", Springer Science and Business Media LLC, 2023

Publicación

<1 %

102

Samuel Núñez-Cook, Fernando Vidal Mugica, Paulo Salinas. " Skull anatomy of the endangered Patagonian huemul deer() ", Anatomia, Histologia, Embryologia, 2022

Publicación

<1 %

Excluir citas

Apagado

Excluir coincidencias

Apagado

Excluir bibliografía

Apagado

CLÁUSULA DE CESIÓN DE DERECHO DE PUBLICACIÓN EN EL REPOSITORIO DIGITAL INSTITUCIONAL

Los que suscriben, PAZ ZHUÑO CARLOS HUMBERTO y IDROVO MOLINA KAROL NICOLE, en calidad de autores del siguiente trabajo escrito titulado Predicción del índice de madurez de Musa Acuminata (banano orito) mediante la aplicación de la inteligencia artificial, otorgan a la Universidad Técnica de Machala, de forma gratuita y no exclusiva, los derechos de reproducción, distribución y comunicación pública de la obra, que constituye un trabajo de autoría propia, sobre la cual tienen potestad para otorgar los derechos contenidos en esta licencia.

Los autores declaran que el contenido que se publicará es de carácter académico y se enmarca en las disposiciones definidas por la Universidad Técnica de Machala.

Se autoriza a transformar la obra, únicamente cuando sea necesario, y a realizar las adaptaciones pertinentes para permitir su preservación, distribución y publicación en el Repositorio Digital Institucional de la Universidad Técnica de Machala.

Los autores como garantes de la autoría de la obra y en relación a la misma, declaran que la universidad se encuentra libre de todo tipo de responsabilidad sobre el contenido de la obra y que asumen la responsabilidad frente a cualquier reclamo o demanda por parte de terceros de manera exclusiva.

Aceptando esta licencia, se cede a la Universidad Técnica de Machala el derecho exclusivo de archivar, reproducir, convertir, comunicar y/o distribuir la obra mundialmente en formato electrónico y digital a través de su Repositorio Digital Institucional, siempre y cuando no se lo haga para obtener beneficio económico.



PAZ ZHUÑO CARLOS HUMBERTO

0706544541



IDROVO MOLINA KAROL NICOLE

0705305829

DEDICATORIA

Dedico el presente trabajo de titulación con todo el cariño y esfuerzo a Dios quien supo guiarme por el buen camino para prosperar en la vida y seguir adelante. Además, dedico a mis padres por forjarme como la persona que soy ahora, por su amor, paciencia y esfuerzo que me entregaron durante toda mi vida, también quiero agradecer a mis queridos familiares, amigos y docentes de la carrera que me colaboraron con los recursos necesarios para el estudio, me ha servido de ayuda para fortalecerme y ser perseverante en los obstáculos que exista y de este modo poder perseguir mis metas y objetivos.

Carlos Paz Zhuño

A Dios, cuya infinita gracia y guía han sido fundamentales en cada paso de este arduo pero gratificante camino. Su presencia ha sido mi mayor fortaleza, y a Él dedico este logro con profunda gratitud. A mi querida hija, con su alegría y su presencia ha sido la fuente de mi mayor inspiración, tu luz me ha motivado a seguir adelante y a dar lo mejor de mí. A mi mamá, por su amor incondicional, sus consejos sabios y por ser siempre mi apoyo inquebrantable. Agradezco cada sacrificio que hizo por mí y por haber estado a mi lado en cada paso de este viaje. A mi esposo, por su inagotable paciencia, por ser mi compañero fiel, por creer en mí en los momentos más difíciles, y por esperarme con amor mientras alcanzaba este objetivo tan anhelado. Tu apoyo constante ha sido fundamental en este logro.

Karol Idrovo Molina

AGRADECIMIENTO

Agradezco primeramente a Dios por permitir darme salud, inteligencia, sabiduría para desarrollar mis habilidades académicas durante estos tiempos, gracias a su fé se logró alcanzar un meta más convertirme un profesional de calidad. Segundo lugar agradezco a mis padres que me han apoyado en mis estudios, que día a día me inculcaron valores éticos y morales, impartiendo paciencia y amor durante toda mi vida, para poder ser parte de una red grande de jóvenes profesionales de la Universidad Técnica de Machala. De este modo seguir en constante preparación para contribuir a la sociedad con los nuevos conocimientos adquiridos, también le agradezco a mis profesores de la carrera, especialmente al tutor de la tesis, Dr. Omar Martínez que a nos ha impartido constancia, y educación, siendo un pilar grande en la orientación del trabajo de titulación, además agradezco a mis profesores y amigos por compartir sus conocimientos y destrezas académicas, ya que servirá de ayuda para poder seguir adelante y ser visionarios a nuevos campos de estudio

Carlos Paz Zhuño

Quiero expresar mi más profundo agradecimiento a Dios, a Jesús y a María Santísima, por iluminar mi sendero y darme la fuerza necesaria para perseverar hasta el final. Sin su guía divina, nada de esto habría sido posible. A mi hija, quien ha sido mi mayor motivación, gracias por llenar mis días de alegría y por recordarme siempre la importancia de seguir adelante. A mi mamá, por su amor y apoyo incondicionales, por estar siempre presente y por ser mi refugio en los momentos de incertidumbre. Tus palabras de aliento y tu confianza en mí han sido un pilar en este proceso. A mi esposo, por su paciencia, su confianza y su constante apoyo. A mi tutor de tesis, por su guía y compromiso durante todo este proceso. Su orientación y dedicación fueron esenciales para que pudiera concluir este trabajo con éxito. A mis amigos docentes y a mi compañero de tesis que han estado a mi lado en todo momento, por su lealtad, su comprensión y por ser gran apoyo incondicional y amistad en estos años de aprendizaje que han sido invaluable en esta etapa de mi vida.

Karol Idrovo Molina

RESUMEN

La producción de banano orito (*Musa acuminata* AA) es una actividad muy significativa que forma parte de la economía del país, siendo aprovechada como fruta o como insumo en el procesamiento de alimentos. En este sentido, la automatización del proceso de clasificación de frutas contribuye a ahorrar tiempo y mermar errores en tareas que intervienen personas. La presente investigación tiene como objetivo predecir el índice de madurez del banano orito *Musa acuminata* AA usando la inteligencia artificial, disminuyendo así los errores que se pueden ocasionar por medio de la vista humana para clasificar esta fruta. Para alcanzar el objetivo propuesto se utilizaron algoritmos de Inteligencia Artificial (IA), en particular *Deep Learning* tales como: *tensorflow*, *keras*, *Neural Networks*, *Backpropagation*, *numpy* las y las bibliotecas de *Matplotlib*, *pyplot* y *Sciklearn*, los que fueron alimentados con imágenes y resultados de los análisis de fisicoquímicos de laboratorio como: acidez titulable, sólidos solubles, textura y pH. Se confeccionó una carta de colores con tres estadios madurativos inmaduro (IM), maduro (MA) y sobre maduro (SM). Luego del tratamiento de la información por parte de los algoritmos, se llegó a obtener un test accuracy del 0,94; este resultado se afianzó en las matrices de confusión de cada algoritmo analizado según los resultados sujetos, se puede deducir que los algoritmos de IA pueden ser utilizados para predicción del índice de madurez del banano orito con alta precisión.

Palabras Clave: Banano orito, inteligencia artificial, *deep learning*, maduración.

ABSTRACT

The production of orito banana (*Musa acuminata* AA) is a very significant activity that is part of the country's economy, being used as a fruit or as an input in food processing. In this sense, the automation of the fruit classification process contributes to saving time and reducing errors in tasks that involve people. The present research aims to predict the maturity index of the orito banana *Musa acuminata* AA using artificial intelligence, thus reducing errors that can be caused by human vision to classify this fruit. To achieve the proposed objective, Artificial Intelligence (AI) algorithms were used, in particular Deep Learning such as: tensorflow, keras, Neural Networks, Backpropagation, numpy and the Matplotlib pyplot and Sciklearn libraries, which were fed with images and results of laboratory physicochemical analyses such as: titratable acidity, soluble solids, texture and pH. A color chart was created with three stages of ripening: immature (IM), mature (MA) and overripe (SM). After processing the information by the algorithms, a test accuracy of 0.94 was obtained; this result was confirmed in the confusion matrices of each algorithm analyzed according to the subject results. It can be deduced that AI algorithms can be used to predict the maturity index of orito banana with high precision.

Keywords: Orito banana, artificial intelligence, deep learning, ripening.

INTRODUCCIÓN

RESUMEN.....	III
ABSTRACT	IV
INTRODUCCIÓN.....	1
PLANTEAMIENTO DEL PROBLEMA	2
JUSTIFICACIÓN	4
OBJETIVOS.....	6
Objetivo general:.....	6
Objetivos específicos:	6
CAPITULO I: MARCO TEÓRICO.....	7
1.1. Origen del Banano Orito.....	7
1.2 Cultivo en Ecuador	7
1.2.1 Cultivo en la provincia de El Oro.	8
1.3 Taxonomía del banano orito (<i>Musa spp.</i>).....	8
1.4. Características del banano orito (<i>Musa acuminata</i> AA)	9
1.4.1 Caracterización fisicoquímica	9
1.4.2 Propiedades Nutricionales.	9
1.4.3 Cambios Bioquímicos de la fruta.....	10
1.5 Proceso de maduración	11
1.6 Inteligencia artificial en la agroindustria	11
1.7 Deep Learning (DL).....	12
1.7.1 Importancia en el campo laboral con Deep learning.	12
1.8 Redes neuronales Artificiales	13
1.8.1 Modelo matemático de la neurona.....	14
1.8.2 Redes Neuronales Convolucionales (CCN).....	15
1.9 Sistema de clasificación “DATASET”	15
1.10.1 Modelo 1 (TensorFlow, TF).....	16
1.10.2 Modelo 2 (Keras)	17
1.10.3 Modelo HSI (Tono, Saturación e Intensidad).....	17
1.10.4 Modelo 4 (Numpy).....	18
1.10.5 Algoritmo Backpropagation.....	18
1.10.6 Biblioteca Matplotlib pyplot	19
1.10.7 Biblioteca scikit-learn (sklearn).....	19
1.11.1 Test accuracy	20
1.11.2 Matriz de confusión	20
1.12 Métricas del procesamiento de un sistema de análisis de imágenes.....	21

CAPITULO II METODOLOGÍA	22
2.1 Propiedades Físicoquímicas e imágenes del banano orito	23
2.1.1 <i>Determinación de acidez del banano</i>	23
2.1.2 <i>Determinación de Sólidos Solubles (°Brix)</i>	23
2.1.3 <i>Determinación de potencial hidrógeno</i>	23
2.1.4 <i>Determinación de la Firmeza</i>	23
2.2. Determinación de índice de maduración	24
2.3 Carta de color	24
2.4 Toma de Imágenes	24
2.4.1 <i>Procesamiento de Imágenes</i>	24
2.5 Algoritmos de procesamiento de imágenes	25
2.5.1 <i>Variables de entrenamiento</i>	26
2.6 PREDICCIÓN DEL ÍNDICE DE MADUREZ	26
2.6.1 <i>Selección de los algoritmos:</i>	26
2.6.2 <i>Evaluación del Modelo.</i>	26
2.7 Hipótesis de investigación:	27
CAPITULO III: RESULTADOS Y DISCUSIÓN	28
3.1 Parámetros físicoquímicos medidos en banano orito	28
3.3 Algoritmos Deep Learning	33
3.4 Interpretación de los resultados del test accuracy por cada época	34
3.5 Interpretación de la arquitectura de la red neuronal para Deep Learning	35
3.6 Interpretación de las neuronales convolucionales en el <i>test accuracy</i>	35
3.7 Interpretación de la Matriz de confusión de los algoritmos utilizados de DL	36
3.8 Prueba de hipótesis	37
CAPITULO IV: CONCLUSIÓN	38
CAPITULO V: RECOMENDACIONES	39
BIBLIOGRAFÍA	40
ANEXOS	50

INDICE DE TABLAS

TABLA 1 TAXONOMÍA DEL BANANO ORITO	8
TABLA 2 INFORMACIÓN NUTRICIONAL DEL ORITO, EN UNA PORCIÓN DE 85 G	9
TABLA 3 CATEGORÍAS DE LOS ALGORITMOS DE DEEP LEARNING	13
TABLA 4 MATRIZ DE CONFUSIÓN.....	21
TABLA 5 PROCESAMIENTO DE IMÁGENES A LA RED NEURONAL	21
TABLA 6 CONDICIONES AGROCLIMÁTICAS DE LA ZONA DONDE SE RECOPIARON LA MATERIA PRIMA	22
TABLA 7 PARÁMETROS ENVIADOS AL ALGORITMO PARA SU EJECUCIÓN.....	26
TABLA 8 RESULTADO DE ANÁLISIS FÍSICO-QUÍMICO EN SU FASE DE ENTRENAMIENTO DEL BANANO ORITO	28
TABLA 9 RESULTADO DE ANÁLISIS FÍSICOQUÍMICO (TEST) DEL BANANO ORITO POST COSECHA	29
TABLA 10 VARIABLES DE ENTRADA, SALIDA Y DE RESPUESTA CON RESPECTO A LAS CARACTERÍSTICAS FÍSICO- QUÍMICA DEL BANANO ORITO REFERENTE A LOS DATOS DE ENTRENAMIENTO Y DE PRUEBA.....	33
TABLA 11 ÍNDICES DE MADUREZ DEL BANANO ORITO EN ENTRENAMIENTO Y TEST	37
TABLA 12 PRUEBA DE MUESTRAS INDEPENDIENTES DE LA HIPÓTESIS	37

INDICE DE FIGURAS

FIGURA 1 MANO DE BANANO ORITO (MUSA ACUMINATA AA).....	7
FIGURA 2 PORCENTAJE DE CULTIVO DE BANANO ORITO EN ECUADOR.	8
FIGURA 3 ACCIÓN DE LA PFO HACIA LOS COMPUESTOS FENÓLICOS DEL BANANO	10
FIGURA 4 RED OUTSAR FUNCIÓN DE ACTIVACIÓN DE LA CCN	14
FIGURA 5 ESTRUCTURA TÍPICA DE UNA RED NEURONAL CONVOLUCIONAL CNN	15
FIGURA 6 ESQUEMA DEL PROCESAMIENTO DEL MODELO DE PREDICCIÓN.....	16
FIGURA 7 REPRESENTACIÓN DEL MODELO HSI PLANO CÓNICO EN ESPACIO DE COLOR	18
FIGURA 8 CONVOLUCIONAL NEURAL NETWORKS PROCESS	20
FIGURA 9 ESQUEMAS DEL SISTEMA DE VISIÓN ARTIFICIAL	25
FIGURA 10 CARTA DE COLORES DEL BANANO ORITO MOSTRANDO LAS ETAPAS DE MADUREZ DESDE EL ESTADO VERDE HASTA EL ESTADO DE ACENTUACIÓN DE DEGRADACIÓN.....	31
FIGURA 11 PROCESAMIENTO DE CADA ÉPOCA UTILIZANDO LA VARIABLE DE LOSS Y TEST ACCURACY.....	34
FIGURA 12 ARQUITECTURA DE LA RED NEURONAL PARA DEEP LEARNING	35
FIGURA 13 GRÁFICA LAS REDES NEURONALES CONVOLUCIONALES DEL TEST ACCURACY.....	35
FIGURA 14 GRAFICA DE MATRIZ DE CONFUSIÓN	36

INDICE DE ANEXOS

ANEXO 1 RACIMO DE BANANO ORITO PARA EVALUAR LA MADURACIÓN VISUALMENTE	50
ANEXO 2 PROCESO DE PREPARACIÓN DE MUESTRAS DEL BANANO ORITO PARA ANÁLISIS DE PROPIEDADES FÍSICOQUÍMICAS EN LABORATORIO	50
ANEXO 3 EQUIPOS UTILIZADOS PARA LA EVALUACIÓN DE PARÁMETROS FÍSICOQUÍMICAS EN EL BANANO ORITO	51
ANEXO 4 MEDICIÓN DE LA FIRMEZA DEL BANANO ORITO MEDIANTE PENETRÓMETRO EN ANÁLISIS DE TEXTURA	51
ANEXO 5 EQUIPO FOTOGRÁFICO UTILIZADO PARA LA DOCUMENTACIÓN DIARIA DE PROCEDIMIENTOS EXPERIMENTALES	52
ANEXO 6 PROCEDIMIENTO DE PREPARACIÓN Y PESAJE DE MUESTRA PARA DETERMINACIÓN DE ACIDEZ TITULABLE	52
ANEXO 7 DETERMINACIÓN DE ACIDEZ TITULABLE	53

INTRODUCCIÓN

El factor de la calidad en frutas es crucial al formar parte de la cadena comercial manufacturera, debido a que los consumidores que prefieren un producto con una presentación visual impecable y con una calidad sensorial comestible de primera, permitiendo ventajas que incluyen bonificaciones en los precios, fidelización de los clientes y referencias favorables, lo que genera un alto incremento en la demanda en por cada mercado destino que llega la fruta (Smith & White,2020). Actualmente, la selección de frutas, y en particular de los bananos, se ampara en el factor humano en la inspección visual de las musáceas, factor que puede provocar errores ya sea por aspectos externos, variaciones en la percepción visual, algún sesgo o parcialidad dentro de los procesos, inclusive si hubiere profesionales involucrados en la selección de las frutas, por lo tanto, estas operaciones para determinar calidad o medir parámetros fisicoquímicos en la frutas, requieren de cierto tiempo y, por lo general, son métodos destructivos (Behera *et al.*, 2021). Los procesos innovadores de selección de frutas, utilizando la inteligencia artificial, por medio de la visión por computadora pueden superar estos problemas porque la clasificación de la madurez de la fruta se puede realizar de forma automática (Mise, 2019), por lo tanto, es relativamente rápido y económico, ya que han dado resultados muy alentadores; algunos procesos que conlleva información fisicoquímica que son inducidos por los cambios bioquímicos ocurridos a lo algo de la maduración (*Machine learning*), otros procesos que utilizan imágenes que capturan los cambios evidentes en la corteza de las frutas (*Deep Learning*). En lo concerniente a la predicción de maduración, por medio de imágenes, la clasificación se realiza mediante métodos de aprendizaje profundo, ya que pueden procesar y aprender automáticamente por modelos preestablecidos (Cho & Koseki, 2021). Los algoritmos de predicción que usan imágenes en su procesamiento, al reconocer patrones generados en cada cambio de maduración del banano como la pérdida de clorofila en la cascara, identifican su tiempo organoléptico (Sri et al., 2020). Estos algoritmos (*Deep learning*) nos permiten incluir datos multivariados por medio de redes convolucionales como imágenes de alta calidad, características fisicoquímicas, por este medio obtenemos información más completa sobre la condición favorables de la fruta, que no son visibles externamente. Los estudios sugirieren que la IA puede aportar en grandes campos, desde patrones, sensores espectrales y otros campos como la agronomía, informática y agroalimentario, En efeto, se aplican a problemas de clasificación y reconocimiento de imágenes en diversos dominios, incluida de predicción del índice de madurez de frutas (Saragih & Rahardjo, 2021).

PLANTEAMIENTO DEL PROBLEMA

La calidad de las musáceas es importante, debido a que la evaluación permitirá determinar el destino del banano, sea como fruta o para su industrialización. La evaluación de frutas se convierte en una tarea sobrecargada y proclive a errores en márgenes elevados, y de esto, se verifica por controles proporcionados por normas de calidad exigidas por organizaciones nacionales y extranjeras. Las principales causas que se producen descarte en la fruta cosechada son la manipulación excedente durante la cosecha y postcosecha, frutos con presencia de mancha oscuras en la piel y dedos laterales abiertos de la mano. Las empresas dedicadas a la fabricación agroalimentaria y comercialización de frutas, en su mayoría, se basan en las capacidades sensoriales del personal dedicado a la inspección, esta técnica afronta problemas de no uniformidad, asociada al factor humano (García, et.al., 2015).

La calidad fisicoquímica de los frutos puede analizarse mediante distintos métodos, ya sean tradicionales o no. En los estudios sobre la maduración de frutos, es común emplear indicadores como la acidez titulable, los sólidos solubles y el pH. Es esencial realizar estas mediciones en el momento adecuado para determinar con precisión el estado de madurez de la fruta (Zumbado, 2020). Ecuador dispone de condiciones climáticas factibles y de suelo, permite el cultivo de banano Orito o también llamado banano baby (*Musa acuminata* AA), su cultivo se encuentra distribuido entre las provincias de El Oro, Azuay, Guayas, Los Ríos, Chimborazo, y Cotopaxi (Pallo et al., 2024). El desconocimiento sobre el proceso de sistemático computacional visión artificial utilizando algoritmos para la predicción de frutas y de los compuestos orgánicos en la maduración de estas frutas como, por ejemplo, los cambios que sufren los hidratos de carbono, el contenido de almidón y modificación de textura, merman el aprovechamiento oportuno de estos alimentos, sea como fruta o destinados a su industrialización ocasionando extensas horas de trabajo y dicotomías de decisión entre personal operativo. Por otro lado, Una cercanía al tema se puede apreciar en el artículo titulado “*Clasificación de la madurez del plátano basada en aprendizaje profundo mediante redes neuronales convolucionales*” (Saragih & Rahardjo, 2021) del cual los autores propusieron identificar el índice de madurez del banano Cavendish por medio de *Deep Learning* aplicando otro sistema de Redes neuronales convolucionales. La IA pretende entender la capacidad neuronal humana, a través de modeladores matemáticos computacionales y las redes neuronales convolucionales, para luego, aplicarla en beneficio de la humanidad. El desarrollo de la visión artificial cumple alternativas para contrarrestar los procesos manuales y evitar errores involuntarios que provocan pérdidas económicas, el

mecanismo de la IA utiliza un análisis profundo (*Deep Learning*) mediante el procesamiento de imágenes digitales por medio redes neuronales (RNA) es la implementación de algoritmos que cumplen la función de detectar y validar el estado de la fruta para que los jornaleros trabajen con tecnología informática para aumentar la producción de frutas de forma eficiente, por lo que, la presente investigación se convierte en una técnica innovadora y pionera que, sin lugar a dudas, va a contribuir a la optimización de los recursos agrícolas, disminuyendo las pérdidas postcosechas y generando un favorable impacto social y económico en la región

JUSTIFICACIÓN

En Ecuador por su localización geográfica y clima tropical posee una enorme ventaja en la producción de frutas tropicales, brindando muchas especies, debido a sus condiciones climáticas estables durante el año. Como menciona el autor Nieto (2018), el estado de maduración es un componente definitivo para obtener frutas de mayor calidad y cubrir las necesidades, no solo dentro del mercado local sino también a nivel internacional. El cultivo del banano Orito, familia de la *Musa acuminata* AA se produce en importantes volúmenes en la provincia de El Oro a diferentes terrazas climáticas que van desde los 100 hasta los 1000 msnm. La cosecha de banano orito en el país del 2018 represento de 18 345 toneladas métricas (Instituto Nacional de Estadísticas y Censos, 2018). Uno de los problemas más importantes que tiene la cosecha de las *musáceas* es el tiempo oportuno de corte, es decir, lograr que las condiciones fisicoquímicas como: acidez, sólidos solubles y textura, entre las principales; sean las más adecuadas. Actualmente, el criterio de selección y corte de las *musáceas* está amparado en la percepción sensorial de las personas, por lo tanto, está sujeto de variación. El análisis manual (tradicional) del experto es el único procedimiento que ofrece una perspectiva de lo que corresponde al estado de maduración de la fruta, como el color, forma, tamaño, textura y/o presencia de daños relacionados con la vida del anaquel del fruto. Además, se ve afectado por la reacción de oxidación del pardeamiento enzimático, por la interacción de la enzima *polifenoloxidasas* ocasionada por oscurecimiento de la fruta y otros cambios desperfectos como la pérdida de firmeza, modificaciones en el olor, efectos contradictorios en la calidad, limitación de la vida útil y bajos costos comerciales del orito, y en los componentes nutricionales (Castillo&Merino, 2020). El crecimiento de la tecnología, en los últimos años, ha dado un notable cambio a nuevos medios. Una de las revoluciones de las ciencias tecnología informática, está relacionado con la Inteligencia Artificial (IA), nombrada “Aprendizaje automático o Aprendizaje de Profundo” (*Deep Learning* - DL). Según Forero&Negre (2024), La inteligencia artificial ha tenido unos incrementos exponenciales en los últimos años. Enfatizando en estudios más profundos y de mayor impacto. Según lo que mencionaron los autores Villalba et al., del año 2021, desarrollaron un prototipo de un sistema que determina el estado de madurez, en su caso particular, del plátano. Para ello, se usó *Deep Learning* y Visión Artificial, este prototipo permite optimizar la productividad en procesos en industrias alimentarias, para contrarrestar la pérdida de material por procesos inapropiados. Esta implementación se llevó el proceso con la ayuda del lenguaje de programación *Python*, utilizando algoritmos de predicción *TensorFlow*, *Keras*, *Numpy*, *HSI*, *Backpropagation*

obteniendo esta fuente en la biblioteca de *Matplotlib pyplot* y de *scikit-learn (sklearn)*, para *Deep Learning* y Redes Neuronales de alto nivel. En ese mismo orden, el autor Bueno (2023), mencionó que, el aprendizaje por redes neuronales convolucionales forma las principales ramas de la inteligencia artificial y demostró ser muy eficaz en diversos campos de las ciencias relacionadas con alimentos, basándose en datos de entrenamiento y validación, variables que fueron ingresadas en los algoritmos de selección del *Machine Learning*. En el año 2021, Zhu *et al.*, procesó imágenes, dándoles distintas categorías en función de las características de selección deseadas, obteniéndose *test accuracy* muy alentadores. Dado los antecedentes mencionados, la problemática a resolver en la presente investigación es el desconocimiento del uso de la inteligencia artificial para la predicción del índice de madurez del banano orito (*Musa acuminata* AA).

OBJETIVOS

Objetivo general:

Predecir el índice de madurez del banano orito (*musa acuminata AA*) mediante la aplicación de la inteligencia artificial, para el establecimiento de las condiciones de aprovechamiento más oportuno, sea como fruta o materia prima en alimentos procesados.

Objetivos específicos:

- Establecer una base de datos, a través de la medición de las características fisicoquímicas y captura de imágenes del banano orito, desde su estado inmaduro hasta su sobre maduración, mediante análisis de laboratorio y tomas fotográficas.
- Aplicar modelos de predicción basados en *Deep Learning* y seleccionar el mejor algoritmo según los resultados de su precisión en pruebas (*test accuracy*) y la matriz de confusión.
- Diseñar una carta de colores con imágenes del banano orito, abarcando desde su estado inmaduro hasta el sobremaduro, teniendo en cuenta la degradación del color verde hasta alcanzar el característico color amarillo de su cáscara.

CAPITULO I: MARCO TEÓRICO

1.1. Origen del Banano Orito

El banano es una planta monocotiledónea pertenecientes a la familia de las *Musáceas* su origen proviene de Asia sudeste y de la India, la introducción de los bananos, desarrollados a partir de *E. acuminata* y *E. balbisiana*, en América se atribuye a los europeos, quienes trajeron esta fruta a través de las Islas Canarias hasta La Española. La ausencia de semillas en el banano sugiere que su reproducción está vinculada a la presencia humana que tienen aproximadamente 2000 años de haber llegado a Ecuador y que, a partir del siglo XX, se cultivó y comercializó el banano de diferentes variedades: Cavendish, baby banana mejor conocido como “orito”, Paradisiaca y banano rojo (Gonzabay, 2017). En la figura 1, se observa una fotografía de una mano del banano orito en su estado inmaduro.

Figura 1 Mano de Banano orito (*Musa acuminata* AA)



Fuente: (Gonzabay, 2017)

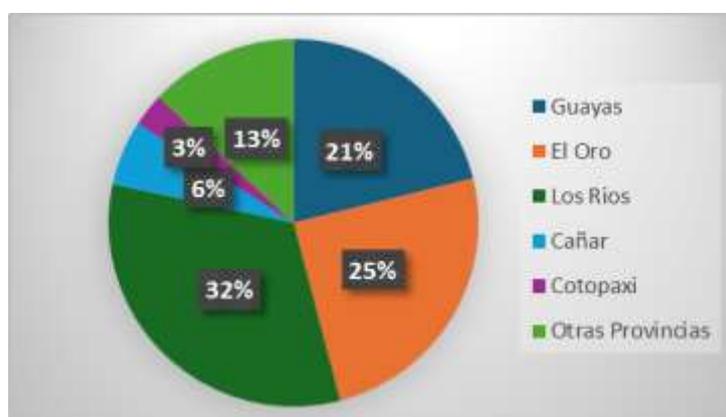
1.2 Cultivo en Ecuador

En Ecuador, se cultivan entre 8,000 y 9,554 hectáreas de banano orito (*Musa acuminata* AA), con un volumen anual de 49 369 toneladas. Todo lo que se produce en los cultivos nacionales para los envíos a destinos internacionales como Estados Unidos, Japón y Unión Europea, como menciona la Corporación Financiera Nacional (CFN,2017). El país exportó 6 millones de toneladas hasta el año 2016 debido a que es agradable por su concentración de azúcares y su tamaño en varios países (Ayala,2016). Se han encontrado alrededor de 21 cultivares de *musáceas*, de estos se encuentran: Dominico Hartón (AAB), Dominico (AAB), Dominico Gigante (AAB), Dominico negro (AAB), Gros Michel (AAA), Guineo de jardín (AAA), Filipino (AAA), Orito (AA), Maqueño morado (AAA), Maqueño verde (AAB), Limeño (AAB), Barraganete (AAB); estos tipos de variedades de banano por sus condiciones de cultivo

en los suelos fértiles de la regiones del país y áreas climáticas, han sido favorables a unas temperaturas de 23°C y 25°C y dependiendo a su humedad oscila 70-85% crecen desde los 5 hasta 200 msnm. Se conocen que los cultivos están en las provincias de El Oro, Los Rios, Guayas, Portoviejo, Pastaza, cañar, entre otros (Guerrero, 2016).

1.2.1 Cultivo en la provincia de El Oro. El cultivo de banano orito en la Provincia de El Oro ha experimentado una expansión significativa, resultando en que más del 45 % de las fincas bananeras de Ecuador se encuentren en esta región (León et al, 2023), El Oro se posiciona como la segunda provincia en términos de producción de banano, representando el 24,8 %, mientras que Los Ríos ocupa el primer lugar con un 32,4 % (Instituto Nacional de Estadísticas y Censos, 2019). En la figura 2, se evidencia la clasificación de los porcentajes de cultivos de banano orito en Ecuador.

Figura 2 Porcentaje de cultivo de banano orito en Ecuador.



Fuente: Zhiminaicela et al., (2020)

1.3 Taxonomía del banano orito (*Musa* spp.)

La clasificación de la taxonomía del banano orito se presenta a continuación en la Tabla 1.

Tabla 1 Taxonomía del banano orito

Clasificación taxonómica	
Reino	<i>Plantae</i>
División	<i>Magnoliophyta</i>
Clase	<i>Liliopsida</i>
Orden	<i>Zingiberales</i>
Familia	<i>Musáceas</i>
Género	<i>Musa</i>
Especie	<i>Acuminata</i> AA

Fuente: Salau (2015).

1.4. Características del banano orito (*Musa acuminata* AA)

1.4.1 *Caracterización fisicoquímica.* El banano orito, es una variedad pequeña del banano *cavendish*, aproximado unos 12 cm y un calibre min. 26 -.34 mm, con un sabor muy dulce y cremoso. Denomina en inglés "*finger banana*" o "*lady finger*". El pseudotallo de la planta de color amarillo verdoso con manchas castañas-oscuras, y su altura de 2,5m. a 4 metros. Sus hojas son angostas y erguidas, el racimo es firme con forma esférica, conforma 4 a 9 manos entre 90 a 220 dedos y su peso contiguo de 26 y 41 libras (Guerrero, 2020). En la reproducción de esta planta se realiza usando los hijuelos del tallo madre, una vez plantada, después de los 9 meses comienza a florecer y unos 42 días después de este brote madura el fruto, podría variar según el lugar como es las condiciones: de siembra, humedad, altura, propiedades del suelo y la iluminación. Esta variedad tiene resistente al hongo *Mycosphaerella fijiensis* (Paéz, 2012).

1.4.2 *Propiedades Nutricionales.* Cuando el banano orito aporta 90 calorías por 100 g del alimento, dispone de: azúcares, potasio, vitamina C, calcio, magnesio, fósforo, contiene vitaminas B6, fibra soluble, almidón resistente (80%), almidón no digerible 24.82% (actúa como prebiótico) y azúcares (3.5%). (Caisedo et al, 2019), vitamina A y E que actúa como antioxidante como barrera de protección de radicales libres. (Procel, 2022). En la tabla 2 se describe la información nutricional del banano orito (85 g) en base a una dieta 2000 calorías.

Tabla 2 Información Nutricional del orito, en una porción de 85 g

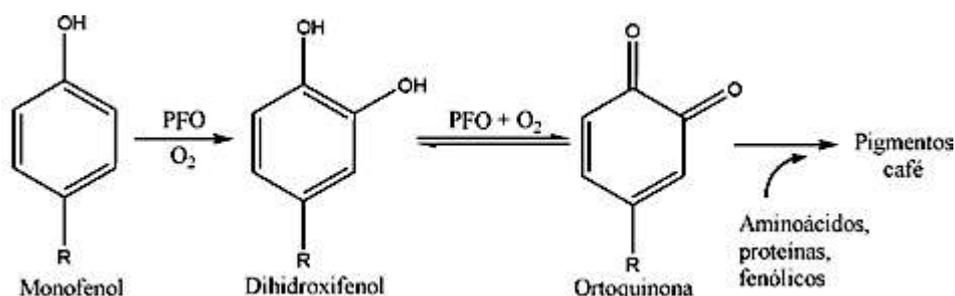
Componentes	Valor Diario
Total de grasa:	0 g
Grasa Saturada:	0 g
Colesterol:	0 mg
Sodio:	0 mg
Hidratos de carbono	20 g
Fibra dietética:	1 g
Azúcar:	13 g
Proteínas:	1 g
Vitamina C	15 UI
Vitamina A	0
Calcio	0
Hierro	0

Nota: En base a una dieta de 2000 calorías

Fuente: (Salau, 2015)

1.4.3 Cambios Bioquímicos de la fruta Los cambios bioquímicos que ocurren en el banano orito vienen a ser la hidrolización de almidón presente en estado verde a azúcares simples (glucosa, sacarosa y fructosa), la frecuencia de respiración progresiva del etileno, degradación de la clorofila y de sustancias pépticas, transformación de los ácidos orgánicos, conmutaciones en enzimas, vitaminas y minerales (Robinson y Saúco, 2012). El pardeamiento enzimático afecta la calidad del producto final, la enzima precursora de la reacción pardeamiento o de oscurecimiento viene a ser la *polifenoloxidasas* (PPO) denominadas como *óxido reductasas* (Peñañiel, 2017). La actividad enzimática de la PPO es una proteína que actúa directamente en los compuestos fenólicos y alteran las capas subcelulares inducidas por la oxidación y polimerización. Los tejidos de la fruta permanecen aislados por membranas celulares, al modificarse por manipulación, se dañan o rompen y así entran en contacto con el exterior, ya que facilitan la interacción de la enzima con el sustrato por el paso de oxígeno. (Crespo y Guanochanga, 2022). Los sustratos de la PPO incluyen *monofenoles*, *polifenoles* y *ortodifenoles*, que se oxidan para formar *melaninas* dispone de hierro. Este proceso implica la conversión de *ortodifenoles* a *orto-quinonas* mediante la interacción *catecolasa*, lo que conlleva una oxidación. Las membranas que presenta el banano se denomina cloroplastos, que contiene la clorofila, está compuesto por *tilacoides*, la membrana interna del cloroplasto, donde ocurren las reacciones de captación de luz de la fotosíntesis, estos se conectan para formar los sacos membranosos llamados “*grana*”, que están presentes en el estroma celular. La clorofilasa participa en la degradación de la clorofila, y su actividad afecta a ciertos factores que alteran su estructura, como la concentración de sustrato, como el pH, la temperatura y el estado de madurez (Castro & Restrepo, 2005). En la figura 3 se observa la acción de la PFO hacia los compuestos fenólicos coaccionando una oxidación y polimerización efectuando un color café en la cascara.

Figura 3 Acción de la PFO hacia los compuestos fenólicos del banano



Fuente: (García et al., 2006)

1.5 Proceso de maduración

Los bananos oritos son frutas climatéricas, y su proceso respiratorio llega a alcanzar máximo los 10 días de vida de anaquel, siendo 180 mg CO₂ h⁻¹ kg⁻¹ a temperaturas de 18°C a 22°C (Castro & Narváez, 2005). El factor del clima como menciona Kongaphisith et al, (2020) el es una clave importante en el proceso de maduración por lo que puede influir en la disponibilidad de la biosíntesis de βcaroteno y la transformación de amiloplasto a cromoplasto, respectivamente, lo que afecta en si el contenido de βcaroteno en el banano. (Thompson & Johnson, 2019). Otro factor es la respiración y la aceleración del etileno; es una fitohormona gaseosa que influye en la textura, consistencia, color y sabor de la fruta, activándose bajo condiciones de estrés. La señalización del etileno comienza cuando se conecta a los receptores proteicos en la membrana del retículo endoplasmático que sintetiza a partir del aminoácido llamado “**metionina**”, mediante las enzimas (metionina) SAM sintetasa y ACC sintasa, y la enzima ACC oxidasa (ACO) lo convierte en etileno. después de alcanzar la madurez fisiológica la SAM en ácido 1-aminociclopropano 1-carboxílico (ACC). Los receptores de etileno los receptores (ETR, ERS, EIN4), ausencia de ello la triple constitutiva (CTR1) se activa de este modo suprime la respuesta al etileno (Sugianti et al., 2022). En las musáceas, la clorofila se degrada progresivamente y da paso de color verde a amarillo. En la respiración, la humedad presente de la fruta migra hacia la corteza por la transferencia osmótica del que se relaciona con peso de la pulpa. Por otro lado, la presión de la pulpa se eleva a cerca de 6,5 atmósferas durante el climaterio y luego aumenta de manera abrupta, alcanzando entre 25 y 27 atmósferas en el fruto totalmente maduro (Hernández, 1986)

1.6 Inteligencia artificial en la agroindustria

La IA y *Deep learning* llamado aprendizaje automático, son técnicas innovadoras disruptivas que disponen cambiar la sociedad. Esos cambios se reflejarán en el campo laboral y en el ámbito industrial, alimentario, agronómico, entre otros (Deepa et al., 2022). Durante años, la agroindustria ha adoptado nuevas tecnologías para el análisis de alimentos. La inteligencia artificial y las redes neuronales artificiales (RNA) permiten un control preciso y detallado de las condiciones nutricionales y funcionales de los alimentos, de este modo facilita la oferta de productos estables y aceptables para los consumidores. Además, estas tecnologías simplifican

procesos de análisis que, con la instrumentación de laboratorio convencional, serían mucho más laboriosos y consumirían más tiempo (Islam et al., 2017).

1.7 Deep Learning (DL)

El aprendizaje profundo (Deep Learning o DL) representa una rama revolucionaria de la inteligencia artificial (IA) que utiliza redes neuronales avanzadas para el aprendizaje autónomo no supervisado. Esta metodología se aplica en la resolución de desafíos complejos que implican el procesamiento de vastos conjuntos de datos e información (Rouhiainen, 2018). Las redes neuronales convolucionales (CNN) destacan por su capacidad para identificar patrones jerárquicos mediante estructuras neuronales, facilitando el descubrimiento de interrelaciones y patrones intrincados en los datos. (Trung et al., 2020). Una red neuronal tiene la capacidad de autoajustarse basándose en ejemplos o bases de datos predefinidas (Islam et al., 2017). Por ejemplo, si se busca entrenar una red para distinguir el grado de madurez de frutas, se le proporcionan muestras etiquetadas con diferentes niveles de maduración, como 1 o 5. Aguirre (2019) señala que los algoritmos de DL pueden realizar abstracciones sofisticadas de manera autónoma (Beunza et al., 2020).

1.7.1 Importancia en el campo laboral con Deep learning. Es relevante por su capacidad de realizar trabajos automáticamente. La visión por computadora se aplica en la detección y clasificación de imágenes, lo que resulta útil en tareas de vigilancia e inspección que se realizan los técnicos u operadores ya sea de producción, recepción de materia prima, entre otras aplicaciones. Interpretación del lenguaje en la CCN se emplea para la creación de asistentes virtuales, traducción automática, clasificación de imágenes y generación de textos. (Artificial Vision, 2012) Esta automatización ofrece una excelente opción para modelos predictivos, aprovechando la potencia de los lectores de gráficos de GPUs (unidad de procesamiento de gráficos) y algoritmos basados en modelos existentes (Porras & Morán, 2014).

Es relevante por su capacidad de realizar trabajos automáticamente. La visión por computadora se aplica en la detección y clasificación de imágenes, lo que resulta útil en tareas de vigilancia e inspección que se realizan los técnicos u operadores ya sea de producción, recepción de materia prima, entre otras aplicaciones (Harmandeep et al., 2023). Interpretación del lenguaje en la CCN se emplea para la creación de asistentes virtuales, traducción automática,

clasificación de imágenes y generación de textos. (Artificial Vision, 2012) Esta automatización ofrece una excelente opción para modelos predictivos, aprovechando la potencia de los lectores de gráficos de GPUs (unidad de procesamiento de gráficos) y algoritmos basados en modelos existentes (Porras & Morán, 2014).

1.8 Redes neuronales Artificiales

RNA (Redes Neuronales Artificiales) es un algoritmo que simula el funcionamiento de las redes neuronales y sus interconexiones, permitiendo realizar tareas específicas utilizando la interacción entre neuronas como unidad de cálculo. Las redes neuronales artificiales se forman por una capa de ingreso, una o más capas ocultas y una capa de salida (Piñeros, 2022) Cada neurona recibe valores de entrada a través de las conexiones entre ellas, los cuales son las funciones de activación. La información que se transfiere a la siguiente capa para su procesamiento es lo que constituye la salida o respuesta de cada neurona (Calderón et al., 2021). En la tabla 3, se muestran las diferentes categorías en las que el Deep Learning se utiliza, de acuerdo con sus niveles de supervisión: sin supervisión, semi-supervisado y reforzamiento con respecto a los datos, la producción, el objetivo y la aplicación.

Tabla 3 Categorías de los algoritmos de Deep Learning

Categorías de algoritmos DL	Aporte	Producción	Objetivo	Aplicaciones
Supervisado	Datos- Etiquetados	Salida- Conocido	Se utiliza para la predicción	Clasificación de imágenes, detección de correo no deseado
Sin supervisión	Datos: sin etiquetar	Salida- Desconocido	Utilizado para el análisis	Minería de texto, reconocimiento facial
Semi-supervisado	Menos datos- Etiquetado	Menos salida- Desconocido	Combina supervisada + no supervisada	Análisis de voz, clasificación de contenido web
Reforzamiento	Aprendizaje basado en la recompensa	Acción	Decisión tomada sobre experiencia	Juegos, navegación robótica

Fuente: (Deepa et al., 2022)

1.8.1 *Modelo matemático de la neurona* Una red neuronal artificial está formada por tres componentes básicos: pesos, umbral y una función de activación

- **Pesos (w).** - Los valores de w_1, w_2, \dots, w_n , son cada peso que identifican la fuerza del vector de entrada $X = [x_1, x_2, \dots, x_n](T)$. Cada entrada se multiplica por su respectivo peso.
- **Umbral (Φ).**- central e interno Φ actúa como una magnitud de compensación que influye directamente en la activación de los nodos de salida “Y”.
- **Función de activación.** La función de activación “f” realiza una operación matemática en salida señalizada. Esta función comúnmente viene forma: lineal, forma de escalón, forma sigmoidea (S) y en tangente hiperbólica

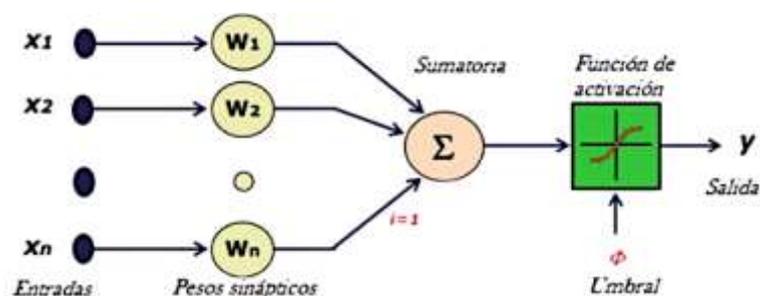
La función matemática de la salida de la neurona está representada por:

$$y = f(w_i x_i + \phi) \quad (\text{Ec.1})$$

Fuente: (Barrio, 2022)

En la figura 4, se identifica la *Red Outsar* o también llamado modelo de *Perceptrón* con variables ajustables que, es una técnica de visión artificial, tiene la particularidad de recordar vectores entre -1 y 1. Además, posee entradas por escala y vectorial de salida. (de Souza et al, 2014). La figura 4 representa el modelo neuronal que se comunica con las variables de entrada, el peso sináptico, la parte sumatoria y posteriormente el ingreso a la función de activación.

Figura 4 Red Outsar función de activación de la CCN



Fuente: (Constante y Gordón, 2015)

La estructura más usada es la red llamada **perceptrón multicapa** con alimentación de las capas delanteras (MLP), que consiste en una capa de entrada, una o varias capas ocultas con funciones de activación y una capa de salida (Souza et al., 2014). Para completar el modelo de la red de la neuronal artificial, se estima un parámetro que se ajustará a los datos para disminuir los datos

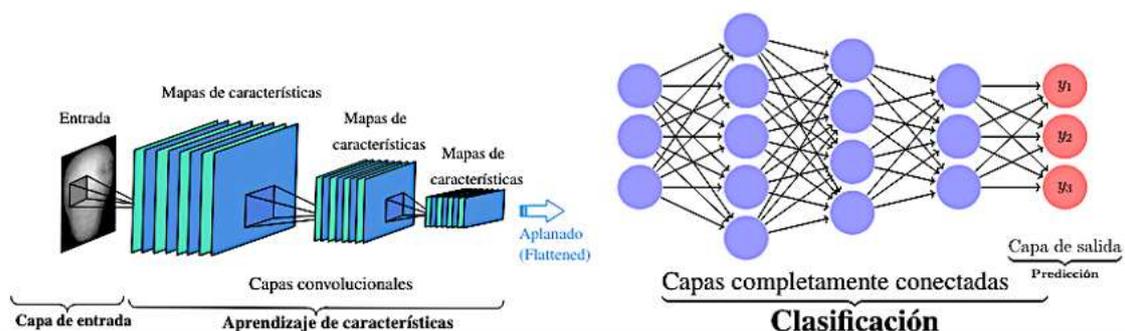
excedidos, se conoce función de costes calculado mediante métodos numéricos convencionales, se calcula el error cuadrático medio siglas de las salidas estimadas por la red a la salida teórica (Llamas et al.,2017).

$$C = \frac{1}{2N} \sum_{i=1}^N \sum_{j=1}^S (y_{ij} - \hat{y}_{ij})^2 \quad (\text{Ec.2})$$

Donde N corresponde el número de ejemplares en el *dataset* en el entrenamiento y el factor S es la variable de salida (Barrio, 2022).

1.8.2 Redes Neuronales Convolucionales (CCN). Esta arquitectura se enfoca en el procesamiento de datos estructurados, como son imágenes, mediante una retícula especializada. Se emplean capas convolucionales que filtran para recopilar ciertos patrones locales, seguidas por capas agrupadas que disminuyen la dimensionalidad. (de Souza et al., 2014). Las capas de conexión total las procesan para clasificar o la tarea deseada. Adicional utilizan el comando por codificación HSI-ConvNet y la arquitectura artificial de ResNet101 (Kusuma & Kumar, 2020). La convolución es un proceso donde se aplican filtros a la entrada y luego se aplica una función de activación, posteriormente agrupan estas operaciones para reducir la dimensionalidad (Trung et al., 2020). Este método ha logrado avances significativos en tareas como clasificación de imágenes y detección de objetos (Jiménez, 2023). En la figura 5 se observa el diagrama de bloques distribuidos por la CNN diseñado por mapas características como las capas de entrada, ocultas y de salida (Sugianti et al., 2023).

Figura 5 Estructura típica de una red neuronal convolucional CNN



Fuente: (Mohamed, 2020)

1.9 Sistema de clasificación “DATASET”

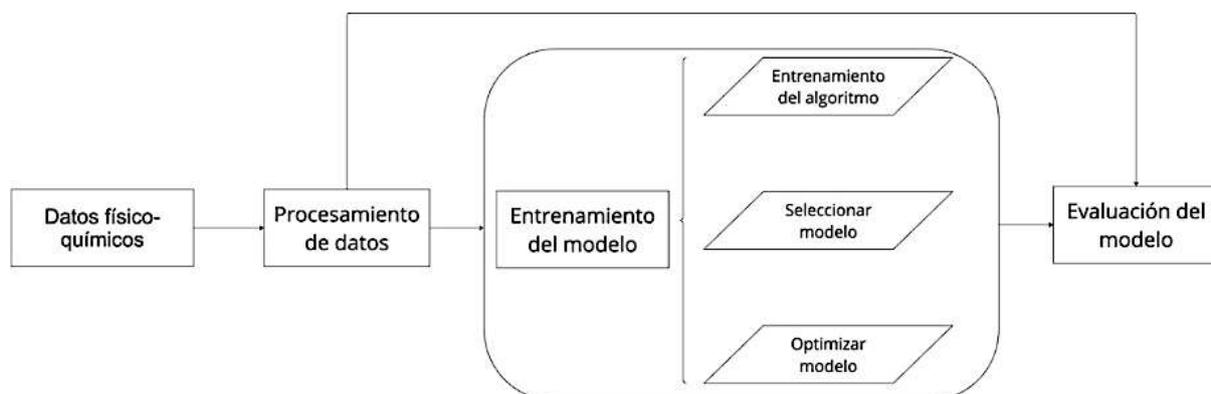
Se diseña una base de datos que contiene patrones específicos, comandos e imágenes de resolución máxima con baja compresión JPEG/HEIF (archivos grandes y alta resolución) El

dataset se clasifica en un 80 % para entrenamiento y otro conjunto del 20 % para pruebas, distribuidos de manera por categorías de los distintos estados de maduración (Rahim et al., 2023). Las imágenes se clasificarán en inmaduro, maduro y sobremaduro del cual se almacena en una base en la nube de Google y uso compartido de archivos (Jiménez, 2023).

1.10 Técnicas de los algoritmos de predicción

La iniciativa de I+D busca desarrollar un sistema de predicción propio utilizando técnicas de IA, basadas en análisis de fuentes de datos como predicciones utilizando equipos cámaras fotográficas, espectrales y entre otras. (Varga, 2021). La técnica de *DL* se une con con el código abierto *PyTorch* (lenguaje de programación *Python*) utilizan las herramientas y funcionalidades para el entrenamiento de datos, construcción de modelos y la optimización de algoritmos de aprendizaje (Refaeilzadeh et al., 2009). A continuación, se presentará en la figura 6, el esquema de procesamiento del modelo de predicción de *Deep Learning*:

Figura 6 Esquema del procesamiento del modelo de predicción.



1.10.1 Modelo 1 (TensorFlow, TF) TensorFlow es un algoritmo de código abierto que proviene de la librería de python diseñada para facilitar y mejorar la complejidad de ingeniar del cual permite el entrenamiento de modelos de aprendizaje profundo (DL) y manejar modelos de inteligencia artificial (IA). Desarrollada por el equipo de Google Brain, utiliza gráficos de flujo de datos para cálculos numéricos y es aplicable en diversos dominios. (Falconí, 2021). TensorFlow incluye herramientas integradas como TensorBoard, que genera gráficos sobre la velocidad de aprendizaje, el peso del modelo, y las funciones de pérdida, entre otros. Permite crear y entrenar modelos de aprendizaje automático mediante APIs intuitiva (Burns & Whyne, 2018). TF son representados por diagramas de proceso de cálculos, operaciones de fase

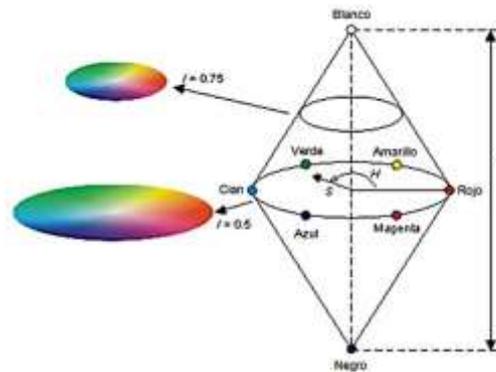
identificación de las imageNet, está es compatible con GPU y ASIC “tensores” para operaciones de alto rendimiento (Vivanco, 2018). Además, TensorFlow puede utilizarse en servidores o en la web “Google Colaboratory” y usa el parámetro "epoch" para determinar el número de iteraciones de entrenamiento, mejorando la precisión del algoritmo con iteraciones (Castro et al., 2018).

1.10.2 Modelo 2 (Keras) El modelo Keras es un algoritmo diseñado para el aprendizaje profundo utilizando redes neuronales convolucionales (CNN), ofreciendo potentes capacidades de análisis con conjuntos de datos preestablecidos y patrones aleatorios a través de API (Interfaz de Programación de Aplicaciones) (Aguirre, 2019). Keras se divide en dos componentes principales: primero, los módulos de texto, que utilizan el algoritmo NLTK que se comunican con las interfaces de TensorFlow, realizando análisis por cada época del modelo. Segundo, los análisis de cada capa de tensores, que son entrenados por diferentes *backends* (Navarro, 2022). Durante el procesamiento de los algoritmos se usan los parámetros:

- **Layers:** Empleado para consolidar todas las listas de datos en un paquete único, lo que facilita su manejo durante el análisis.
- **Models:** Sirven para desglosar el modelo derivado del análisis previo y clasificar nuevos textos de entrada utilizando por el método “*model.predict()*”.
- **Preprocessing:** Presenta dos funciones clave: la primera, se encarga de tokenizan (transforman a unidades digitales) al conjunto de datos preestablecidos en los “*Layers*”, y la segunda envía la información al modelo predictivo a través de la función “*fit_on_texts()*”.

1.10.3 Modelo HSI (Tono, Saturación e Intensidad) El modelo HSI (Tono, Saturación e Intensidad) fue diseñado para cuantificar los valores de tonalidad (H), saturación (S) e intensidad (I) de un color, transformando el espacio RGB en un espacio perceptual. (Purwa et al., 2022). En el plano tridimensional, la intensidad del color se representa en el eje vertical, la saturación por la distancia a este eje, y el croma por el ángulo horizontal con el rojo como referencia. Factores como: la iluminación, el número de píxeles, variedad de tamaño y la distancia del objetivo influyen en las características de la imagen con una profundidad de 24 bits, permite representar 16,777,216 colores. La tonalidad, se representa como un ángulo entre 0 y 360 grados (Alvarado, 2017). En la figura 7 representa el espacio de color HSL

Figura 7 Representación del modelo HSI plano cónico en Espacio de color



Fuente: (Alvarado, 2017)

1.10.4 Modelo 4 (Numpy) Es un algoritmo de datos optimizados para almacenar y acceder a matrices multidimensionales (tensores) de manera eficiente. Además, gestiona metadatos que facilitan la interpretación, como el "tipo de datos", "el tamaño", la "forma" y los "pasos" del tensor. Utiliza herramientas de cálculo para procesar estructuras con gran cantidad de datos (Van der Walt et al., 2011). Este modelo incorpora un nuevo tipo de dato, el *array*, que es similar a una lista, pero es eficiente computacionalmente. Adicional, dispone de otras funciones que permiten manipular los elementos del *array* multicapa no secuencial, denominado vectorización (Falconí, 2021).

1.10.5 Algoritmo Backpropagation Este algoritmo es el método de entrenamiento más utilizado en redes de retroalimentación. Se trata de un método de aprendizaje guiado que se basa en el descenso de gradiente que implica el comienza con una entrada que se propaga a través de las múltiples capas de la red hasta llegar a una capa de salida. El aprendizaje es a través del entrenamiento sucesiva de conjuntos, es de selección perceptrón multicapa con un conjunto de datos llamado "época" o *epoch* (Barrio, 2022). Existe dos modos de entrenamiento:

- **Modo Secuencial:** Este método de entrenamiento, los pesos se actualizan después de la presentación de cada ejemplo, siguiendo un enfoque patrón por patrón (capas ocultas). Un conjunto de entrenamiento contiene N ejemplos, por lo que el modo secuencial de entrenamiento resulta en N actualizaciones de pesos por cada época.
- **Modo Batch:** En este método de entrenamiento, los pesos (capas) se actualizan una sola vez tras la presentación de todo el conjunto. Durante cada época, se calcula el error

cuadrático medio proporcionado por la red, que realiza una estimación precisa del vector gradiente hacia un mínimo local entre la capa final (García, 2015).

El algoritmo Backpropagation es importante para realizar cálculos de derivadas parciales a función de coste que está relacionado con los pesos y los sesgos neuronales para lograr el aprendizaje de la red, con respecto a la función de activación de la neurona se utiliza la ecuación (Llamas et al., 2017).

$$z = w^T x + b = \sum_{i=1}^N w_i \cdot x_i + b \quad (\text{Ec. 3})$$

De este modo la función de coste se reduce para calcular las derivadas parciales de los pesos y el sesgo respecto de la ecuación presentada (Barrio,2022).

1.10.6 Biblioteca Matplotlib pyplot Es una biblioteca de visualización de datos alto impacto y compatibles para la generación de gráficos a partir de imágenes de dos dimensiones, con los datos representados en categorías de listas o también llamado *arrays*. (Babitz, 2023). Proporciona unos comandos como: *API, pylab. Matplotlib* personalizable para crear gráficos. Requieren códigos para crear gráficos más básicos con pocas personalizaciones (Babitz, 2023). *Matplotlib* está diseñado para trabajar con matrices *NumPy*. Los títulos de gráficos y etiquetas de los ejes facilitan la comprensión de una visualización, permiten al espectador comprender rápidamente lo que está viendo con mayor claridad con más capas en el diagrama de dispersión (Lemenkova, 2020).

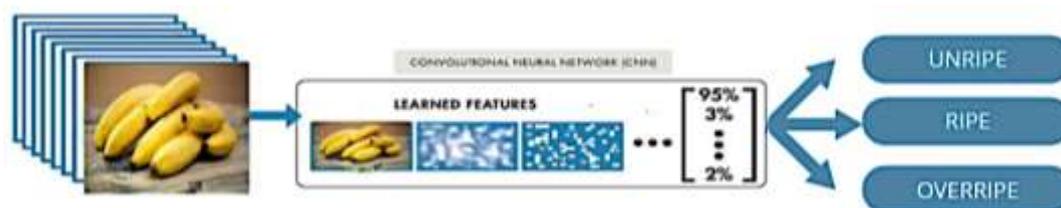
1.10.7 Biblioteca scikit-learn (sklearn) Proporciona una interfaz estándar de aprendizaje automático con datos hiperparámetros mediante validación cruzada. Dispone de funciones auxiliares como detectores de interfaces de búsqueda que sirven para ajustar u optimizar el rendimiento algorítmico. Los parámetros de segmentación (tamaño de ventana, superposición de segmentos) representa un gran impacto significativo en el rendimiento del aprendizaje de secuencias (T.Aditya et al., 2024). La biblioteca sigue una interfaz unificada para varios algoritmos de aprendizaje automático. Además, puede agilizar el procesamiento de creación, evaluación e implementación de modelos de aprendizaje automático que interpreta imágenes en 3D (Burns&Whyne, 2018).

1.11 Métricas para evaluación de los algoritmos

A continuación, se demostrará las diferentes formas para evaluar a los algoritmos:

1.11.1 Test accuracy La precisión del test, es una métrica que evalúa la efectividad de un modelo de aprendizaje automático al clasificar correctamente las muestras en un conjunto de datos de prueba. Se denomina, proporción de predicciones correctas en relación con el total de predicciones realizadas (Wong, 2023). Esta métrica es crucial para la evaluación del rendimiento de un modelo en tareas de clasificación, como la predicción automatizada y no destructiva del estado de madurez de las frutas, categorizando las muestras en sus respectivas etapas (verde, maduro, sobre maduro) según lo indicado por Constante y Gordón (2015). La exactitud se calcula dividiendo el número de predicciones correctas entre el número total de predicciones.

Figura 8 Convolutional Neural Networks Process



Fuente: (Kusuma & Kumar, 2020)

1.11.2 Matriz de confusión Esta matriz está diseñada para crear una tabla que muestra el número de predicciones realizadas en un conjunto de datos, permitiendo evaluar la calidad de la clasificación de los modelos. En este proceso, se emplearon los submódulos adyacentes en python "preprocessing" y "metrics", que resultaron esenciales durante el manejo de datos de entrenamiento y prueba. El módulo "preprocessing" facilitó la codificación de las etiquetas de clase, representadas en este caso por las líneas y sublíneas, mientras que el módulo "metrics" fue crucial para evaluar los datos de entrenamiento y prueba (Falconí, 2021). La Tabla 4 a

continuación presenta el número de predicciones del conjunto de datos, evaluando la calidad de clasificación de los modelos.

Tabla 4 *Matriz de confusión*

		Predicción	
		Positivo	Negativo
Actual	Positivo	Verdadero positivos (TP)	Falsos negativos (FN)
	Negativo	Falsos positivos (FP)	Verdaderos negativos (TN)

Fuente: (Contreras *et al.*, 2020)

1.12 Métricas del procesamiento de un sistema de análisis de imágenes

En un sistema de visión artificial, una imagen se procesa como una matriz de valores capturada y digitalizada por una cámara, que luego la envía a un software o procesador. Esta imagen digital se organiza como una matriz $M \times N$, donde cada celda corresponde a un píxel. Cada píxel tiene atributos como brillo, tono, color, luminosidad, croma y saturación, los cuales se cuantifican a través de operaciones específicas. Estos valores se almacenan y se procesan mediante algoritmos (Alegre *et al.*, 2016).

Tabla 5 *Procesamiento de imágenes a la red neuronal*

Procesos	Nivel de visión	Entrada	Salida	Área
1. Captura				
	Bajo	Imagen	Imagen	Procesamiento de imágenes
2. Preprocesamiento				
			Grupo de píxeles	
3. Segmentación	Medio	Imagen		
			Información cuantitativa de píxeles	Análisis de imágenes
4. Descripción		Objetos o regiones		
			Objetos clasificados	
5. Reconocimiento (clasificación)		Información cuantitativa		

6.Interpretación	Alto	Objetos clasificados en categorías	Comprensión de la escena	Visión por computador
-------------------------	------	------------------------------------	--------------------------	-----------------------

Fuente: (Pasato, 2022)

CAPITULO II METODOLOGÍA

La materia prima utilizada en presente investigación fueron bananos orito (*musa acuminata* AA) en estado verde, procedente del sector Las Palmas, parroquia del cantón Pasaje, provincia de El Oro- Ecuador. La metodología se clasifica en dos procesos: La primera parte consistió en la obtención de los análisis de laboratorio y la segunda parte, en el uso de algoritmos de clasificación de *Deep Learning* (visión artificial).

Tabla 6 Condiciones agroclimáticas de la zona donde se recopilaron la materia prima

Factores climáticos	Promedio
Altitud	150 msnm
Humedad Relativa %	64%
Temperatura medio anual (°C)	18°C y 28°C
Clima	Mayormente nublado

Fuentes: (INAMHI, 2022)

2.1 Propiedades Físicoquímicas e imágenes del banano orito

En la parte experimental de nuestro proyecto se capturó una imagen del banano orito cada 6 horas, por un lapso promedio de 8 días. Paralelamente, en cada día de análisis a las muestras se le realizaron análisis físicoquímicos de acidez, grado brix, pH y de firmeza. Los análisis instrumentales ingresaron a los algoritmos de predicción, de test y entrenamiento, para correlacionarlos y evaluar los resultados, clasificando el estado de madurez del banano orito, representadas por las etiquetas: IM (inmaduro), MA (maduro) y SM (sobre madurado).

2.1.1 Determinación de acidez del banano. Para la determinación de la acidez se siguió la metodología descrita en la AOAC 942.05, la muestra se tituló con una solución estandarizada de hidróxido de sodio 0,1 N con la presencia de un indicador (fenolftaleína).

$$\text{Acidez \%} = A * B * C * D / 100 \quad (\text{Ec.4})$$

A: Representa la cantidad en milímetros de hidróxido de sodio (NaOH) utilizados

B: Representa la normalidad de la base

C: Representa el peso equivalente, expresado en ácido málico

D: Es la cantidad de la pulpa, expresada en unidades gramos.

El ácido predominante llamado ácido málico se determinó como el % de acidez la fruta

2.1.2 Determinación de Sólidos Solubles (°Brix) Se determinó de acuerdo con la metodología descrita en la AOAC 932.12 utilizando un refractómetro de marca *WMETERS* y modelo REF107 a 27 °C.

2.1.3 Determinación de potencial hidrógeno El potencial hidrógeno se midió utilizando un potenciométrico de la marca ROHS, modelo YY-1030 según lo descrito en la norma AOAC 981.12/90.

2.1.4 Determinación de la Firmeza Se empleó un penetrómetro MARCA FRUIT HARNESS TESTER modelo GY-3, con rango de 1 - 24 kg/cm² (x10⁵ Pa). El proceso se instruye como indica (Mera, 2022).

2.2. Determinación de índice de maduración

Para la determinación del índice de madurez se siguió la metodología descrita por García & Cabrera (2023), quienes indicaron que para tal efecto se utiliza una relación matemática entre el contenido de sólidos solubles y acidez de la fruta tal como se indica en la fórmula. La ecuación 2 se calcula el índice de madurez con el porcentaje de °Brix y porcentaje de acidez.

$$\text{Índice de madurez} = \frac{\% \text{ sólidos soluble}}{\% \text{ Acidez}} \quad (\text{Ec.5})$$

2.3 Carta de color

Como mencionaron los autores Redrovan & Nagua (2021) para poder desarrollar una carta de color se basa en los resultados de la evaluación fisicoquímicos e imágenes del banano orito; información que será cotejada con la degradación del color verde de la cascará en cada estadio de maduración, hasta alcanzar el color amarillo característico de un banano maduro.

2.4 Toma de Imágenes

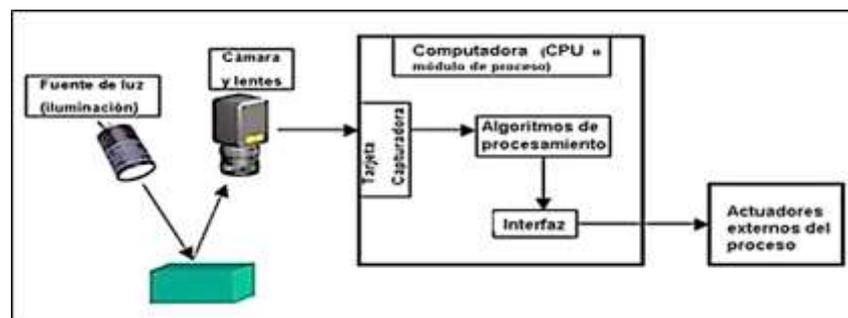
Se realizaron 4 tomas fotográficas diarias durante 8 días, una calidad de 6960x4640 pixeles con un tamaño de 9.8 MB y un peso de 72 ppp procesador de 24 bips, a un clúster de banano orito, con 3 repeticiones dando en total de 96 imágenes. Se utilizó una cámara CANON EOS 90D con una lente de 50 mm 1:1,4 adicional, se incorporó un Kit lente de cámara extra (lente estabilizador de la cámara) marca EF-S 18-135 mm f/ 3.5-5.6 imagen *Stabilizer* ISO5000 STM Lens (67mm), dispone de un sensor APS-C de 32,5 MP, el equipo ofrece un alcance de teleobjetivo equivalente a 1,6x de formato completo. Dispone de un sensor CMOS APS-C de que contiene 32,5 megapíxeles proporciona un rendimiento óptimo para capturar imágenes.

2.4.1 Procesamiento de Imágenes Se utilizó el software SckaLearn de Python para Deep Learning, se logró correlacionar las características fisicoquímicas del banano y su patrón de color (Herrero, 2005). El procesamiento de las imágenes fue utilizado por el sistema de visión artificial (VA), se utilizó las imágenes del banano oritos en los diferentes estadios madurativos, los componentes que forman son los siguientes:

- **Fuente de luz:** Proporciona las condiciones de iluminación necesarias para capturar imágenes claras y detalladas.
- **Sensor de imagen:** Capta las características del objeto en estudio, convirtiendo la información visual en señales eléctricas.
- **Tarjeta de captura o adquisición de imágenes:** Actúa como un interfaz entre sensor de la imagen y el computador, encargándose de transferir la información para su procesamiento.
- **Algoritmos de análisis de imagen:** Realizan transformaciones en la imagen para procesarla y extraer detalladamente la mayor cantidad de información.
- **Computadora o módulo de procesamiento:** Ejecuta los algoritmos de análisis sobre la **imagen** capturada, permitiendo la interpretación y análisis de los datos obtenidos. (Fracarolli et al.,2020)

En la figura 9, se observa la representación de los componentes de un sistema de visión artificial (VA).

Figura 9 Esquemas del sistema de visión artificial



Fuente: (Herrero,2005)

Las imágenes recolectadas se procesaron antes de entrar a los algoritmos de clasificación, se recolectaron siluetas de las frutas, estandarización de tamaño y color de estas, con un fondo blanco para resaltar, y se llevó a pruebas experimentales y de test. Es fundamental considerar la cantidad de datos y las características de las mediciones, previa al tratamiento de las imágenes mediante la IA.

2.5 Algoritmos de procesamiento de imágenes

Se utilizó el software “Google Colab” debido a la facilidad de conexión con archivos de “Google Drive” la disposición de ser compartido con variedad de usuarios. Los algoritmos de procesamiento de imágenes utilizaron el lenguaje de programación *Python 2.7.8* usando la

librería de Open CV 2.4.9. La segmentación y clasificación fue mediante el clasificador *Numpy*, *TensorFlow*, *Keras*, *Backpropagation* obtenidos de la librería de *Sklearn*, *Matplotlib* *pyplot*. A continuación, se observa en la figura 7, el proceso de la CCN aplica la recolección de imágenes, se procesan en porcentajes bidimensionales y se agrupan de acuerdo con su clasificación.

2.5.1 Variables de entrenamiento

En la tabla 7, se define las variables de entrenamiento y *test*.

Tabla 7 Parámetros enviados al algoritmo para su ejecución

Variable	Definición
<i>Xtrain</i>	Parámetro fisico-quimico de entrain (°Brix, Textura, Acidéz, Ph y IM)
<i>Xtest</i>	Parámetro fisico-quimico de <i>Test</i> (°Brix, Acidéz, Textura, Ph y IM)
<i>Ytrain</i>	Etiquetado los estados de Madurez del banano orito (IM,MA,SM) entrain
<i>Ytest</i>	Etiquetado los estados de Madurez del banano orito (IM,MA,SM) <i>test</i>

2. 6 PREDICCIÓN DEL ÍNDICE DE MADUREZ

2.6.1 Selección de los algoritmos: Se empleó algoritmos de predicción *TensorFlow*, *Keras* que provienen de la librería de *Sklearn* y *Matplotlib* y Redes Neuronales de alto nivel, como lo menciona el autor Sheth et al., (2022). Según Contreras *et al* (2020), luego del procesamiento de datos, por parte de los algoritmos, se crea una matriz de confusión que servirá para determinar la eficiencia del modelo de predicción. Previamente, se debe ajustar el número de épocas, en nuestro estudio se utilizó 55 *epoch* a procesar del cual se procedieron a derivar los test accuracy por epocas y la variable de reducción de imágenes *pooling* durante el procesamiento de los datos ingresado a *Google colab*.

2.6.2 Evaluación del Modelo.

Se utilizaron métricas de exactitud, *test accuracy* (Ec.6) y tasa de error (Ec. 7) (Martínez, 2022).

$$\text{Test Accuracy} = \frac{IM+MA+SM}{Total} \quad (\text{Ec.6})$$

Fuente: (Villalba *et al.*, 2021)

- IM, número de las visualizaciones de los bananos oritos inmaduros
- MA, número de las visualizaciones de los bananos oritos maduros

- SM, número de las visualizaciones de los bananos oritos sobre maduros
- Total, número de las visualizaciones total de los bananos oritos

La tasa de error se representa:

$$\text{Tasa de error} = 1 - \text{Test accuracy} \quad (\text{Ec.7})$$

Fuente: (Villalba *et al.*, 2021)

2.7 Hipótesis de investigación:

H₀: No hay diferencia significativa ($p \geq 0,05$) en la predicción del índice de madurez entre los modelos de predicción de inteligencia artificial y el método tradicional.

H₁: Hay diferencia significativa ($p \leq 0,05$) en la predicción del índice de madurez entre los modelos de predicción de inteligencia artificial y el método tradicional.

El contraste de hipótesis se determinó mediante un ANOVA de un factor, con un nivel de significancia del 0.05 %. Del cual se realizó una prueba de Levene para la igualdad de varianzas

CAPITULO III: RESULTADOS Y DISCUSIÓN

3.1 Parámetros fisicoquímicos medidos en banano orito

Los resultados de los cambios físico-químico del banano orito (*Musa acuminata* AA) postcosecha en los diferentes rangos madurativos se muestran en la siguiente tabla:

Tabla 8 Resultado de análisis físico-químico en su fase de entrenamiento del banano orito

Datos Físico-Químicos	Días después de la cosecha								
	0	1	2	3	4	5	6	7	8
Acidez (%)	1,29 (0,2)	1,68 (0,32)	1,87 (0,29)	2,20 (0,39)	2,74 (0,36)	3,29 (0,38)	2,87 (0,38)	2,56 (0,18)	2,64 (0,18)
Solidos Solubles (Brix)	6,33 (0,1)	9,58 (1,53)	13,11 (1,02)	15,67 (1,87)	19,22 (2,03)	20,00 (1,79)	25,44 (2,24)	27,89 (2,03)	29,56 (1,24)
pH	5,44 (0,23)	5,24 (0,24)	4,80 (0,36)	4,84 (0,35)	4,70 (0,11)	4,63 (0,31)	4,84 (0,18)	4,93 (0,17)	4,96 (0,17)
Textura (índice de fuerza)	9,28 (0,84)	7,26 (0,82)	3,95 (0,68)	2,46 (0,44)	2,07 (0,25)	1,83 (0,62)	1,99 (0,56)	1,54 (0,50)	0,64 (0,37)
Índice de Madurez	4,97 (0,67)	5,83 (0,88)	7,41 (1,65)	6,48 (0,99)	7,10 (1,48)	7,28 (1,00)	9,65 (1,81)	11,00 (1,30)	11,29 (0,52)
Estadio madurativo	IM	IM	IM	IM	MA	MA	MA	SM	SM

Media de tres repeticiones y su desviación estándar. IM, Inmaduro; MA, Maduro; SM, sobre maduro

Como se evidenció en la tabla 6 se realizaron tabulaciones de media aritmética y desviación estándar correspondientes a los análisis físico-químicos del banano orito a lo largo de los días de su maduración estos datos se utilizaron de entrenamiento para el modelo. Los parámetros: acidez, brix, textura y pH cambian continuamente a través del tiempo, esto se debe a las constantes modificaciones bioquímicos como: incremento de la tasa de respiración e intercambio gaseoso del etileno que influye en la actividad enzimática del cual influye en la velocidad del proceso de maduración, la degradación del contenido de azúcares en disolución de compuestos pécticos, descomposición de la clorofila y elevación en los niveles de ácidos orgánicos (Castellanos & Algecira, 2012), los procesos metabólicos la pulpa han aumentado la

absorción de agua que se encuentra en la cáscara y de este modo se produce la degradación de los hidratos de carbono presentes.

Tabla 9 Resultado de análisis fisicoquímico (test) del banano orito post cosecha

Datos Fisicoquímico	Días después de la cosecha								
	0	1	2	3	4	5	6	7	8
Acidez (%)	1,3 (0,1)	2,0 (0,3)	2,5 (0,9)	2,6 (0,9)	3,1 (0,5)	2,9 (0,5)	2,8 (0,7)	2,3 (0,1)	2,3 (0,3)
Sólidos Solubles (°Brix)	7,0 (0,9)	13,3 (1,2)	15 (0,9)	15,7 (1,3)	25,7 (2,1)	25,3 (2,1)	26,7 (2,2)	28,7 (2,1)	31,0 (1,0)
pH	5,4 (0,3)	5,1 (0,2)	4,9 (0,5)	4,8 (0,4)	4,7 (0,1)	4,7 (0,3)	4,8 (0,3)	4,7 (0,2)	4,6 (0,2)
Textura (índice de fuerza)	7,8 (1,3)	6,1 (0,7)	2,5 (0,5)	2,3 (0,3)	1,8 (0,5)	1,8 (0,6)	1,9 (0,7)	1,2 (0,6)	1,1 (0,9)
Índice de Madurez	5,1 (1,2)	7,2 (1,1)	6,1 (1,7)	7,4 (1,2)	8,8 (1,8)	8,0 (1,8)	10,1 (1,5)	13,1 (0,4)	13,1 (0,8)
Estadio madurativo	IM	IM	IM	IM	MA	MA	MA	SM	SM

Media de tres repeticiones y su desviación estándar. IM, Inmaduro; MA, Maduro; SM, sobre maduro.

En la tabla 7, se tabularon en media aritmética y desviación estándar correspondientes a los análisis físico-químicos del banano orito que se utilizó para prueba (test) de lo que equivale el 20% de los datos ingresados en forma de etiqueta al modelo predictivo. Estos cambios que suceden con la fruta afectan la textura como indica el autor Castricini et al., (2014) la firmeza inicia con un valor de 8.7 kg/cm². y el color de la cáscara se atrofia. La acidez que se encuentra en el banano (% ácido málico) ascendió a medida que el almidón (fuente de carbono) se convierte en azúcares simples como la fructuosa, glucosa, sacarosa y pequeños trazos de maltosa. En este proceso intervienen ciertas enzimas que promueven las vías metabólicas de maduración tales como las alfa, beta-amilasas, la fosforilasa de almidón y alfa-1,4-glucano-fosforilasa (Mainardi et al., 2006; Mota et al., 2002). Además, los ácidos orgánicos presentes tales como ácido cítrico, málico, oxálico y ascórbico (vitamina C) son degradado por la acción de enzimas deshidrogenasa del banano orito, la mayoría de los ácidos han sido metabolizados o transformados durante el proceso de maduración, y estos integran el sabor ácido y

ligeramente amargo que han sido sintetizados por los azúcares totales y reductores que se encuentran en la pulpa a media que evolucionan el fruto. Según el estudio de los autores Llanos & Bedoya (2019), se reportó que la acidez del banano aumenta gradualmente durante el proceso de maduración de los que los ácidos orgánicos presentes en el banano *Musa acuminata* AA iniciando del estado verde con 0,7 % al 1,5 % en el estado madurativo, que los ácidos contribuyen a la calidad postcosecha de la fruta.

El parámetro de pH, los valores presentaron una disminución continua, debido a la degradación de los ácidos orgánicos que se desprecian causada por la respiración celular y a la conversión del almidón a azúcares simples, como menciona el autor Bello (2008), en el proceso de maduración se aumenta la acidez de la pulpa. La PPO es una metaloenzima que cataliza dos tipos de reacciones: primero, la conversión de monofenoles a orto-difenoles mediante una acción de hidroxilación; y segundo, la transformación de orto-difenoles a orto-quinonas a través de una actividad catecolasa que implica una oxidación, estos cambios se ven activos en rango de pH de 5,0 y en referencia estándar de un rango 6,0-6,5. El sistema se inactiva cuando el pH del medio alcanza las zonas ácidas inferiores a 3,0; como lo describe Peñafiel (2017). El banano orito verde presenta un valor alto de pH considerable en el estado verde hasta llegar al estado sobre maduro con un pH de 4,6 como se observa en la tabla anterior. Como reporta Llanos & Paéz (2021). Mientras avanza el tiempo de maduración, el pH disminuye y aumenta la acidez en la pulpa. Los sólidos solubles (°Brix) aumentan en la maduración, lo que significa que es equivalente a la concentración de los azúcares totales, en la fase verde el contenido de azúcares es bajo, la mayoría de los carbohidratos en el banano es almidón como indica Bustamante, (2020) a medida que se produce la maduración, se descompone en azúcares simples lo que lleva a aumentar el contenido. Menciona el autor Casanova (2014) que el banano orito en el estado de madurez verde mostró pH (4,96) y °Brix (15,30) inicialmente y en comparación con el estado maduro acrecientan hasta llegar a un pH (5,35) y °Brix (16,05). Los sólidos solubles se encuentran dentro del rango estudiado y para el consumo óptimo están entre 17,5 y 19 % sería ($6,0 \pm 0,75$ °Brix). Por otro lado, los autores Rosenthal et al., (2011) y García (2015), describen que los sólidos totales aumentan desde 1 % en estado verdes hasta alrededor de 20 % en estado maduro y en el estado de sobremadurez la concentración de azúcares puede disminuir debido a su conversión en alcoholes, como el bioetanol (Castro & Feijo, 2009). La textura, una propiedad organoléptica crucial, se caracteriza por factores como la porosidad, gelificación, elasticidad, microestructura y agregación, los cuales también reflejan la calidad y el grado de madurez del producto. Se puede observar en las tablas 6-7 la textura del banano orito empieza a degradarse a partir del día 2 con un valor de 2,5 kg/cm², y posteriormente en

el día 5 se obtiene valores $>1,8 \text{ kg/cm}^2$ el cual la pulpa madura es de fácil penetración al utilizar el equipo. Como indica el autor Peñafiel (2017), la textura del banano orito en la fase inmaduro (verde) inicia con 7 kg/cm^2 la cáscara tiene una apariencia lisa debido a la alta concentración de almidón, la actividad de las enzimas que descomponen la pectina está en el grupo de las enzimas *pectinolíticas* como: la *pectina metilesterasa* y la *pectinasa* se activan y empiezan a descomponer la pectina, la fruta se vuelve más suave y menos firme, el almidón se convierte en azúcares causada por la transpiración de la cascara al medio ambiente por el proceso osmótico del agua que está en la piel de la pulpa, en la etapa sobremadura del banano orito se vuelve suave y casi cremoso. El índice de madurez se determina mediante el cálculo matemático de los parámetros de sólidos solubles y acidez. En el trabajo de Torres et al, (2013) utilizaron las mismas etricas de Parametros fisico quimico y el Indice de madurez Esta evaluación garantiza tanto la calidad de aceptación del producto como una vida útil prolongada en el anaquel. Además, el índice de madurez debe ser más bien objetivo que subjetivo y, preferiblemente, no destructivo, observando un incremento de las características fisicoquímicas del banano (Chu et al., 2022).

3.2 Carta de Color

Figura 10 Carta de colores del banano orito mostrando las etapas de madurez desde el estado verde hasta el estado de acentuación de degradación

CARTA DE COLOR DEL BANANO ORITO								
0	1	2	3	4	5	6	7	8
pH: 5,44 Acidez: 1,29 Sólidos Soluble: 6,33	pH: 5,24 Acidez: 1,68 Sólidos Soluble: 9,58	pH: 4,80 Acidez: 1,87 Sólidos Soluble: 13,11	pH: 4,84 Acidez: 2,20 Sólidos Soluble: 15,67	pH: 4,70 Acidez: 2,74 Sólidos Soluble: 19,22	pH: 4,63 Acidez: 3,29 Sólidos Soluble: 20,00	pH: 4,84 Acidez: 2,87 Sólidos Soluble: 25,64	pH: 4,93 Acidez: 2,36 Sólidos Soluble: 27,89	pH: 4,56 Acidez: 2,64 Sólidos Soluble: 29,56
								
Color verde oscuro, indica que el banano orito está completamente inmaduro.	Verde con un tono más claro, indicando un maduración inicial.	Color verde amarillento, indica un avance en la maduración.	El banano orito se vuelve amarillo verdoso y está comenzando a madurar.	Amarillo claro con algunas manchas verdes, casi maduro.	Un tono brillante de amarillo, completamente maduro y listo para ser consumido.	Amarillo con algunas manchas marrones que indican una dulzura mayor.	Amarillo con más manchas marrones, muy dulce pero casi demasiado maduro.	Marrón, que significa que el banano orito está muy maduro o pasado de maduración.

En la figura 10, se muestran imágenes de las distintas etapas de maduración del banano orito, desde su estado inmaduro a sobremaduro. Existen variaciones de pH, sólidos solubles y acidez, a medida que el banano orito madura, representado visualmente los cambios de color por su apariencia, como indica Verma et al, (2015) el patrón se basa al análisis visual, tiende

a disminuir ligeramente al inicio (de 5,44 a 4,63) esto indica una acidificación del fruto en las primeras etapas de maduración, seguidamente incrementa de a poco en las etapas más maduras (hasta 4,96) producido por una ligera alcalinización; en cuanto a la acidez nos mostró un aumento gradual desde 1,29 en la etapa 0, hasta un pico de 3,29 en la etapa 5 alcanzando su madurez óptima, seguida por una disminución en las etapas posteriores; por último con los grados brix ($^{\circ}$ Brix) obtuvimos un aumento a lo largo de toda la maduración, consistentemente desde 6,33 en la etapa 0 hasta 29,56 en la etapa 8, lo cual indicó un incremento en el contenido de azúcares pero comienza a perder acidez, lo que puede afectar en la textura y el sabor (García, 2002). Para la interpretación del estado de madurez del banano orito se basó en los detalles señalados por los parámetros fisicoquímicos para esta carta de color, en donde se puede evidenciar los cambios organolépticos, fisiológicos que se modifican a medida que se madura la fruta, el aspecto a señalar más importante es la "Clorofila" de color verde y los carotenoides de colores amarillo, naranja y rojo. Estos cambios se evidencian visualmente como consecuencia de la degradación de la clorofila, debido a la degradación del cloroplasto y la formación de carotenoides en los "*plastidos*" mientras que la "*xantofila*" se encuentra persistente. Esta fruta existe una mayor concentración de clorofila a y b en los primeros días de almacenamiento, posteriormente, estas se degradan a clorofila a y feoforbida, carotenoides y xantofilas, motivo de la acción de enzimas clorofilasas que conllevan a formar esta coloración amarilla en la corteza, debido al desenmascaramiento y síntesis de nuevo de carotenoides (Castro,2007). Las o-quinonas son reactivas y dan lugar a múltiples reacciones de oxidación, adición y polimerización forman pigmentos denominados melaninas representa el color oscuro en la piel del banano (Martínez et al., 2015). Cuando la pulpa aumenta su tamaño, las células de la cáscara que están deficitarias en Ca^{2+} se desintegran y manifiestan el bronceado (Díaz et al., 2007), la coagulación y oscurecimiento del contenido de los vasos laticíferos. Los niveles 7 y 8 están relacionados con el "Estado de degradación acentuada". Las manchas marrones y el color amarillo de los bananos en estos puntos indican que han llegado a su punto máximo de madurez y están empezando a degradarse, pues entre sus propiedades físicas está la de reflejar la luz del espectro amarillo. (Abraham et al., 2022).

Como menciona Siriboon & Banluisilp (2004), la fruta se encuentra de color amarillo estado maduro por la presencia de: α -caroteno, el β -caroteno y la luteína. Dado que la cáscara de banano es rica en compuestos fenólicos, se oxida rápidamente por Polifenoloxidasas. La firmeza de la fruta disminuyó constantemente durante los siete días de almacenamiento. Se esperaba que durante esos períodos todo el almidón se convirtiera completamente en azúcar.

Al estudiar la actividad de la enzima pectato liasa durante la maduración del fruto, se observó un aumento progresivo desde el inicio del climaterio, mientras que la poligalacturonasa también incrementó durante este proceso (Anurag et al., 2003). Además, Seemi et al. (2004) señalan que estos cambios pueden implicar un aumento en la actividad de diversas hidrolasas de la pared celular, impulsadas por hormonas de maduración. En particular, destacan la actividad de la metil esterasa (PME), poligalacturonasa (PG), pectato liasa (PL) y celulasa, especialmente en el caso del banano de la variedad *musa acuminata* AA.

3.3 Algoritmos Deep Learning

En la tabla 10, se definen las variables de entrada y de salida, así como también la variable de respuesta, información necesaria para la ejecución de los algoritmos.

Tabla 10 Variables de entrada, salida y de respuesta con respecto a las características físico-química del banano orito referente a los datos de entrenamiento y de prueba

Variable	Definición
<i>epoch</i>	Numero de épocas (capas) CNN
<i>xtrain</i>	Características fisicoquímicas de entrenamiento (Sólidos solubles, Acidez, Textura, pH)
<i>xtest</i>	Características fisicoquímicas en el <i>test</i> (Sólidos solubles, Acidez, Textura, pH)
<i>ytrain</i>	Estadio de madurez del banano orito (IM, MA y SM) para entrenin
<i>ytest</i>	Estadio de madurez del banano orito (IM, MA y SM) para el <i>test</i>

En la tabla 10, se pudo observar el modelo matemático de clasificación de *Deep Learning* aplicado a la predicción de estadios madurativos de banano orito.

3.4 Interpretación de los resultados del test accuracy por cada época

A continuación, en la figura 11, se presenta los valores procesados por algoritmos de IA por cada época con sus respectivos resultados del test accuracy.

Figura 11 Procesamiento de cada época utilizando la variable de loss y test accuracy

```

Epoch 1/55
6/6 [=====] - 111s 11s/step - loss: 1.2536 - accuracy: 0.3240 - val_loss: 1.0729 - val_accuracy: 0.432
Epoch 2/55
6/6 [=====] - 75s 5s/step - loss: 1.0668 - accuracy: 0.4190 - val_loss: 1.0222 - val_accuracy: 0.4324
Epoch 3/55
6/6 [=====] - 90s 7s/step - loss: 0.9529 - accuracy: 0.6257 - val_loss: 0.8315 - val_accuracy: 0.6216
Epoch 4/55
6/6 [=====] - 75s 4s/step - loss: 0.6940 - accuracy: 0.6488 - val_loss: 1.1925 - val_accuracy: 0.5405
Epoch 5/55
6/6 [=====] - 74s 5s/step - loss: 0.7966 - accuracy: 0.6145 - val_loss: 0.9286 - val_accuracy: 0.5946
Epoch 6/55
6/6 [=====] - 84s 7s/step - loss: 0.6607 - accuracy: 0.6704 - val_loss: 0.6968 - val_accuracy: 0.7297
Epoch 7/55
6/6 [=====] - 84s 6s/step - loss: 0.5356 - accuracy: 0.7095 - val_loss: 0.7629 - val_accuracy: 0.7027
Epoch 8/55
6/6 [=====] - 74s 5s/step - loss: 0.5126 - accuracy: 0.7430 - val_loss: 0.6919 - val_accuracy: 0.7297
Epoch 9/55
6/6 [=====] - 74s 5s/step - loss: 0.4859 - accuracy: 0.8045 - val_loss: 0.7942 - val_accuracy: 0.6486
Epoch 10/55
6/6 [=====] - 81s 5s/step - loss: 0.5370 - accuracy: 0.7095 - val_loss: 0.5995 - val_accuracy: 0.7297
Epoch 11/55
6/6 [=====] - 74s 4s/step - loss: 0.4375 - accuracy: 0.8268 - val_loss: 0.7112 - val_accuracy: 0.7027
Epoch 12/55
6/6 [=====] - 74s 5s/step - loss: 0.4432 - accuracy: 0.7765 - val_loss: 0.6312 - val_accuracy: 0.9189
Epoch 13/55
6/6 [=====] - 83s 7s/step - loss: 0.4430 - accuracy: 0.8156 - val_loss: 0.5923 - val_accuracy: 0.8649
Epoch 14/55
6/6 [=====] - 75s 5s/step - loss: 0.4411 - accuracy: 0.8101 - val_loss: 0.5366 - val_accuracy: 0.8919
Epoch 15/55
6/6 [=====] - 74s 5s/step - loss: 0.3770 - accuracy: 0.8212 - val_loss: 0.5553 - val_accuracy: 0.9459

```

En la figura 11, se ejecutó: los algoritmos, las épocas, las variables (x/y) tanto para entrenamiento y de test, donde se inició identificando la carpeta principal de las imágenes que se respaldan en la nube de *microsoft (Google Drive)* el cual se ingresa estos valores en *Google Colaboraty* que permite ejecutar el código *Python* que ofrece acceso a recursos de computación, como GPUs y TPUs. *Colab* es adecuada para el aprendizaje automático, lo primero que se puede observar cómo se procesan las épocas (*epoch*) por medio de las redes neuronales convolucionales que son incorporadas por las capas de ingreso, las ocultas y de salida, estos procesos de entrenamiento llegan a encontrar la menor cantidad de datos perdidos (*loss*), previamente se ingresó las 55 épocas que dan un resultado individual de *test accuracy*, el un valor final de *test accuracy* fue de 0,9459, cabe recalcar que este valor no debe superar el 1% (*overfitting*) ya que vendrían a sobrecargar la información de estas matrices y llegando a darnos datos erróneos, siendo afirmativo el valor para la predicción, se evidencia que tiene *pooling (loss)* :0,5872 datos dan precisión a los modelos de predicción. Como indica Cosovic y Jankovic, (2020). La CNN el modelo se detuvo en un entrenamiento con 111 para el dataset con 5 clases de imagenes se obtuvo un 9.72% test accuracy

3.5 Interpretación de la arquitectura de la red neuronal para Deep Learning

En la siguiente la figura 12, se interpreta la arquitectura de la red neuronal para *Deep Learning* aplicando los comandos de clasificación y visualización.

Figura 12 Arquitectura de la red neuronal para Deep Learning

```

modelo = Sequential([
    layers.experimental.preprocessing.Rescaling(1./255, input_shape=(height_shape, width_shape, 3)),
    layers.Conv2D(16,3, padding='same', activation='relu'),
    layers.MaxPooling2D(2),
    layers.Conv2D(32,3, padding='same', activation='relu'),
    layers.MaxPooling2D(2),
    layers.Conv2D(64,3, padding='same', activation='relu'),
    layers.MaxPooling2D(2),
    layers.Conv2D(128,3, padding='same', activation='relu'),
    layers.MaxPooling2D(2),
    layers.Flatten(),
    layers.Dense(256, activation='relu'),
    layers.Dropout(0.5),
    layers.Dense(num_classes, activation='softmax')
])

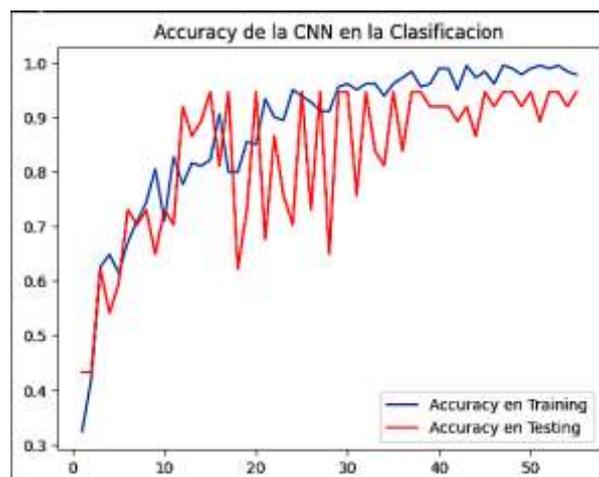
```

En la figura 12, se pudo visualizar el diseño arquitectónico de *Deep Learning*, en el cual se puede observar los *layer* de las CNN configurada como: Conv2D en el momento de la activación y la *summarize_model*. proporcionan datos sobre el número de ejemplos, así como el valor de los pesos y sesgos de las diferentes capas del modelo. Esto se debe a que, inicialmente, la red extrae los patrones utilizando la primera etapa que incluye los algoritmos, seguido por el clasificador (*top model*) para procesar las imágenes con máxima precisión. Las capas de *pooling* se utilizan para reducir el tamaño de los mapas de activación en las capas más cercanas a la salida, para ejecutar en GPUs (*Cloud for Deep Learning*). Además, también se redujo con el *overfitting* (aprendizaje excesivo) cual se calcula la media de los elementos y con el *max-pooling* identifica los elementos máximos de imágenes procesadas. Como mencional el autor Takahiro et al. (2023), utilizan la estructura artificial con algoritmos similares para DL

3.6 Interpretación de las neuronales convolucionales en el test accuracy

En la figura 13, se observa los resultados de la gráfica que usaron las CNN en la red.

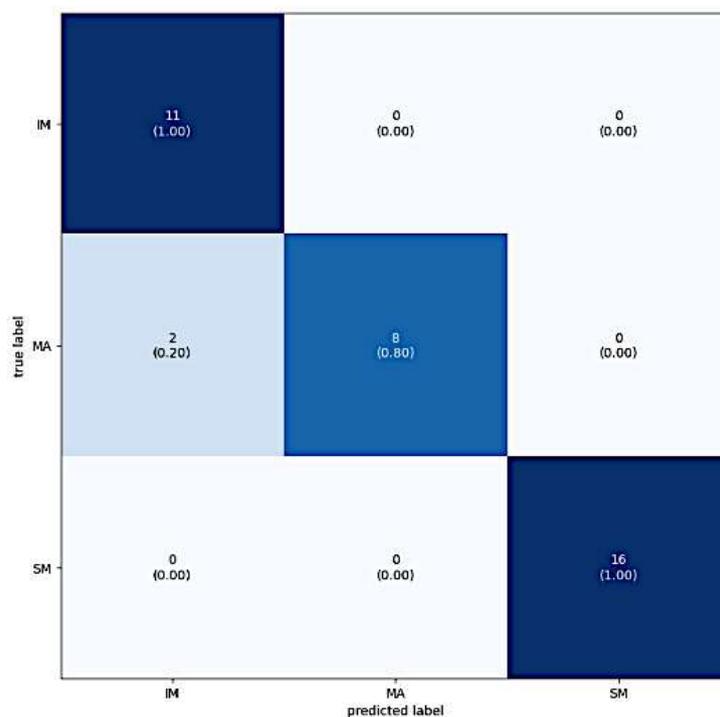
Figura 13 Gráfica las redes neuronales convolucionales del Test Accuracy



La figura 13, señala un gráfico de líneas que muestra la precisión de una red neuronal convolucional durante el proceso de clasificación a lo largo de 55 épocas. La figura tiene dos líneas que representan la: precisión en el entrenamiento (línea azul) precisión en pruebas (línea roja). La precisión aumenta consistentemente y llega cerca de 1,0, lo que indica que el modelo se ajusta muy bien a los datos de entrenamiento. La precisión de las pruebas también mejora con el tiempo, pero muestra más fluctuaciones en comparación con la precisión del entrenamiento. Además, es ligeramente inferior y más variable, indica que, si bien el modelo se generaliza bien a datos no vistos, puede tener cierto sobreajuste, dada la precisión de entrenamiento perfecto, pero la precisión de las pruebas ligeramente inferior. La variable de prueba (testing) se estabiliza alrededor de 0,9 después de las épocas iniciales, aunque tiene cierta variabilidad. Las fluctuaciones en la precisión de las pruebas sugieren que el rendimiento del modelo en el conjunto de prueba es menos estable en comparación con el conjunto de entrenamiento. Según, Cosovic y Jankovic (2020), en el conjunto completo de datos, la CNN detuvo el entrenamiento en la época 69, obteniendo una precisión del 74,24 %. La pérdida de entrenamiento en la última época alcanzó el valor de 0,9616; mientras que la pérdida de validación alcanzó el valor de 1,19 en la precisión del modelo.

3.7 Interpretación de la Matriz de confusión de los algoritmos utilizados de DL

Figura 14 Grafica de Matriz de Confusión



En la figura 14, se observa la gráfica de matriz confusión prueba de los análisis de predicción con su etiqueta de los estadios madurativos, al realizar una comparación con resultados de otras investigaciones (Martínez, et, al; 2022) el cual obtuvo un *test accuracy* de 0,8; utilizando los algoritmos de *Machine Learning* , comparando con la presente investigación, el cual fue de 0,9; con un nivel interferencia predictivo del 2 %. quiere decir que la gráfica de la matriz de confusión nos refleja que los datos reales y los datos de predicción tienen en el grado de MA (maduro) dos valores que no puede detectar en las capas de CNN mientras que los estados de IM y SM nos señala que concuerdan los valores reales con los de predicción.

3.8 Prueba de hipótesis

En las siguientes tablas se muestran los valores del índice de madurez de los bananos orito de entrenamiento y de test, madurados en condiciones ambientales y de test de predicción, respectivamente.

Tabla 11 Índices de madurez del banano orito en entrenamiento y test

Muestras de banano orito	Índice de madurez								
	Entrenamiento	4,94	5,83	7,14	6,48	7,1	7,28	9,65	11
test	5,11	7,2	6,1	7,4	8,8	8	10,1	13,1	13,1

El contraste de hipótesis fue realizado utilizando una prueba T – student de muestras independientes con un nivel de confianza del 95 %.

Tabla 12 Prueba de muestras independientes de la hipótesis

		Prueba de muestras independientes								
		Prueba de Levene para la igualdad de varianzas		Prueba T para la igualdad de medias						
Test		F	Sig.	t	gl	Sig. (bilateral)	Diferencia de medias	Error típ. de la diferencia	95% Intervalo de confianza para la diferencia	
									Inferior	Superior
Test	Se han asumido varianzas iguales	,686	,454	-,934	4	,403	-,95667	1,02447	-3,80106	1,88773
	No se han asumido varianzas iguales			-,934	3,697	,407	-,95667	1,02447	-3,89552	1,98219

Según los resultados demostrados en la tabla 12, del análisis estadístico se puede inferir que, se acepta la Hipótesis nula confirmando que, el algoritmo de IA puede predecir el estado de madurez del banano orito con una alta precisión.

CAPITULO IV: CONCLUSIÓN

El uso de estos métodos de clasificación innovadores es de beneficio para la agroindustria, particularmente al reducir las pérdidas después de la cosecha y optimizar los recursos agrícolas, dando como resultado, un impacto económico y social positivo en la región. La automatización del proceso de clasificación mediante inteligencia artificial ayuda a reducir los errores humanos, causantes de un elevado porcentaje de rechazo de calidad y optimiza el tiempo para determinar el estado de madurez de los bananos. Se creó una carta de colores que abarca desde fase organolpética el estado inmaduro hasta el sobremaduro o senescencia del banano orito, lo que facilita la visualización y clasificación de los diferentes estados de maduración de la fruta, logrando predecir sus características fisicoquímicas y texturales. En el presente trabajo de investigación, se predijo que el índice de madurez del banano orito (*musa acuminata AA*) mediante la aplicación de la inteligencia artificial, específicamente, a través de algoritmos de *Deep Learning*, se obtuvo con un porcentaje de 94 %, de aproximación con lo cual se contribuye al aprovechamiento más oportuno de esta musácea, tanto como fruta o para su industrialización.

CAPITULO V: RECOMENDACIONES

Este estudio recomienda ampliar la base de datos, como tener grandes cantidades de imágenes y establecer otros parámetros instrumentales para mejorar las precisiones de las predicciones utilizadas por las redes neuronales convolucionales, esto ayuda a refinar los modelos y reducir sesgos potenciales. Adicionalmente es preferible explorar nuevos algoritmos de predicciones que se encuentran en la librería de *Phyton* para poder comparar otros algoritmos de aprendizaje automático y de aprendizaje profundo. Los modelos basados en el aprendizaje por refuerzo y las redes neuronales recurrentes (RNN) son algunas de las técnicas que podrían ofrecer mejoras adicionales. Es recomendable disponer de un sistema de predicción con entornos reales donde se inicia la cosecha de los frutos en tiempo real para evitar que maduren contra tiempo al realizar el transporte de la materia prima, de este modo contrarrestar los cambios de maduración que se ejecutan desde la recolección hasta los destinos que son llevados para los análisis, es indispensable poder optar por otros parámetros, poder identificar el grado de madurez por medio de otros análisis instrumentales como es el colorímetro, la densidad, generadores catalíticos y medición de calibre del fruto. El sistema de predicción puede integrarse con tecnologías de sensores avanzadas como la longitud de onda a partir de la espectroscopía o las imágenes hiperespectrales infrarrojo (Vis/NIR) especificando equipos como GaiaField-mini y Dualix, mediante el método de análisis de discriminación de mínimos cuadrados parciales (PLSDA) Esto podría mejorar la robustez y la precisión del sistema. La integración con Tecnologías de Sensores es preferible usar para obtener datos adicionales, El modelo propuesto podría desarrollarse como una aplicación móvil como MobileNet V2 para identificar el estado de madurez a partir de datos en tiempo real en el campo de banano. Esto permitirá adaptar el modelo a las demandas y características del entorno de trabajo, promoviendo la colaboración interdisciplinaria con expertos en agroindustria, informática y ciencia de datos para continuar innovando y mejorando los sistemas de predicción de

madurez de frutas. Esta colaboración puede generar nuevas ideas con avances de campo y atraer colaboraciones o financiamiento para futuros proyectos.

BIBLIOGRAFÍA

- AOAC (Association of Official Analytical Chemists). (1990). Official methods of an analysis of the association of official analytical chemists. 11a edition. Washington.
- AOAC. Official method of analysis. Association of Official Analytical Chemistry. 16th edición, 981.12/90. Ed. By Hoorwitz, N., P. Chialo, y H. Reynold, Washington, USA. (1990). <https://bit.ly/3Ap1dfd>
- Aguirre, W. A. L. (2019). Espectroscopia infrarrojo y técnicas de machine learning y deep learning para la detección y clasificación de arándanos. Pueblo Continente, 30(2). Enlace: <https://bit.ly/46Mz4e3>
- Abraham, B. , Saleh, B. and Zelelew, D. (2022) Effect of Post-Harvest Handling and Ripening Methods on Quality and Shelf-Life of Banana. American Journal of Plant Sciences, 13, 175-192. doi: 10.4236/ajps.2022.132011
- Alvarado Cervantes, R. (2017). "Segmentación de imágenes digitales sobre la base de la información integral del color", Rev. Universidad Autónoma de Mexico,, enlace: <https://repositorio.unam.mx/contenidos/102386>
- Ayala Laverde, C. S. (2016). Comercialización del banano orito (Musa acuminata) con fines de exportación, cantón La Maná provincia de Cotopaxi, link: <https://repositorio.utc.edu.ec/bitstream/27000/3481/1/T-UTC-00758.pdf>
- Artificial, Vision. (2012) Aplicación práctica de la visión artificial en el control de procesos industriales. España, enlace: <https://bit.ly/4dzovgw>
- Alegre, E., Pajares, G., & De la Escalera, A. (2016). Conceptos y métodos en visión por computador. In España: Grupo de Visión del Comité Español de Automática enlace: <https://bit.ly/3WHbLOE>

- Burns D. M. & Whyne C. M. (2018). Seglearn: A Python Package for Learning Sequences and Time Series, *Journal of Machine Learning Research* 19 link: <https://jmlr.org/papers/volume19/18-160/18-160.pdf>
- Barrio González, D. D. (2022). Aplicación del aprendizaje automático en modelos de materia activa. Universidad Politécnica de Madrid, España. Link: https://oa.upm.es/70193/3/TFG_Diego_del_Barrio_Gonzalez.pdf
- Beunza J. J., Puertas E., Condés E. (2020). Manual práctico de inteligencia artificial en entornos sanitarios. Enlace: <https://bit.ly/3SN2hzL>
- Bustamante, W. D., Quevedo Guerrero, J. N., García Batista, R. M., Herrera Reyes, S. N., y Luna Romero, Á. E. (2020). Determinación de la relación de carga en los grados Brix en hojas y frutas de banano clon Williams (Musa Paradisiaca). *Rev. Universidad y Sociedad*, 421-430, enlace: <https://bit.ly/3WA6mZ6>
- Babitz K. (2023). Introducción a la representación gráfica con Matplotlib en Python, Sitio Web, Datacamp, Pensilvania, Estados Unidos, enlace: <https://www.datacamp.com/tutorial/matplotlib-tutorial-python>
- Castillo, L. & Merino C. (2020). Evaluación de contenido antioxidante en una bebida fermentada de pulpa de banano orito (Musa acuminata AA). Universidad Estatal Amazónica, Pastaza, Ecuador, repositorio UEA [https://repositorio.uea.edu.ec/bitstream/123456789/874/1/T.%20AGROI N.%20B.%20UEA.%20%202112.pdf](https://repositorio.uea.edu.ec/bitstream/123456789/874/1/T.%20AGROI%20N.%20B.%20UEA.%20%202112.pdf)
- Crespo, C. F., & Guanochanga, J. (2022). Diseño de un Proceso para la Obtención de Pulpa Congelada a Partir de Orito (Musa acuminata AA). *Revista Científica Ciencia y Tecnología*, 22(36). DOI: <https://doi.org/10.47189/rcct.v22i36.542>
- CFN. (2017). Sector Agricultura, Ganadería, Silvicultura Y Pesca "Banano Y Plátanos". <https://bit.ly/46Hu7Dk>
- Caisedo, W., Sánchez, J., Viamontes, M., Tapuy, A., Estrada, C., Flores, A., & Moya, C. (2019). Chemical composition and apparent digestibility of green "orito" banana (Musa acuminata AA) meal in growing pigs. Cuba. *Rev Journal of Agricultural Science*, enlace <https://www.cjascience.com/index.php/CJAS/article/view/908>
- Constante, P. N. & Gordón, G. M., (2015). Diseño e implementación de un sistema de visión artificial para clasificación de al menos tres tipos de

- frutas. Escuela Politecnica Nacional, enlace:<http://bibdigital.epn.edu.ec/handle/15000/11368>
- Castricini, A., Oliveira, L., Deliza, R., Ferreira, E., Vilela, M. (2014). Caracterização pós-colheita e sensorial de genótipos de bananeiras tipo prata. Brasil. <https://doi.org/10.1590/0100-2945-058/14>
- Chu, X., Miao, P., Zhang, K., Wei, H., Fu, H., Liu, H., ... & Ma, Z. (2022). Green Banana maturity classification and quality evaluation using hyperspectral imaging. *Agriculture*, 12(4), 530. <https://doi.org/10.3390/agriculture12040530>
- Castro-B., M., Restrepo S., L. P., & Narváez C., C. E. (2005). Actividad de clorofilasa durante la maduración del banano bocadillo (*Musa accuminata*)(Simons). *Actualidades Biológicas*, 27(83), 8-8. <https://doi.org/10.17533/udea.acbi.329419>
- Castro, L., & Feijoo, M. I. J. (2009). Valoración del potencial de frutos de tres musáceas para la producción de alcohol a nivel de laboratorio (Doctoral dissertation, Tesis Ing. Agropecuario Escuela Superior Politécnica del Litoral. Guayaquil-Ecuador). Enlace: <https://bit.ly/3M1Mqtp>
- Cosovic, Marijana & Jankovic Babic, Radmila. (2020). CNN Classification of the Cultural Heritage Images. International Symposium INFOTEH-JAHORINA, East Sarajevo, Bosnia and Herzegovina <http://dx.doi.org/10.1109/INFOTEH48170.2020.9066300>
- Cho, B. H., & Koseki, S. (2021). Determination of banana quality indices during the ripening process at different temperatures using smartphone images and an artificial neural network. *Scientia Horticulturae*, 288, 110382. <https://doi.org/10.1016/j.scienta.2021.110382>
- de Souza, C. C., Araújo, L. O., Nunes, H. S., & Conceição, L. R. (2014). Utilização de redes neurais artificiais para previsão de preços de frutas e hortaliças. *FACEF Pesquisa-Desenvolvimento e Gestão*, 17(3). Enlace: <http://periodicos.unifacel.com.br/facefpesquisa/article/download/715/73>
- Deepa, N., Sathya Priya, J., & Devi, T. (2022). Towards applying internet of things and machine learning for the risk prediction of COVID-19 in pandemic situation using Naive Bayes classifier for improving accuracy. *Materials Today: Proceedings*, 62, 4795–4799. <https://doi.org/10.1016/j.matpr.2022.03.345>

- Díaz, A., Cayón, G., & Mira, J. J.. (2007). Metabolismo del calcio y su relación con la "mancha de madurez" del fruto de banano. Una revisión. *Agronomía Colombiana*, 25(2), 280-287. Retrieved July 29, 2024, from http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-99652007000200010&lng=en&tlng=es
- Erazo Narváez, C. A. (2023). Diseño de un sistema embebido de monitoreo por visión artificial que permita medir el grado de madurez de las frutas [Tesis de pregrado, Universidad Técnica del Norte]. Recuperado de <https://repositorio.utn.edu.ec/handle/123456789/15095>
- Forero-Corba, W. & Negre Bennasar, F. (2024), Técnicas y aplicaciones del Machine Learning e Inteligencia Artificial en educación: una revisión sistemática, *RIED-Rev. Iberoamericana de Educación*, España: <https://www.redalyc.org/journal/3314/331475280017/331475280017.pdf>
- Falconí P. D. (2021). Algoritmos de Deep Learning utilizando Tensor Flow para el tratamiento de datos de producción científica en la Universidad Técnica de Cotopaxi (Master's thesis, Ecuador: Latacunga: Universidad Técnica de Cotopaxi: UTC.). <https://doi.org/10.55204/trc.v3i2.e226>
- Fracarolli, JA, Pavarin, FFA, Castro, W. y Blasco, J. (2020). Visión por ordenador aplicada a productos alimentarios y agrícolas. *Revista Ciencias Agrícolas*, 51 (spe), e20207749. <https://doi.org/10.5935/1806-6690.20200087>
- García W., Claudia L., Giraldo G., Germán A., Hurtado T., Hernando, & Mendivil, Carlos O.. (2006), Cinética enzimática de la polifenol oxidasa del banano gros Michel en diferentes estados de maduración. *Rev. Vitae*, enlace:http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-40042006000200002&lng=en&tlng=es
- García N., B. (2015). Implementación de técnicas de deep Learning, Universidad San Cristóbal de La Laguna, España. <https://bit.ly/46F2ta5>
- Guerrero Z., S. (2020). Características morfométricas de cultivares de Musáceas establecidos en la finca experimental "LA MARÍA". Los Ríos. Link: <https://repositorio.uteq.edu.ec/server/api/core/bitstreams/5bcda07a-c25a-4559-8cb2-75916c10e35d/content>
- Gonzabay, R. (2017). Cultivo del banano en el Ecuador. *Revista Afese*, 58(58), 113-142. <https://afese.com/img/revistas/revista58/cultivobanano.pdf>

- Harmandeep Singh G., G. Murugesan, A. Mehbodniya, G. Sekhar Sajja, Gaurav G., Abhishek B.,(2023) Fruit type classification using deep learning and feature fusion, *Computers and Electronics in Agriculture*, Rev. sciencedirect, *Computers and Electronics in Agriculture*, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2023.107990>.
- Hernández, E. (1986). Cambios físicos y químicos durante la maduración de cambures y platanosa. *Revista de la Facultad de Agronomía*, 7(1). Link <https://produccioncientificaluz.org/index.php/agronomia/article/download/25881/26507/>
- Herrero, I.(2005) “Control de blisters mediante visión artificial”, Universidad Nacional de Quilmes, link: <https://docplayer.es/9893222-Aspectos-de-un-sistema-de-vision-artificial.html>
- Islam, R., Henderson, P., Gomrokchi, M., & Precup, D. (2017). Reproducibility of benchmarked deep reinforcement learning tasks for continuous control. arXiv preprint arXiv:1708.04133. <https://doi.org/10.48550/arXiv.1708.04133>
- Jiménez, Y. S. J. (2023). Clasificación automática de estados de madurez de frutas utilizando imágenes hiperespectrales y redes neuronales convolucionales profundas (Rev. Universidad Tecnológica de Pereira). Link: <https://repositorio.utp.edu.co/server/api/core/bitstreams/c8f9312b-cdae-4883-9751-6ae197583135/content>
- Kongaphisith T., François G., Ratri B., Akharapong K., b, Jarupa V. (2020) Determinación del contenido de β caroteno en pulpa de *Musa acuminata* AA (Kluai Khai) en diferentes etapas de maduración y periodo de cosecha en Tailandia. *Rev. Alimentos y Agricultura de los Emiratos*. Enlace: <http://dx.doi.org/10.9755/ejfa.2020.v32.i6.2114>
- Kusuma A., De R. & M. D. Marno. (2018). Tomato Maturity Classification using Naive Bayes Algorithm and Histogram Feature Extraction. *Journal of Applied Intelligent System* (e-ISSN : 2502-9401) Vol. 3 No. 1, link: <https://publikasi2.dinus.ac.id/index.php/jais/article/view/1988/1343>
- Llanos, J., & Bedoya, D., (2019). Caracterización físicoquímicas y morfológicas del Píloro (*Musa acuminata*) producido en zona de Vega y Lomerío en el departamento del caquetá, con el fin de proponer procesos de

- transformación. Florencia. Alimentech. Universidad de Pampiona.
<https://doi.org/10.24054/limentech.v17i2.324>
- Llamas, PM Leronés, R. Medina, E. Zalama y J. Gómez G. Bermejo, (2017)
 “Classification of Architectural Heritage Images Using Deep Learning
 Techniques Ciencias Aplicadas, vol. 7, no.10, págs. 126.
<https://doi.org/10.3390/app7100992>
- Lemenkova, P. (2020). Python libraries matplotlib, seaborn and pandas for
 visualization geo-spatial datasets generated by QGIS. *Analele stiintifice
 ale Universitatii" Alexandru Ioan Cuza" din Iasi-seria Geografie*, 64(1),
 13-32. <https://ssrn.com/abstract=3699706>
- León A., J. P., Espinosa A., M. A., Carvajal R., H. R., & Quezada C., J. (2023).
 Análisis de la producción y comercialización de banano en la provincia de
 El Oro en el periodo 2018-2022. *Ciencia Latina Revista Científica
 Multidisciplinar*, 7(1), 7494-7507.
https://doi.org/10.37811/cl_rcm.v7i1.4981
- Martínez, O., Lapo C., B., Pérez R., J., y Zambrano C., (2015). Mecanismo de
 gelatinización del almidón nativo de banano exportable del Ecuador. *Rev.
 Colomb. Quim.* <https://doi.org/10.15446/rev.colomb.quim.v44n2.55215>
- Martínez, O. Capuñay O., Caucha L., Ruilova M., (2022). Modelo predictivo
 para la mención del estado de madurez de musáceas sp., cultivadas al
 suroeste del Ecuador, usando algoritmos de Machine Learning.
<https://doi.org/10.33262/rmc.v7i2.2809>
- Mera E. S. (2022) aplicaciones pedagógicas del penetrómetro gy-3 en procesos
 de transformación agroindustrial, repositorio Universidad Técnica de
 Cotopaxi, Latacunga. Ecuador. Enlace:
<https://repositorio.utc.edu.ec/bitstream/27000/9429/1/PC-002369.pdf>
- Mise, E. F. (2019). Plan de exportación de banano orito de la hacienda Maria
 Elvira hacia mercado español *Rev. Universidad de Zamorano*: enlace:
<https://bdigital.zamorano.edu/server/api/core/bitstreams/93734e14-4fd4-4b1a-973e-30a2897c339c/content>
- Mohamed E.; & A O'REILLY (2020) *Deep Learning for Vision Systems*.
 Manning Publications Co., ISBN 9781617296192. Enlace:
<https://bit.ly/4dC1Zno>

- Navarro, S. (2022). Keras en Deep Learnin. KeepCoding Bootcamps. Link: <https://keepcoding.io/blog/keras-en-deep-learning/>
- Nieto, B. (2018). Visión Artificial como Alternativa para la Gestión de Calidad en la Comercialización del Banano Cavendish en su Etapa de Post-Cosecha. <https://bit.ly/46KrffR>
- Norma Técnica Ecuatoriana 380- 1985-12, Conservas vegetales. Determinación de sólidos solubles. Método refractómetro. <https://bit.ly/3YCDt1h>
- Paéz, (2012). Caracterización Morfo.agronómica de doce cultivares de Musáceas y evolución a la resistencia de la enfermedad de Sigatoka Negra (*Mycosphaerella F.*) en La Maná, Cotopaxi, Ecuador. Repositorio de la Uteq. Enlace: <https://bit.ly/4fFwYkm>
- Pallo Macias, Y. L. ., Quiñonez Chávez, M. N. ., & Albarrasin Reinoso, M. V. . (2024). Producción y comercialización del baby banano (*Musa acuminata*) en el cantón La Maná. Revista Científica Arbitrada Multidisciplinaria PENTACIENCIAS, 6(1), 142–149. <https://doi.org/10.59169/pentaciencias.v6i1.974>
- Pasato Guanga, A. L. (2022). Control de maduración de aguacate mediante análisis de imagen (Bachelor's thesis, Universidad Técnica de Ambato. Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología. Carrera de Ingeniería en Alimentos). Link: <https://repositorio.uta.edu.ec/jspui/handle/123456789/36078>
- Peñafiel, Y. (2017). Evaluación del efecto del método químico (eritorbato del sodio), físico (escaldado) y el proceso de secado sobre el pardeamiento enzimático y no enzimático de oritos (*Musa acuminata*) AA rebanados Universidad Técnica del Norte]. Repositorio Universidad Técnica del Norte. <https://repositorio.utn.edu.ec/bitstream/123456789/6537/1/03%20EIA%20438%20TRABAJO%20DE%20GRADO.pdf>
- Piñeros Guzmán, J. (2022). Clasificación de la madurez del aguacate Hass para su cosecha mediante una red ANN. Universidad de los Andes. Disponible en: <http://hdl.handle.net/1992/58801>
- Procel, Katherin (2022). La cocina de vanguardia vinculada con la identidad gastronómica de la etnia shuar de ka oarroquia Asunción sucúa-Morona

- Santiago. Riobamba link:
<http://dspace.esPOCH.edu.ec/handle/123456789/19825>
- Porras, J., De la Cruz, M., & Morán, A. (2014). Clasificación system based on computer vision. Escuela Profesional de Ingeniería Electrónica-Universidad Ricardo Palma: <https://bit.ly/4dk5YW0>
- Purwa H. Putra, M. S. Novelan, & M. Rizki. (2022). Analysis K-Nearest Neighbor Method in Classification of Vegetable Quality Based on Color. *Journal of Advanced Engineering and Technology Studies*, 3(2), 126-132 <https://journal.yrpiPKU.com/index.php/jaets/article/download/763/476>
- Rahim Azadnia, Saman Fouladi, Ahmad Jahanbakhshi, (2023). Intelligent detection and waste control of hawthorn fruit based on ripening level using machine vision system and deep learning techniques, *Rev. sciencedirect*, Teherán, Irán ISSN 2590-1230 <https://doi.org/10.1016/j.rineng.2023.100891>.
- Refaeilzadeh, P., & Liu, H. (2009). Cross-validation. *Encyclopedia of databasesystems*, *Encyclopedia of database systems* (Vol. 6). New York: Springer. (5), 532-538 <https://bit.ly/3AguPv4>
- Robinson, J., y Saúco, V. (2012). Plátanos y bananas. España: Ediciones MundiPrensa: <https://bit.ly/4cuYuhO>
- Salau L. & Torres H. (2015). Manejo Poscosecha de Banano Orito (*Musa acuminata*) hasta elcentro de Acopio en Época de Verano en el cantón Bucay, Guayas-Ecuador. link: <https://bit.ly/46KYyZj>
- Saragih, R. E., & Rahardjo Emanuel, A. W. (2021). Banana ripeness classification based on deep learning using convolutional neural network. In 2021 3rd East Indonesia Conference on Computer and Information Technology (EIconCIT) (pp. 85-89). IEEE. Enlace: <https://doi.org/10.1109/EIconCIT50028.2021.9431928>
- Sri, M. Kusuma., Saikrishna, K., & Kumar, V. V. (2020). Classification of ripening of banana fruit using convolutional neural networks. In *Proceedings of the 4th International Conference: Innovative Advancement in Engineering & Technology (IAET)*. <http://dx.doi.org/10.2139/ssrn.3558355>

- Smith, J., D., & White, L. (2020). Post-harvest physiology and storage of bananas. *Journal of Agricultural Science*, 45(3), 123-130. <https://doi.org/10.1016/j.tifs.2023.03.003>
- Sheth, V., Tripathi, U., & Sharma, A. (2022). A comparative analysis of machine learning algorithms for classification purpose. Gujarat, India. *Procedia Computer Science*, 215, 422-431. <https://doi.org/10.1016/j.procs.2022.12.044>
- Sugianti C., T. Imaizumi, M. Thammawong, K. Nakano (2023) Recent Postharvest Technologies in the Banana Supply Chain. *Res. Ciencias Agrícolas*, Yanagido, Hokkaido, Japón Gifu: 501-11993 https://doi.org/10.7831/ras.10.0_123
- Takahiro Matsui and Hiroyuki Sugimori and Shige Koseki and Kento Koyama (2023) Automated detection of internal fruit rot in Hass avocado via deep learning-based semantic segmentation of X-ray images, *Rev. Postharvest Biology and Technology*, Japón. <https://doi.org/10.1016/j.postharvbio.2023.112390>
- Thompson, M., & Johnson, K. (2019). Optimal ripeness stages for banana consumption. *Rev. Food Quality and Preference*, 32(2), pag: 89-07 enlace: <https://link.springer.com/book/10.1007/978-3-030-27739-0>
- T Aditya Sai S. KaifKhan, K. Karthik Reddy, & G. SaiChand. (2024). FromRaw to Refined:Data Preprocessing with Scikit-learn.Recent Trends in Computer Graphics and Multimedia Technolog, DOI: <https://bit.ly/4fJYDk3>
- Torres, R., Montes, E. J., Pérez, O. A., & Andrade, R. D. (2013). Relación del color y del estado de madurez con las propiedades fisicoquímicas de frutas tropicales. *Información tecnológica*, 24(3), 51-56. <https://dx.doi.org/10.4067/S0718-07642013000300007>
- Trung W. Le, F. Maleki, F. Perdigón R., Reza F., Samuel K.,(2020) Overview of Machine Learning: Part 2: Deep Learning for Medical Image Analysis, *Neuroimaging Clinics of North America*,Volume 30, Issue 4 doi:<https://doi.org/10.1016/j.nic.2020.06.003>
- Varga, Leon Amadeus; Makowski, J. y ZELL, Andreas (2021). Measuring the Ripeness of Fruit with Hyperspectral Imaging and Deep Learning, *Rev*

International joint Neural Network, enlace:
<https://doi.org/10.1109/IJCNN52387.2021.9533728>

- Vivanco Castro, J. S. (2018). Implementación de algoritmos de clasificación con Deep Learning a través del uso de la librería TensorFlow (Bachelor's thesis). Enlace: <http://dspace.utpl.edu.ec/handle/20.500.11962/23604>
- Villalba, A., Requena, T., Solanilla, F., & Rangel, J. (2021). Prototipo de un sistema que determine el estado de madurez de un plátano utilizando Deep Learning y Visión Artificial. *Revista De Iniciación Científica*, 6, 49-53. <https://doi.org/10.33412/rev-ric.v6.0.3155>
- Van der Walt, S. C. Colbert, and G. Varoquaux, (2011)“The NumPy Array: A Structure for Efficient Numerical Computation,” *Comput. Sci. Eng.*, vol. 13, no. 2, pp. 22–30. <https://doi.org/10.1109/MCSE.2011.37>
- Verma A., R. Hegadi and K. Sahu, (2015). Development of an effective system for remote monitoring of banana ripening process," 2015 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE) Dhaka, Bangladesh, 2015, pp. 534-537, doi: 10.1109/WIECON-ECE.2015.7443987
- Zhiminaicela Cabrera, J. B., Quevedo Guerrero, J. N., & García Batista, R. M. (2020). La producción de banano en la Provincial de El Oro y su impacto en la agrobiodiversidad. *Revista Metropolitana de Ciencias Aplicadas*, 3(3), 189-195. link <https://www.redalyc.org/pdf/7217/721778107024.pdf>

ANEXOS

Anexo 1 Racimo de banano orito para evaluar la maduración visualmente



Anexo 2 Proceso de preparación de muestras del banano orito para análisis de propiedades fisicoquímicas en laboratorio



Anexo 3 Equipos utilizados para la evaluación de parámetros fisicoquímicas en el banano orito



Anexo 4 Medición de la firmeza del banano orito mediante penetrómetro en análisis de textura



Anexo 5 Equipo fotográfico utilizado para la documentación diaria de procedimientos experimentales



Anexo 6 Procedimiento de preparación y pesaje de muestra para determinación de acidez titulable



Anexo 7 Determinación de acidez titulable

