



**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

TÍTULO:

**Optimización de las exportaciones de banano ecuatorianas mediante un
clasificador basado en redes neuronales**

AUTORAS:

Bravo Mero, Josselyn Camilla

Riofrio Cedeño, María José

**Trabajo de Integración curricular previo a la obtención de título de
LICENCIADO EN NEGOCIOS INTERNACIONALES**

TUTOR:

Ing. Carrera Buri, Félix Miguel, Mgs.

Guayaquil, Ecuador

9 de febrero del 2024



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL

FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES

CERTIFICACIÓN

Certificamos que el presente trabajo de integración curricular fue realizado en su totalidad por **Bravo Mero, Josselyn Camilla y Riofrio Cedeño, María José**, como requerimiento para la obtención del título de **Licenciados en Negocios Internacionales**

TUTOR (A)

f. _____
Ing. Carrera Buri, Félix Miguel, Mgs.

DIRECTORA DE LA CARRERA

f. _____
Ing. Hurtado Cevallos, Gabriela Elizabeth, Mgs.

Guayaquil, a los 09 del mes de febrero del año 2024



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL

FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES

DECLARACIÓN DE RESPONSABILIDAD

Nosotras, **Bravo Mero, Josselyn Camilla y Riofrio Cedeño, María José**


DECLARAMOS QUE:

El Trabajo de Integración Curricular, **Optimización de las exportaciones de banano ecuatorianas mediante un clasificador basado en redes neuronales**, previo a la obtención del título de **Licenciadas en Negocios Internacionales**, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría.


En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

Guayaquil, a los 09 del mes de febrero del año 2024

LAS AUTORAS:

f. 

Bravo Mero, Josselyn Camilla

f. 

Riofrio Cedeño, María José



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL

FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES


AUTORIZACIÓN

Nosotras, **Bravo Mero, Josselyn Camilla y Riofrio Cedeño, María José**


Autorizamos a la Universidad Católica de Santiago de Guayaquil a la **publicación** en la biblioteca de la institución del Trabajo de Integración Curricular, **Optimización de las exportaciones de banano ecuatorianas mediante un clasificador basado en redes neuronales**, cuyo contenido, ideas y criterios son de mi exclusiva responsabilidad y total autoría.

Guayaquil, a los 09 del mes de febrero del año 2024

LOS AUTORES:

f. 

Bravo Mero, Josselyn Camilla

f. 

Riofrio Cedeño, María José



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES

REPORTE COMPILATIO

CERTIFICADO DE ANÁLISIS
magister

Tesis Final Josselyn Bravo Mero - María Ríofrio Cedeño (1)

0% Textos sospechosos

< 1% Similitudes (ignorado)
0% similitudes entre conxillas (ignorado)
0% entre las fuentes mencionadas (ignorado)
4% Idioma no reconocido (ignorado)

Nombre del documento: Tesis Final Josselyn Bravo Mero - María Ríofrio Cedeño (1).docx
ID del documento: c1d6d133b8a49d9d8c4a913225ed4e57edfe8749
Tamaño del documento original: 3,01 MB

Depositante: Félix Miguel Carrera Buri
Fecha de depósito: 26/1/2024
Tipo de carga: interfase
fecha de fin de análisis: 26/1/2024

Número de palabras: 18.474
Número de caracteres: 123.715

Ubicación de las similitudes en el documento:

Fuentes principales detectadas

N°	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	Documento de otro usuario #d958d El documento proviene de otro grupo 2 fuentes similares	1%		Palabras idénticas: 1% (280 palabras)
2	TESIS ANALISIS DE LAS ESTRATEGIAS COMERCIALES REVISIÓN 9.07.docx ... #s3092c El documento proviene de mi grupo 27 fuentes similares	1%		Palabras idénticas: 1% (182 palabras)
3	repositorio.ucsg.edu.ec http://repositorio.ucsg.edu.ec/handle/ucsg/3317/3365/3/T-UCSG-PRF-MED-634.pdf.us 40 fuentes similares	1%		Palabras idénticas: 1% (195 palabras)
4	Fernando Rivadeneira y Johan Castells_AVANCE.docx Fernando Rivadeneira... #6c8d8f El documento proviene de mi grupo 20 fuentes similares	1%		Palabras idénticas: 1% (179 palabras)
5	repositorio.ucsg.edu.ec http://repositorio.ucsg.edu.ec/bitstream/38117/1817/1/UCSG-PRF-ESP-CH-628.pdf.pdf 20 fuentes similares	< 1%		Palabras idénticas: < 1% (170 palabras)

Ing. Carrera Buri, Félix Miguel, Mgs.

AGRADECIMIENTO

Con total alegría quiero dedicar el presente trabajo a todas aquellas personas que han formado parte de mi vida:

En primer lugar, quiero agradecer a Dios por permitirme compartir este logro con mi familia y amigos. Él que siempre me ha demostrado que hay un camino en medio de la oscuridad y quien me dio fuerzas para nunca rendirme.

A mis padres, Elsa Elizabeth Mero Barberán y Colón Alberto Bravo Cruz, que han sido mis pilares y mi inspiración. A mi madre, que es mi mejor amiga con un amor incondicional y paciente, que me ha demostrado que uno es capaz de lograrlo todo con la mano de Dios. A mi padre, quien es mi héroe favorito con un carácter fuerte y que vela siempre por la seguridad de sus seres queridos, que siempre me guía en el camino de Dios y que me enseña siempre a ser fuerte.

A mi hermano Michael Ibrahim Bravo Mero, quien es mi cómplice en la vida, agradeciéndole su compañía, orgullosa siempre de él y que espero ser una buena hermana mayor a sus ojos a pesar de todos mis errores y tropiezos.

A mi querida familia en mis amados hogares que día a día me acompañan, gracias por brindarme su entendimiento, su paciencia, una sonrisa, un abrazo, un todo estará bien, esas palabras de aliento que me permitieron reír cuando solo quería llorar. Ustedes, abuelos, abuelas, tíos, tías, primas, primos, padrinos, madrinas, mis mascotas gracias por darme un gran hogar en donde me siento segura.

A mis queridas amigas y amigos, empezando con mi compañera con la que

comparto este proyecto, gracias por siempre ser mi copiloto en esta aventura que se llama universidad, a mis amigos del colegio que creyeron en mí y me brindaron su sincera amistad y locura que aprecio con toda mi alma, a mis amigos y compañeros de la universidad con quienes he pasado grandes momentos y muchas batallas, espero que Dios siempre les brinden muchas bendiciones y a los amigos que he ido haciendo en el camino, les agradezco por dejarme entrar a sus vidas y aprender de ustedes.

A mis distinguidos profesores y asesoras, quienes han sembrado en mí, esa semilla de la curiosidad, a todos aquellos que tomaron su preciado tiempo para mi enseñanza, para escucharme y aconsejarme, les agradezco por su paciencia y su amor a la docencia.

A mi tutor de tesis, usted quien me ofreció el apoyo y las herramientas para mi desarrollo académico, le agradezco su confianza.

A todas las personas que Dios me ha permitido conocer y que han influido en mi crecimiento personal y profesional, les agradezco por su existencia. Este éxito es de todos nosotros.

- *Bravo Mero, Josselyn Camilla*

AGRADECIMIENTO

En primer lugar, doy gracias a Dios por brindarme salud, permitirme vivir esta experiencia universitaria con buenos recuerdos y de allí haber conocido muy buenos amigos, además de poder desarrollarme profesionalmente en una carrera que me apasiona y de la que espero seguir aprendiendo mucho más. Agradezco a toda mi familia a quienes están físicamente y a quienes no, por la fuerza y el apoyo brindado en todo este proceso que con toda seguridad sin todos ellos no lo hubiese podido lograr, gracias por los sabios consejos, la ayuda, en especial a aquellos quienes estuvieron conmigo en los momentos más significativos para mí en esto incluyo también a todas mis mascotas que son parte fundamental en mi vida Hachiko, Ares, Apolo, Armando y Mora. Y para finalizar con mucho cariño agradezco a todas las autoridades de la Universidad Católica de Santiago de Guayaquil por la paciencia en mi formación académica y a mis compañeros Josselyn Camilla Bravo, Alejandra Abad y Bryan Arcos por su apoyo moral y compañerismo puesto que han apartado en un alto porcentaje a que este proceso se sienta más liviano a estos también les agradezco la confianza y paciencia que me regalaron, gracias por todas las experiencias vividas juntos.

- Riofrio Cedeño, María José

DEDICATORIA

Este trabajo se lo dedico a mis padres, por su esfuerzo continuo en sus hijos, mi hermano quien le da color a mi vida, mi amada familia quienes me han visto crecer, mis amigos que son mis hermanos de otra sangre, docentes, asesores, profesores particulares que en toda mi vida me han inculcado a superarme. A mis seres queridos que, a pesar de no estar aquí presentes, sé que están en el Cielo cuidándonos, espero hacerles sentir orgullosos del camino que he escogido. Del mismo modo, quiero dedicar este trabajo a esa niña asustadiza que no sabía si sus esfuerzos estaban dando frutos, quiero demostrarle que, con fe, paciencia y el apoyo de todos sus seres queridos, lo imposible se vuelve posible. Recordarle siempre que el momento más oscuro es aquel justo antes del amanecer.

- *Bravo Mero, Josselyn Camilla*

DEDICATORIA

Se lo dedico a mi mamá quien, a pesar de no estar físicamente, continua presente como parte de mis motivos para continuar en esta carrera, gracias por sus ánimos que con todo el amor de madre me brindaba, a su vez a mi hermana Mariuxi Riofrío, mujer a la que admiro y me llena de orgullo, a quien considero mi segunda madre por todo el cariño, amor y ser un soporte inmenso en mi vida, que jamás me ha permitido vencerme en todas las circunstancias que he pasado. Finalmente, a mi pareja Jandry Rodríguez quien considero parte de mi familia y estuvo en cada momento de esta carrera alentándome a continuar, enseñarme tantas cosas y dar lo mejor de mí siempre.

- Riofrío Cedeño, María José



**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

TRIBUNAL DE SUSTENTACIÓN

f. _____

Ing. Hurtado Cevallos, Gabriela Elizabeth, Mgs.
DIRECTORA DE CARRERA

f. _____

COORDINADOR DEL ÁREA

f. _____

OPONENTE



**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

CALIFICACIÓN

Bravo Mero, Josselyn Camilla

Riofrio Cedeño, María José

Índice

<i>Introducción</i>	2
<i>Problemática</i>	5
<i>Justificación</i>	8
<i>Alcance</i>	10
<i>Objetivos</i>	10
Objetivo General	10
Objetivos Específicos	11
<i>Preguntas de Investigación</i>	11
<i>Capítulo I: Fundamentación Teórica</i>	12
<i>Marco Teórico</i>	12
El banano como producto exportable	12
Factores que afectan a la producción del banano	13
Inteligencia Artificial	15
Machine Learning	16
Redes Neuronales Artificiales	19
Arquitecturas basadas en el cerebro	21
Tipos de Redes Neuronales Artificiales	21
Red Neuronal Monocapa.	21
Red Neuronal Multicapa.	22
Red Neuronal Recurrente.	23
Modelos de Redes Neuronales Artificiales	24
El Perceptrón	24
Adaline – Madaline	26
Redes Neuronales Convolucionales	28
Las curvas ROC	29
Punto de corte que determina la sensibilidad y la especificidad más altas	29
Comparar la capacidad discriminativa de 2 o más test diagnósticos	30
<i>Marco conceptual</i>	30
Exportación de banano	30
Machine Learning	31
Algoritmos de Machine Learning	32
Inteligencia Artificial	37
<i>Marco Legal</i>	38
<i>Capítulo II</i>	39
<i>Metodología</i>	39

Metodología en el programa R studio.	40
Instalación y carga de paquetes	40
Análisis de los Valores Faltantes o “NAS” en las variables	41
Semilla	43
<i>Capítulo III</i>	46
<i>Análisis de los Resultados</i>	46
<i>Conclusiones</i>	53
<i>Referencias Bibliográficas</i>	57
<i>Anexos</i>	64
Script completo R studio	65
Muestra de las observaciones	67

Índice de Tablas

<i>Tabla 1</i>	2
<i>Tabla 2</i>	3
<i>Tabla 3</i>	18
<i>Tabla 4</i>	34
<i>Tabla 5</i>	53

Índice de Figuras

<i>Figura 1</i>	4
<i>Figura 2</i>	20
<i>Figura 3</i>	21
<i>Figura 4</i>	21
<i>Figura 5</i>	22
<i>Figura 6</i>	23
<i>Figura 7</i>	24
<i>Figura 8</i>	25
<i>Figura 9</i>	26
<i>Figura 10</i>	27
<i>Figura 11</i>	39
<i>Figura 12</i>	42
<i>Figura 13</i>	44
<i>Figura 14</i>	47
<i>Figura 15</i>	48
<i>Figura 16</i>	49
<i>Figura 17</i>	50
<i>Figura 18</i>	50
<i>Figura 19</i>	51
<i>Figura 20</i>	52
<i>Figura 21</i>	64

RESUMEN

Las exportaciones son parte esencial para el crecimiento del país en la actualidad, donde la innovación y la automatización de procesos con el uso del análisis de datos es una herramienta eficaz para mejorar la clasificación de los productos identificando las variables claves que influyen directamente. No obstante, el entendimiento y la utilización de conceptos de inteligencia artificial, como lo son las redes neuronales artificiales para la clasificación siguen siendo un desafío, esto porque es un proceso complejo y que se está desarrollando e innovando periódicamente. Pese a estos desafíos, es fundamental que las empresas vayan adaptando sus procesos a esta nueva era de la digitalización para poder desarrollar una ventaja competitiva. La clasificación de los productos y la identificación de las variables que afectan en su exportación son primordiales, debido a que permiten a las empresas adoptar nuevas estrategias para la producción de los productos. La presente investigación se enfoca en el desarrollo de un modelo de redes neuronales artificiales para la clasificación de bananos ecuatorianos para la exportación, en el cual se espera lograr un mínimo error en la predicción de clasificación de los tipos de banano. El objetivo es determinar cuáles son las variables que afectan directamente a la exportación del banano. La aplicación de las redes neuronales artificiales para la clasificación se justifica debido a que este sector es una de las principales industriales en la economía de nuestro país.

Palabras Claves:

Innovación, Análisis de datos, Inteligencia Artificial, Redes Neuronales Artificiales para la clasificación, Exportaciones, Banano.

ABSTRACT

Exports are an essential part of the country's growth today, where innovation and process automation with the use of data analysis is an effective tool to improve the classification of products by identifying the key variables that directly influence them. However, the understanding and use of artificial intelligence concepts such as artificial neural networks for classification remains a challenge because it is a complex process that is regularly being developed and innovated. Despite these challenges, it is essential for companies to adapt their processes to this new era of digitalisation in order to develop a competitive advantage. The classification of products and the identification of the variables that affect their export are essential, as they allow companies to adopt new strategies for the production of products. This research focuses on the development of an artificial neural network model for the classification of Ecuadorian bananas for export, in which it is hoped to achieve a minimum error in the prediction of the classification of banana types. The objective is to determine which variables directly affect banana exports. The application of artificial neural networks for classification is justified because this sector is one of the main industries in the economy of our country.

Keywords:

Innovation, Data analysis, Artificial Intelligence, Artificial Neural Networks for sorting, Exports, Bananas.

RÉSUMÉ

Les exportations sont aujourd'hui un élément essentiel de la croissance du pays, où l'innovation et l'automatisation des processus avec l'utilisation de l'analyse des données est un outil efficace pour améliorer la classification des produits en identifiant les variables clés qui les influencent directement. Cependant, la compréhension et l'utilisation de concepts d'intelligence artificielle tels que les réseaux neuronaux artificiels pour la classification restent un défi car il s'agit d'un processus complexe qui fait régulièrement l'objet de développements et d'innovations. Malgré ces défis, il est essentiel pour les entreprises d'adapter leurs processus à cette nouvelle ère de numérisation afin de développer un avantage concurrentiel. La classification des produits et l'identification des variables qui affectent leur exportation sont essentielles, car elles permettent aux entreprises d'adopter de nouvelles stratégies pour la production de produits. Cette recherche se concentre sur le développement d'un modèle de réseau neuronal artificiel pour la classification des bananes équatoriennes destinées à l'exportation, dans lequel on espère obtenir une erreur minimale dans la prédiction de la classification des types de bananes. L'objectif est de déterminer les variables qui affectent directement les exportations de bananes. L'application des réseaux neuronaux artificiels pour la classification se justifie par le fait que ce secteur est l'une des principales industries de l'économie de notre pays.

Mots-clés:

Innovation, Analyse de données, Intelligence artificielle, Réseaux neuronaux artificiels pour le triage, Les exportations, Les bananes.

Introducción

El origen del banano nace en el continente asiático meridional y es conocido desde el año 650 D.C. (Después de Cristo), para el año 1516 fue trasladado a las Américas. Dentro de la variedad de bananos conocidos, tenemos el Groz Michel siendo paulatinamente reemplazada por el banano tipo Cavendish el cual se divide en subgrupos como Gran Enano, Lacatan Robusta y Valery; por otro lado tenemos plátano enano o domicilio, plátano guineo, plátano rojo los cuales son cultivados principalmente en países del región asiática como Kenia, India, Tailandia, Malasia; de ahí en Europa como las Islas Canarias; América; Ecuador, Colombia, Brasil; África Occidental, Ivory Coast.

Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) hasta el cierre del 2021 el volumen de las importaciones netas mundiales de bananos se contrajo un 2,7% en 2021, una disminución de 550.000 toneladas en comparación con el año anterior, situándose en unos 19,5 millones de toneladas, esta sustancial reducción se debió a la diferentes de restricciones postpandemia y costos más altos en la cadena de suministro mundiales.

El banano es uno de los principales productos agrícolas producidos principalmente de regiones tropicales. Según López (2017) en las últimas décadas los mayores exportadores de la fruta son Ecuador, Filipinas y Costa Rica. Como observamos en la Tabla 1 y en la Tabla 2, los principales países importadores y exportadores respectivamente en el año 2021.

Tabla 1

Principales países importadores de banano en el 2021

Principales países importadores de banano a nivel mundial en el 2021		
País	Porcentaje	Valor
Estados Unidos	17.9%	\$2.44 MM
China	8.35%	\$1.14 MM
Japón	6.25%	\$852 M
Alemania	5.87%	\$801 M
Rusia	5.49%	\$748 M

Nota: Tabla elaborada a partir de información recopilada del The Observatory of Economic Complexity [OEC] (2017 - 2021)

Por el lado de las exportaciones de banano alrededor del mundo según los datos disponibles por la FAO tuvieron una significativa reducción de 7,8% para finales del 2021 llegando a la ubicarse en unos 20,5 millones de toneladas donde casi todos los principales exportadores de la fruta experimentaron también esta disminución, a esto hay que añadirle el alza importante de los fertilizantes requeridos para la siembra y cosecha de la fruta.

Tabla 2

Principales países exportadores de banano en el 2021

Principales países exportadores de banano a nivel mundial en el 2021		
País	Porcentaje	Valor
Ecuador	26.9%	\$3.67 MM
Filipinas	10.9%	\$1.49 MM
Costa Rica	9.04%	\$1.23 M
Colombia	7.84%	\$1.07 M
Guatemala	7.34%	\$1.01 M

Nota: Tabla elaborada a partir de información recopilada del The Observatory of Economic Complexity [OEC] (2017 - 2021)

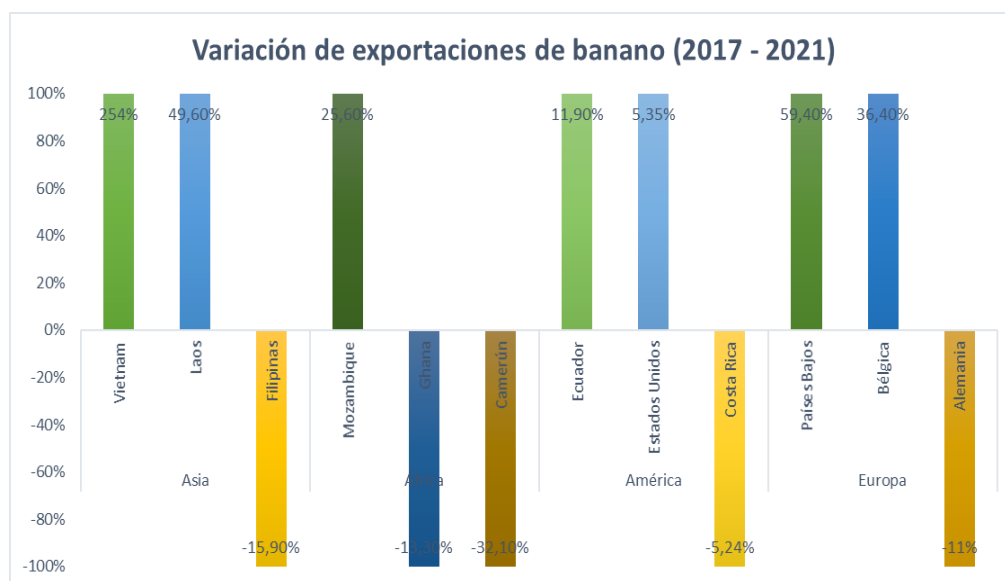
Según Suárez (2019) el banano es un alimento fundamental, considerado como uno de los cultivos alimentarios que tienen una gran importancia, por ende, se posiciona como un producto de exportación. Con lo antes mencionado, podemos asegurar que el banano posee muchas propiedades que ayudan a las personas y que, por tanto, es una de las frutas mayor exportadas.

El banano se ubica entre los principales productos agrícolas, es destacable el hecho de que los países importadores más importantes de los últimos años son Estados Unidos, Alemania y Bélgica (López, 2017).

En la Figura 1, observamos una comparación por continente como ha variado el crecimiento del valor de los principales exportadores de banano entre los años 2017 a 2021.

Figura 1

Variaciones de exportaciones de banano



Nota: Adaptado con datos proporcionados por The Observatory of Economic Complexity [OEC] (2017 - 2021)

Al observar la Figura 1, observamos la variación de los principales países exportadores por continente. Al analizar el primer continente en Asia, observamos un porcentaje curioso, a pesar de que Filipinas es uno de los principales exportadores a nivel mundial, observamos un decrecimiento de -15.90%, en el 2017 su valor era de \$1.77 MM y en el 2021 fue de \$1.49 MM. Asimismo con África, existen pocos países con una variación positiva como es el caso de Mozambique cuya variación fue de 25.60%. Cabe mencionar que América y Asia se encuentran como los países con más concentración en sus exportaciones de banano. Con respecto al primero, Ecuador y Estados Unidos tienen una variación positiva, siendo estos de América del Norte y América del Sur. No obstante, con respecto a Costa Rica, país de Centroamérica tiene una variación negativa con un -5.24%. Finalmente, con respecto a Europa, tenemos a Países Bajos con una variación enorme en sus exportaciones bananeras, en donde observamos un excelente crecimiento. Sin embargo, no es lo mismo con Alemania, al ser un país más frío, ha bajado sus exportaciones en un -11%.

En el año de 1910 Ecuador comienza a exportar donde no se usaba cajas o algún sistema de medición exacto, solo se hacía un conteo por racimo los cuales tenían un peso aproximado a un quintal, al día de hoy, las hectáreas sembradas de banano sobrepasan las 200

mil, en la Costa con el 81%, Sierra 16% y Oriente 3%. El comercio del banano representa aproximadamente el 20% del Producto Interno Bruto (PIB) (León et al., 2018).

La exportación de banano es una de las principales actividades económicas realizadas por las provincias del El Oro, Guayas, Esmeraldas, Los Ríos, y en los valles cálidos de la Sierra de Loja y Cañar, el comercio del banano representa para el país el segundo mayor ingreso hacia la economía ecuatoriana por ende contribuye con el desarrollo económico del país. Ecuador tiene alrededor de 162.236 hectáreas sembradas de Banano y cuenta con 4.473 productores de la fruta, por lo que solo el 78% de los productores bananeros son representados por grandes empresas, las medianas 18%, y las pequeñas empresas el 4% (Ministerio de Comercio Exterior, 2017).

Debido a la creciente tendencia de un estilo de vida más saludable o por dos factores fundamentales tales como, el aumento de la población y el aspecto nutricional ya que posee altos niveles de fibra, vitamina A, C, vitamina B6, elementos que son fuente de energía que brinda a se prevé que aumente la demanda del banano hasta julio del 2023 con un 6,4% en comparación con el mismo periodo del año 2022.

Problemática

Ecuador se ha caracterizado por ser un país en vías de desarrollo, en el cual depende mucho o en su mayoría de las exportaciones de petróleo (Ácaro-Chamba et al., 2021). No obstante, Ecuador también es altamente conocido por sus exportaciones de banano, esto debido a que posee ciertos factores que posibilitan competir en este sector, permitiendo darle una participación en el comercio mundial que siempre va en aumento.

Dado que Ecuador es un país subdesarrollado, esta producción de banano se considera como una actividad altamente rentable debido a que es más solicitada en países desarrollados y que se caracterizan más por productos no alimentarios.

Considerando el gran papel que tiene el sector bananero sobre la economía ecuatoriana y que su presencia en el nivel de exportaciones nacionales se va asemejando a las exportaciones petroleras (Coba, 2022), podemos acotar que es indispensable que mejore el proceso productivo y operativo del banano; y en caso de un incremento de su demanda se deberá aumentar la competitividad en la industria y, por ende, un elevado nivel de calidad, así como de servicio y así el producto tenga rentabilidad en el mercado.

Actualmente los controles de calidad en la producción y exportación de banano son cada vez más rigurosos debido a la creciente tendencia por un consumo de producto más saludable que no esté sobrecargado de fungicidas y preservantes, los cuales deterioran el aspecto nutricional y el tiempo de vida útil de la fruta, por ende los pequeños y medianos agricultores necesitan optimizar cada vez más el proceso de clasificación del banano puesto que con el procedimiento actual se puede llegar a perder mucho tiempo.

Pueden existir muchos aspectos por los cuales se hace una pérdida de tiempo, por ejemplo, debido a que luego de que los bananos sean cosechados se procede a lavar, desinfectar, se le colocan los respectivos sellos a las frutas, se los pesan para luego pasar a ser organizados por clústeres de 4 hileras, a lo largo de este proceso muchos racimos de bananos se pueden perder debido a las condiciones en las que puede trasladado en cada punto del proceso por lo que entonces no se estaría aprovechando la cosecha en su totalidad puesto que el factor del tiempo de maduración estaría afectando significativamente (Vásquez-Castillo et al., 2019).

La maduración del banano da como resultado un grupo de cambios físicos, químicos y biológicos, que conllevan a la formación de un fruto propicio para el consumo humano.

El proceso de maduración se da debido a un aumento de la respiración del banano, síntesis y liberación de etileno, degradación del almidón y ácidos grasos, otorgando sabor y olor característico del fruto maduro. Cuando la fruta empieza a madurar viene el proceso de degradación oxidativa donde la pared celular que la recubre se vuelve más permeable lo que afecta la textura y sabor de la fruta, debido a la pérdida de compuestos, este proceso ocurre por el etileno que activa las enzimas hidrolíticas como la poligalacturonasa y celulasa, que rompe los enlaces entre polisacáridos, este proceso causaría que el banano pierda las características óptimas para su exportación ya que no llegaría en buenas condiciones a su lugar de destino (Martínez-González et al., 2017).

Por ende, y a causa del aumento en la demanda de esta fruta en los últimos años es importante el uso de algún concepto que nos permita optimizar este proceso sin generar gran cantidad de desperdicios.

Un cuestionamiento clave radica en la maduración del banano, la pronta maduración del banano sería una grave consecuencia para la producción, puesto que, se entra en una desprogramación del tiempo estimado en las cámaras frigoríficas, y si entra el banano con alto grado de madurez, esto podría dificultar la comercialización a los diversos países, esto depende de cuál es su área de origen, puesto que Ecuador se caracteriza por tener altas variedades de clima, principalmente en la Costa, Sierra y El Oriente.

Por lo que, su origen y su transportación puede resultar cambiantes y desafiantes, factores como posibles fallos o errores humanos en el proceso de recolección del banano puede generar pérdida del producto para la exportación o venta de consumo interno.

Debido al entorno más cambiante en el que nos encontramos, un entorno empresarial dinámico, en donde la innovación y la tecnología son piezas claves en el crecimiento de las exportaciones mejorando el desarrollo económico de los países. Estas regiones necesitan considerar los patrones de sus exportaciones, examinar el producto, evaluar los lugares de destino, la innovación en los procesos, entre otros (Díaz Muñoz et al., 2021).

Por lo que podemos recalcar que en nuestro entorno actual se requiere un análisis exhaustivo de los datos relacionados con el banano. Esta tarea es inherentemente compleja y consume tiempo y recursos significativos. Por lo tanto, surge la necesidad imperante de automatizar el proceso de clasificación de las exportaciones de banano.

Asimismo, dado a los continuos factores ambientales cambiantes que se han venido presentando en los últimos años la producción de banano se ha visto afectada, el aumento de temperatura del suelo ha traído consigo sequías frecuentes y mayor proliferación de plagas en los cultivos que principalmente afecta a zonas bananeras como la Cuenca del Amazonas y América Central (Gálvez, 2017).

A su vez, el aumento de temperatura también podría volverse una desventaja competitiva dentro de la industria debido a que podría adecuar zonas que antes no cumplían con las características necesarias para la producción de esta fruta, además de las dificultades que vendría presentando Ecuador en otros entornos, por ejemplo, en los últimos años se ha presentado una elevada deuda externa, altos niveles de inflación, gran dependencia del sector primario, elevado apalancamiento del sector, rezago en apoyo e investigación.

El sobre calentamiento de los suelos imposibilitaba muchas zonas del Ecuador encargadas de la producción del banano, como también causan problemas en la transportación y por ende en el tiempo de maduración de las frutas (Elbehri et al., 2015). Debido a que, al ser productos altamente solicitados, siempre se realizan cargas masivas y estas deben llegar en el tiempo preciso dependiendo del tipo de banano que se vaya a producir. Cada caja de bananos tiene diferentes características que deben ser respetadas para que, de este modo, no se pierda la cosecha y se pueda aprovechar al máximo sus beneficios.

Justificación

Se realiza este trabajo de investigación con el fin de analizar y clasificar las cajas de banano que el Ecuador exporta y permitir una mejoría en el proceso de clasificación para aprovechar toda la cosecha, tomando en consideración su tiempo de maduración para que los bananos que se quedan como consumo nacional puedan ser exportarlos y que Ecuador pueda aportar más en el comercio internacional.

Según Acosta Palomeque et al., (2018) el comercio internacional no solo genera mayor crecimiento económico, del mismo modo, ayuda a que los países promuevan mejoras en los procesos de producción, dando como resultado una mejora en su competitividad.

Nuestro país, Ecuador, cuenta con un suelo fértil que ha permitido brindarle al fruto características propias como un intenso y dulce sabor, permitiendo que varias empresas inviertan en la producción de este alimento.

Sin embargo, Ecuador se ha visto afectado por razones internas y externas su producción de banano. Por lo que, se ha visto necesario analizar las causas que afectan que una parte de este producto no pueda ser exportado.

Cabe mencionar que, en los últimos años, a pesar de que Ecuador sigue encabezando en la lista de los mayores exportadores, igualmente se ha contemplado una bajada en su exportación, esto se debe a diversos factores políticos, ambientales y culturales (Calderón et al., 2016). Es por eso que los productores ecuatorianos han centrado sus esfuerzos para mejorar su competitividad en el sector internacional, implementando nuevos métodos que ayudarán en la producción del banano.

En esta investigación se hará uso de las redes neuronales artificiales para poder mejorar esta situación con la producción del banano que se queda estancado en el Ecuador y que por fallas en un proceso que se lo maneja aun manualmente y no automatizado no han podido ser objeto de exportación, por ende, causando pérdidas en ingresos que podrían aportar a Ecuador a tener un mayor reconocimiento mundial en este producto.

La aplicación de las redes neuronales artificiales acorde a las exigencias de Ecuador se ve justificado debido al continuo crecimiento de las exportaciones de banano, por lo cual es necesario una mejora en sus procesos de producción, permitiendo aprovechar al máximo las cosechas y generar rentabilidad. Mediante el uso de la Inteligencia artificial se logra minimizar o en algunos casos si es aplicada correctamente, eliminar los riesgos que se puedan presentar en distintos escenarios de la producción, donde el producto será clasificando acorde

al tiempo de maduración, facilitando el transporte oportuno, eliminando de toda manera el riesgo de pérdida del producto.

Esto debido a que todos los clústeres de banano en el sector agroindustrial ecuatoriano que no son exportados son considerados grado B o de rechazo y son utilizados para su venta nacional u otras preparaciones a base de banano (Ramírez y Solórzano, 2012).

Muchas empresas dedicadas a este sector han implementado mecanismos de mejora en sus procesos de producción. Una empresa, la cual está relacionada con la mecanización de las actividades de cortado y otras actividades de racimos de banano, donde muchas de las tareas son hechas manualmente y con la aplicación de nuevos procesos automatizados les han generado mejores resultados (Arreaga, 2020).

Por lo que empresas como esta, están obligadas a mejorar sus procesos de producción para que se pueda aprovechar todo el producto y no genere pérdidas en la compañía. Estos mecanismos muchas veces son mediante la Inteligencia Artificial o modelos de gestión.

Según Gutiérrez-Rosas et al., (2012), las redes neuronales artificiales han predominado su uso en el campo de las exportaciones con la detección de patrones para medir y reconocer la calidad de productos manufacturados.

Es decir, con un oportuno análisis de datos es mucho más sencillo comprobar cuando es el mejor momento para poder incrementar la producción de un tipo en específico, cesar la producción de otro tipo de banano, permitiendo enfocarnos en tareas particulares que necesitan ser atendidas.

Dentro de este entorno globalizado y competitivo la innovación de los procesos productivos es un factor clave para la ventaja competitiva además de ser una forma para reducir costos, las redes neuronales artificiales ayudan a su vez a planificar estrategias operativas debido a que también podrían detectar comportamientos atípicos en el mercado y su entorno a su vez estimar riesgos por cambios en diferentes factores lo que nos ayudará a prevenir posibles pérdidas, en este caso preciso, planes adaptables a posibles alteraciones climáticas.

En resumen, la aplicación de las redes neuronales artificiales es fundamental en los procesos de optimización de producción, para mejorar la economía del país junto con el crecimiento en el comercio internacional.

Alcance

Este proyecto investigativo va dirigido hacia empresas exportadoras de productos agrícolas, con el objetivo de dar a conocer los conceptos de la inteligencia de negocios y las redes neuronales junto a sus beneficios; permitiéndoles implementar procesos automatizados en cuyas actividades aún posean sistemas realizados manualmente, causando un inconveniente en el crecimiento y proceso de los productos.

Cabe añadir que con esta investigación se espera que sirva de guía de aprendizaje para aquellos profesionales interesados en lo que puede ofrecer el Business Intelligence de la mano con las redes neuronales, proporcionando mejoras en el entorno de trabajo.

Este es un mundo globalizado, en donde las personas que dominen y pongan en práctica estos conceptos serán las personas más aptas para competir en el mundo laboral, otorgándoles una ventaja competitiva con respecto a los demás, aprovechando al máximo estos conocimientos y permitir el mejor rendimiento de las empresas exportadoras.

La adaptación de modelos de inteligencia artificial nos puede ayudar en los procesos de control de la calidad del banano, específicamente en su tiempo de maduración, posibilitando un análisis eficaz y resultados que nos permitan tomar acciones necesarias para mejorar los procesos.

Al observar ejemplos de aquellas empresas que han encontrado o modificado nuevas maneras de automatizar los procesos, con respecto a la clasificación permite su correcta evaluación.

Por ejemplo, una empresa que ha sabido reconocer áreas para mejorar en el área de la agricultura enfocados en la calidad del producto que presentaron el desarrollo de un sistema automatización y gestión de la información en una línea de producción de banano (Parra, 2018).

Objetivos

Objetivo General

- Ejecutar un modelo basado en redes neuronales artificiales para la clasificación de bananos ecuatorianos para la exportación.

Objetivos Específicos

1. Analizar los conceptos y las teorías del uso de las redes neuronales artificiales en la clasificación de los diferentes tipos de bananos mediante la revisión de literatura exhaustiva.
2. Aplicar la metodología resultante de la revisión literaria de las redes neuronales artificiales para la clasificación.
3. Evaluar los resultados de la implementación de las redes neuronales artificiales para la optimización de exportación de banano ecuatoriano.

Preguntas de Investigación

1. ¿Cuál es la variable más significativa que afecta en la producción del banano?
2. ¿Cuál es la diferencia en el tiempo de maduración de los bananos que se quedan para consumo nacional y los que son exportados?
3. ¿Qué efecto tiene el hecho de optimizar las exportaciones de banano mediante el uso de redes neuronales artificiales?

Capítulo I: Fundamentación Teórica

Marco Teórico

El banano como producto exportable

El banano ha sido un fruto que ha marcado una gran influencia mercantil y económica ya que es uno de los productos agrícolas más consumidos a nivel mundial. Este fruto se cultiva en plantaciones relativamente grandes por productores independientes y empresas multinacionales que controlan cerca del 50 por ciento de la superficie plantada.

Según un reporte de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (2021) el banano es el fruto de mayor venta en el mundo y por el valor bruto de su producción, es el cuarto cultivo alimentario más importante del mundo, después del arroz, el trigo y el maíz.

En la actualidad el sector bananero a nivel de las exportaciones presenta un peso muy importante en la economía del Ecuador, es una de las actividades del agro y económicas con más relevancia en el Ecuador, es la producción de banano, que representa el 2 % del PIB total del país y alrededor del 35 % del PIB agrícola del Ecuador (Ministerio de Comercio Exterior, 2017).

El precio por caja de este producto es definido anualmente con el fin de mantener el crecimiento económico tomando en cuenta la estabilidad del mercado. A partir del año 2019 las exportaciones de banano volvieron a aumentar un 1.78% para Ecuador vendiendo así 356.825.216 cajas de 43 libras de banano aumentando así un 1.7% más que en el periodo de 2018 (Erazo Berrú et al., 2017).

El Ministerio de Agricultura y Ganadería, Acuacultura y Pesca [MAGAP] (2020), estableció el Precio de Sustentación (PMS) para la caja 22XU (41,5-43 libras) el cual oscilaba entre \$6.20 dólares a \$ 6.40 dólares para los años 2015 a 2020, aun cuando desde el año 2017 a 2018 varió entre \$6.26 a \$6.20 presentando así un decrecimiento del -0.96%. Terminando así con el mejor precio para el periodo del 2020 en \$6.40. En el 2021 este producto tuvo un crecimiento importante llegando a costar 6.95 dólares por la caja 22XU (18.14kg), sin embargo, en 2022 el precio del banano mediante el acuerdo ministerial bajó a 6.25 dólares debido a diferentes factores como descenso de las exportaciones por la guerra presentada en el

continente europeo, movimientos nacionales sociales que detuvieron las actividades económicas del país por unos 18 días en el mes de junio entre otros.

A pesar de todo esto, para el presente año 2023, su precio ascendió a 6.50 dólares por cajas de 43 libras, y se estima según la convocatoria del MAGAP a consejo sectorial que la caja de la fruta para el 2024 estaría en 6 dólares las 41.5 libras y 6.22 dólares por 43 libras, todo esto considerando la baja temporada de demanda de la fruta y tratando de que Ecuador participa en la competencia de mercados internacionales como Colombia y Costa Rica.

Ecuador es el primer exportador de banano a nivel mundial y el tercer productor mundial de la fruta posee ventajas comparativas para la producción del banano, ya que tiene los factores climáticos propicios para su crecimiento con buena calidad. Además de que existe disponibilidad de la fruta todo el año. Esta actividad, incluyendo todo el proceso de producción, comercialización y exportación; constituye una importante fuente de empleo: un 16% de la población, según datos del CORPEI, depende directa o indirectamente de este sector. Esta actividad representa para el país el segundo producto con mayor ingreso de divisas, después del petróleo, con un equivalente al 6% del PIB en el año 2000.

Factores que afectan a la producción del banano

Dentro de la producción bananera existen muchos factores que afectan la calidad, recolección y distribución de la cosecha, entre estos están los factores climáticos, tipo de suelo, temperaturas, retrasos en el proceso de fertilización, el viento ya que estos afectan directamente el desarrollo y crecimiento de la planta.

De acuerdo con el Instituto para la Innovación Tecnológica de la agricultura [INTAGRI] (2018) la producción agrícola óptima se concentra dentro de los 15 grados de latitud al norte y al sur del ecuador de la Tierra, aunque se pueden obtener buenas cosechas hasta a 30 grados. La altitud recomendada para este cultivo no debe exceder los 2.000 metros sobre el nivel del mar, y la mayoría de las plantaciones comerciales se ubican entre 400 y 600 metros sobre el nivel del mar. Vale la pena señalar que la latitud retrasa el ciclo de crecimiento de las plantas aproximadamente un mes por cada 100 metros sobre el nivel del mar.

La lluvia es el segundo factor más importante, aunque en algunas áreas exista humedad constante y precipitación. Existe un requisito mensual de 120 a 200 mm, usted también puede ayudar con el riego cuando se produce sequía. El tipo de raíz de plátano se ve

afectado por los siguientes factores las sequías y en su mayor porcentaje al agua de lluvia que puede inundar fácilmente las raíces y provocar deterioro general de la condición de la planta, por los que produciría un proceso de fotosíntesis reducida, se produce la erosión del suelo, como resultado de lo cual da un ph bajo y la pérdida de nutrientes de la fruta por lo que aumentarían la posibilidad de enfermedades fúngicas y bacterianas. (INTAGRI, 2018).

Tomando en cuenta que el agua es uno de los principales elementos reguladores de temperatura y producción, es importante prever su ausencia en caso de sequía o inundaciones que se puedan dar por diferentes fenómenos climáticos como “La corriente del niño” que según Loaiza (2023) en la provincia de El Oro principal productor de este fruto, se advierte que se podría perder alrededor de 50.000 hectáreas de banano si no se protege correctamente las hectáreas de cultivo. Además de proteger el cultivo de las inundaciones también hay que la temperatura de la cosecha debido a que existe un rango óptimo de temperatura que varía entre de 20 a 30 grados centígrados para poder llegar a tener el mejor rendimiento y los ciclos más cortos de la cosecha, si la temperatura se vuelve inferior a 15 grados, se podrían presentar alargamientos del ciclo vegetativo lo que causaría varias afecciones en el crecimiento y la calidad del banano.

El rendimiento de la producción del cultivo de banano en Ecuador también se vería drásticamente afectado dado los continuas plagas a los que suelen estar expuestas los racimos como los nematodos y el sigatoka negra, plagas que destruyen desde la raíz de la fruta causando un bajo peso, reduciendo el vigor de los racimos ya que se encarga de reducir la fotosíntesis y no permitiendo así que las cosechas sean aptas para la exportación o la venta nacional del producto puesta este podría estar susceptibles a más plagas y enfermedades lo que causaría también posibles enfermedades para el consumidor.

Debido a estos factores es esencial para las empresas del sector bananero maximizar el rendimiento de la producción de banano para así no perder un porcentaje de la cosecha tomando en cuenta que la fruta experimenta diferentes retos en su crecimiento y desarrollo para posteriormente llegar a la clasificación para su exportación, además de que las organizaciones bananeras o no bananeras que no están innovando sus procesos pueden quedar obsoletas dentro del mercado ya que no estaría compitiendo al mismo nivel que otras productoras.

Inteligencia Artificial

De acuerdo con Team (2023), es una tecnología que permite crear máquinas capaces de realizar tareas que tradicionalmente dependían de la inteligencia humana donde el experimento de Alan Turing llamado el Test de Turing consistía en determinar si la inteligencia artificial puede imitar las respuestas humanas, este artículo estableció las bases de la inteligencia artificial.

A partir de este podemos identificar que el objetivo de la IA es emular la inteligencia humana a través de diversas capacidades en la máquina tales como el reconocimiento de voz, la toma de decisiones, la búsqueda semántica y las diversas técnicas de aprendizaje automático (Haleem et al., 2022).

Es una realidad que finalmente la adopción de la IA se acelerará en la frontera digital reduciendo la brecha que existe entre los consumidores y la tecnología, de tal forma que cada vez se inviertan más recursos en este sector. Sin embargo, si bien el mundo en el que vivimos actualmente se encuentra repleto de ejemplos de tecnología, desde reconocimiento facial y modulación inteligente de sonido, hasta automóviles dotados de autoconducción; mucho de esto es posible gracias a la IA, también definida como la capacidad de un sistema para interpretar correctamente los datos externos y aprender de ellos para utilizarlos con el fin de alcanzar objetivos específicos (Haenlein y Kaplan, 2019).

A nivel del sector bananero la IA se puede convertir en una herramienta clasificadora de banano por peso, imágenes para mejorar tiempos de cosecha y distribución lo que ayudaría a las productoras a apostar un poco más por la innovación en tecnología nueva, sino que a nivel de competitividad está también pondría impulsar a la empresa a crecer y generar una ventaja competitiva frente a otros agricultores de la industria.

La IA no solo nos serviría para programar una correcta clasificación de banano, también nos serviría en otras áreas según Agronet (2019) la inteligencia artificial nos brinda herramientas que nos permiten detectar enfermedades o diversas plagas que pueda estar presentando el fruto, esta herramienta puede ayudar a los productores a grandes volúmenes de pérdidas, además de que son tecnologías portátiles para monitorear el desarrollo del banano de manera más eficiente, vinculándose con mercados, agentes de extensión, imágenes satelitales e información climática. La tecnología también se está convirtiendo en una primera línea de defensa contra las enfermedades y plagas que pueden potencialmente destruir las

cosechas de sus cultivos. Esto se logra a través de las redes neuronales artificiales como modelo fundamental de la IA que es capaz de aprender y reconocer patrones a través de un entrenamiento de datos y su implementación automatizada que permitirá detectar en este caso posibles plagas o enfermedades que afectarían a la planta lo que no se lograría haciendo de manera manual ya que el operador fallaría en su detección al analizar diferentes días y tomaría mucho tiempo recorrer todas las hectáreas de cultivo.

Así mismo las redes neuronales artificiales servirían en la automatización de la clasificación de bananos de exportación puesto que disminuiría el tiempo de reconocimiento, lo cual no sería posible en caso tal se haga manualmente por las exportadoras bananeras.

Machine Learning

Según Ramírez (2018) el Machine Learning o también conocido como aprendizaje automático es un subcampo de las ciencias computacionales, como también una rama de la Inteligencia Artificial, que facilita a los sistemas aprender de los datos, en otras palabras, maneja grandes cantidades de datos para crear sistemas que de manera automática aprenden y tienen la capacidad de clasificar, resolver y predecir situaciones o eventos, y comportamientos futuros sin la necesidad del ser humano, todo esto mediante la creación y la alimentación de algoritmos con enormes bases de datos, pudiendo identificar patrones y de este modo, analizar los datos.

Como señala Alpaydin (2020), el aprendizaje automático mediante la utilización de algoritmos permite a las computadoras mejorar su capacidad de aprender, analizar y relacionar los patrones de una extensa base de datos y con ellos poder clasificarlos, realizando predicciones que pueden permitir a las personas un mejor control en su toma de decisiones, gracias a la Inteligencia Artificial, en el cual dota a las máquinas la suficiencia de realizar tareas autónomas sin la necesidad de tener una previa programación.

Se lo conoce como un método de análisis de datos que logra automatizar la construcción de los modelos analíticos gracias a la utilización de los datos que abarcan diferentes formas de información digital, como, por ejemplo: palabras, números, clics e inclusive imágenes (Date, 2020).

Asimismo, cabe recalcar que el proceso del Machine Learning es un poco complicado. Esto debido a que, conforme el algoritmo absorbe los datos de entrenamiento, es probable que los modelos producidos sean mucho más precisos basados en datos.

Los algoritmos empleados cuando se aplican en el Machine Learning se crean en base a los datos recopilados, en donde se analizan, y se calculan, y mientras más datos estén almacenados en el sistema, por ende, estos serán mucho más complejos y a la vez, tendrán una mayor efectividad, entonces cuando se presenten los resultados esperados, serán mucho más exactos e irán mejorando con el paso del tiempo (Aprende IA, 2021).

Para proporcionar una mejor explicación, después del entrenamiento cuando se proporciona un modelo con una entrada, siempre se le dará una salida. Esto quiere decir que, un algoritmo predictivo creará un modelo predictivo, un algoritmo clasificador creará un modelo clasificador. A continuación, cuando se proporcione el modelo clasificador con datos, recibirá una clasificación basada en los datos que entrenaron al modelo (International Business Machine Corporation, 2017).

Actualmente, la tecnología del Machine Learning demuestra ser muy esencial para realizar el correcto análisis de los datos, debido a su capacidad de recopilar y proporcionar informaciones específicas de los productos, sus características, logrando que las empresas desarrollen nuevas estrategias para aprovechar las ventajas y oportunidades antes mencionadas.

La importancia del Machine Learning ha ido creciendo debido a que, en la actualidad, ahora hay más volúmenes y variedad de datos inmensos, el tener acceso al poder computacional el alcance a un Internet de alta velocidad (Madan et al., 2022).

Mitchell (2021) menciona que gracias a estos factores que permiten la transformación digital, logran el desarrollo rápido y automático de modelos que pueden analizar y clasificar de forma rápida conjuntos de datos enormes y complejos.

Según Carrión (2020) las aplicaciones del Machine Learning, de los datos de entrada aprenden y luego mejoran continuamente permitiendo la precisión de los resultados, todo esto, por métodos de optimización automatizados.

La calidad del modelo de Machine Learning depende esencialmente de dos aspectos:

Tabla 3

Aspectos que influyen en la calidad del modelo de Machine Learning

<i>La elección del Modelo</i>	<i>Calidad de los Datos de Entrada</i>
Es esencial la elección del algoritmo indicado para cada caso. En donde, las redes neuronales son un tipo de algoritmo con alta precisión y versatilidad que nos brinda. Aunque es importante para grandes cantidades de datos, si es para pequeñas cantidades de datos, es preferible la elección de un modelo más sencillo que funcione mejor.	Si se ingresan datos que sean de baja calidad o simplemente desordenados, por consiguiente, la salida del modelo será en gran magnitud inexacta.

Nota: Análisis de la elección del modelo y calidad de datos. Tomado de (Jiménez, 2019; Yiu, 2019; Madan et al., 2022)

En el caso de las redes neuronales se utilizan principalmente en el aprendizaje supervisado y también en los problemas de aprendizaje por refuerzo. Del mismo modo, se usan las redes neuronales dentro del aprendizaje no supervisado, aunque no es tan normal. Ejemplos de sus usos podemos destacar los decodificadores y mapas autoorganizativos [SOMs] (Profesora Becker de la Universidad de Toronto, 1991; Lee, 2019).

El Machine Learning ha ido mejorando y progresando conforme los años, en donde, se han desarrollado nuevas metodologías para lograr obtener el mayor potencial.

Como lo son las redes neuronales artificiales, en donde, cuyo funcionamiento que, actualmente no se ha comprendido en su totalidad. Sin embargo, si se ha logrado emular el cerebro humano hasta cierto punto, logrando manejar enormes cantidades de datos, lo que le da inicio al aprendizaje profundo, que es un nuevo mundo de la Inteligencia Artificial y del Machine Learning (IBM Cloud Education, 2021).

Redes Neuronales Artificiales

Como lo especifica Padilla et al., (2017) “Las redes neuronales son métodos complejos de procesamiento de información, inspirados en asociaciones neuronales biológicas (p.6)”.

Las Redes Neuronales Artificiales son un modelo que fueron inspirados en el funcionamiento del cerebro humano. En el que, está conformado por un conjunto de nodos conocidos como neuronas artificiales que se encuentran conectadas y se transmiten señales entre sí, de las cuales se transmiten desde la entrada hasta generar una salida.

El objetivo de las Redes Neuronales Artificiales es lograr aprender gracias a estar modificándose automáticamente de manera que pueda realizar tareas que sean complejas que no podrían ser realizadas por la simple programación basada en reglas; logrando que se pueda automatizar funciones que anteriormente eran realizadas por personas (Lean, 2019).

Las Redes Neuronales Artificiales tienen características similares a las del cerebro, en donde “ofrece varias ventajas como el aprendizaje adaptativo, la autoorganización y la operación en tiempo real” (Matich, 2001, p.8).

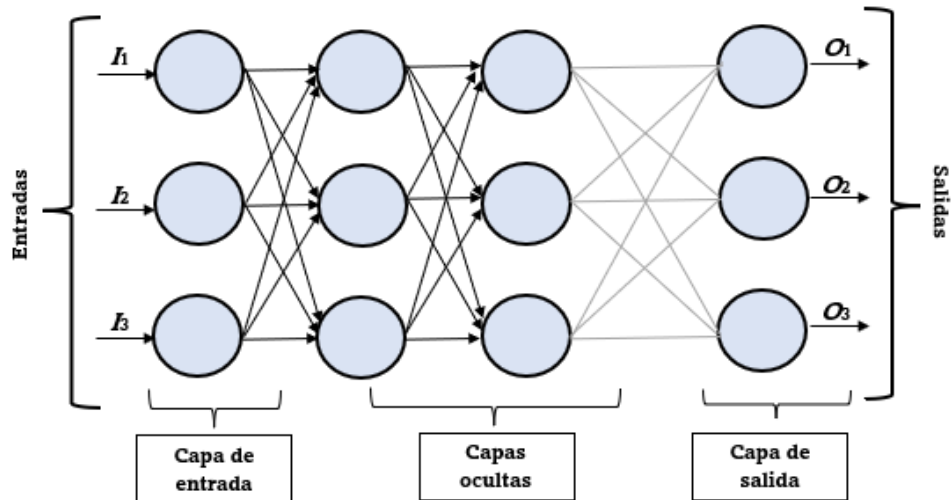
Poseen la habilidad de identificar las relaciones complejas no lineales tanto en variables respuesta como en variables explicativas, logrando entender dichas relaciones.

Según menciona Prieto (2018) “El origen de las redes neuronales artificiales es tratar de emular, con modelos matemáticos, el comportamiento del cerebro en la realización de determinadas tareas”. Cabe recalcar que la “red neuronal” como término es esencial que se considere al cerebro como más de un solo órgano, como un computador que trabaja de manera paralela independientemente, procesando información compleja y que no es lineal; de los cuales al observar estas características lo hacen un computador no tradicional, puesto que las actividades no las hace a través de programas, ni de ecuaciones; si se mantiene un x objeto recto, se requerirá un simple movimiento manual en el que el cerebro coordina con las extremidades.

Como se mencionó anteriormente, las redes neuronales y el cerebro se asemejan en su funcionamiento, en donde, las redes son las que reciben una serie de valores de entrada y cada una de estas llegan a un nodo llamado neurona. Las neuronas de la red están agrupadas en capas que forman la red neuronal artificial, y estas poseen un peso, en otras palabras, un valor numérico, con el que modifica la entrada recibida (Lean, 2019).

Figura 2

Redes Neuronales Artificiales



Nota. Tomado de Damián Matich “Redes Neuronales: Conceptos Básicos y Aplicaciones (2001).

En la Figura 2 observamos el esquema de la red neuronal, que se encuentran neuronas interconectadas en tres capas, en la que los datos entran por la capa de entrada, atravesando la capa oculta y estas salen por la capa de salida. Tienen su clasificación en binarios, las cuales toman valores dentro del intervalo $\{0,1\}$ o $\{-1,1\}$ y las reales que van dentro de $[0,1]$ o $[-1,1]$.

El procesamiento de estas neuronas se resume en inputs y outputs de información, dependiendo de la fuerza que tengan las neuronas interconectadas a otras (Montaño, 2018).

Entre las áreas en las que las Redes Neuronales Artificiales han tenido un gran impacto ha sido en el Reconocimiento de patrones, en donde se estudia técnicas, metodología para lograr identificar la diferencia de objetos partiendo de sus atributos más destacados.


Como señalan Tostado et al., (2015) para hacer esto, utiliza algoritmos computacionales basados en cálculos temáticos simulando ciertas habilidades propias del ser humano como los sentidos. Cabe añadir que, las Redes Neuronales Artificiales como los algoritmos de aprendizaje, toman un proceso de inducción que se la conoce como la fase de entrenamiento, en donde se calibra el peso que hay entre las conexiones de las neuronas y que posteriormente estarán aplicadas.

Arquitecturas basadas en el cerebro

Se encuentra en Anexos como la Figura 20

Figura 3

Arquitectura de una Red Neuronal Simple




Nota: Red Neuronal Simple con una capa de entrada, salida y una capa oculta. Tomado de Basogain (2023)

Tipos de Redes Neuronales Artificiales

Red Neuronal Monocapa.

Figura 4

Red Neuronal Monocapa.




Nota: Tomado de Universidad de Sevilla (2023)

Según Universidad de Sevilla (2023) esta red neuronal artificial es la más simple, en donde se tiene una capa de neuronas, de las cuales proyectan las entradas a una capa de neuronas de salida.

Red Neuronal Multicapa.

Figura 5

Red Neuronal Multicapa.




Nota: Tomado de Universidad de Sevilla (2023)

En este tipo de red neuronal artificial, existe un conjunto de capas intermedias entre las que son las capas de entrada y las de salida conocidas como capas ocultas Universidad de Sevilla (2023).

Red Neuronal Recurrente.

Figura 6

Red Neuronal Multicapa.



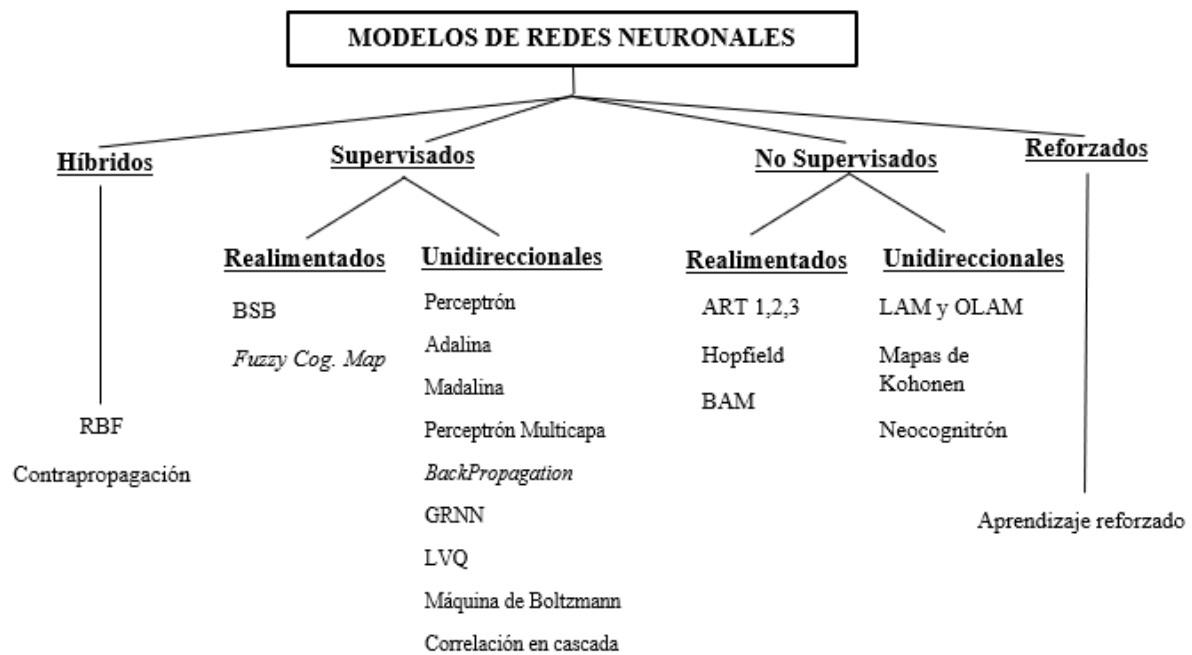
Nota: Tomado de Universidad de Sevilla (2023)

En este tipo de red, se observa la existencia de lazos de realimentación en la red, que podrían ser entre neuronas de diversas capas, de la misma capa o entre una misma neurona, principalmente es adecuada para los sistemas no lineales Universidad de Sevilla (2023).

Modelos de Redes Neuronales Artificiales

Figura 7

Clasificación de las Redes Neuronales Artificiales por el tipo de aprendizaje y la arquitectura



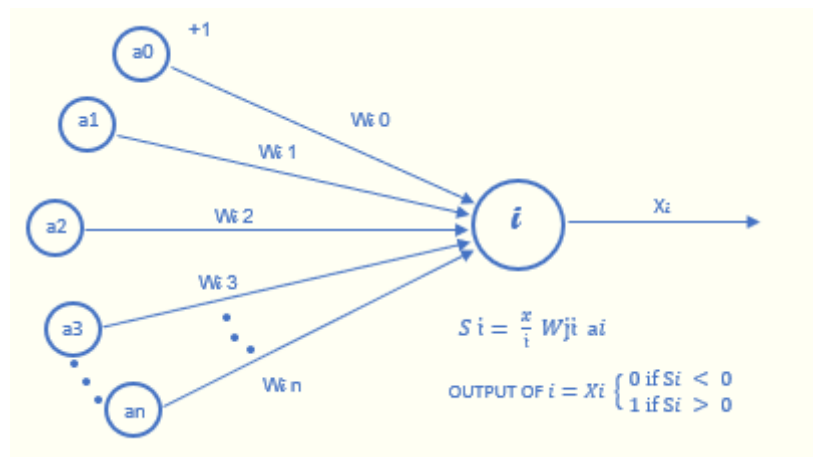
Nota: Tomado de Universidad de Sevilla (2023)

El Perceptrón

La arquitectura del Perceptrón, o mejor conocido como el mapeo de patrones (pattern-mapping), en donde éste aprende a clasificar modelos mediante un aprendizaje supervisado. Este presenta dos capas de unidades procesadoras (PE) y solamente una de ellas es la que tiene la capacidad de adaptar los valores numéricos de las conexiones, esta admite capas adicionales, sin embargo, no disponen de la capacidad de modificar sus propias conexiones Universidad de Sevilla (2023).

Figura 8

Unidad procesadora básica del Perceptrón



Nota: Tomado de Universidad de Sevilla (2023)

En la Figura 8 nos enseñan la unidad procesadora básica del Perceptrón, Las entradas llegan por el sentido izquierdo y cada conexión con la neurona j tiene asignada un peso de valor w_{ji} .

A continuación, realiza la suma ponderada de las entradas según la siguiente ecuación:

$$S_j = \sum a_i w_{ji}$$

Algo que tienen en común muchas de las Redes Neuronales Artificiales es la entrada especial se llama “bias” representada en la parte superior izquierda (entrada a_0). Está siempre representa un valor fijo, $+1$ y funciona como una masa en un circuito eléctrico donde no varía de valor. Luego, el Perceptrón comprueba si la suma de las entradas ponderadas es menor o mayor que un cierto valor umbral y genera la salida “ x_j ” como lo observamos en la siguiente ecuación:

$$\text{si } S_j > 0 \text{ entonces } X_j = 1$$

$$\text{si } S_j \leq 0 \text{ entonces } X_j = 0$$

La salida x_j se transmite a lo largo de la línea de salida y constituye uno de los componentes del vector de salida de la red.

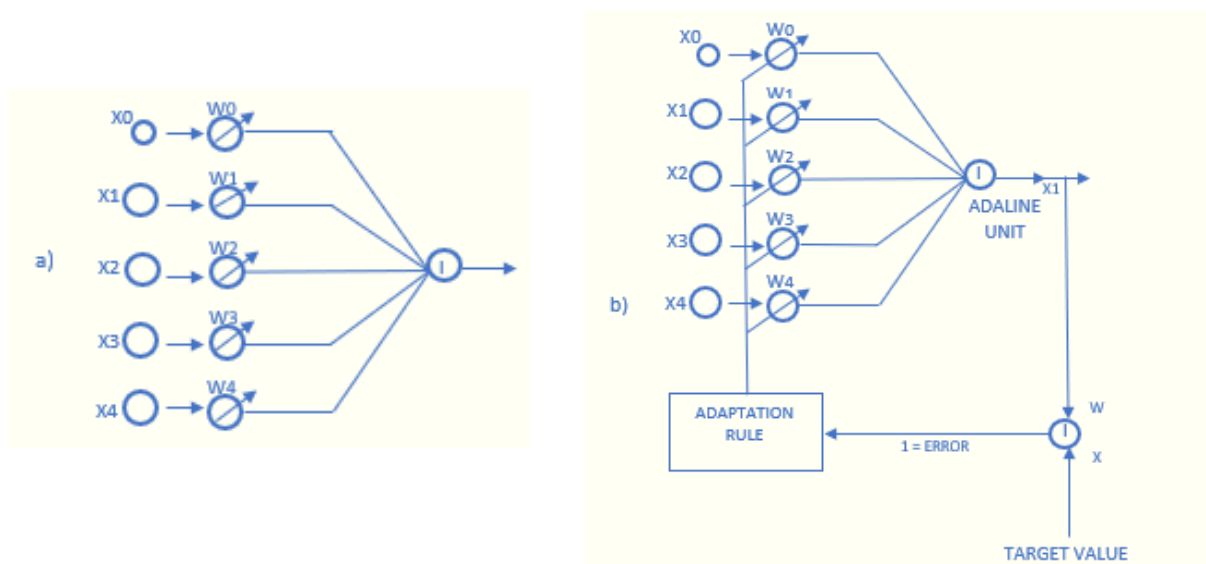
Adaline – Madaline

La arquitectura de Adaline (Adaptive Linear Neuron), fue creada por Bernard Widrow en 1959, en donde se usa un dispositivo lógico que realiza una suma lineal de las entradas y genera una función umbral para el resultado de dicha suma.

Asimismo, la arquitectura Madaline (Multilayer Adaline) creada por el mismo autor presenta una configuración constituida por dos o más unidades Adaline. Las aplicaciones investigadas destacan el reconocimiento de patrones de señales. Sin embargo, los primeros experimentos de las antes mencionadas se constató en clasificar patrones linealmente separables, que presenta la misma limitación que el Perceptrón, que es la carencia de un método que se pueda ajustar más de una capa de pesos.

Figura 9

Red Adaline A y B



Nota: Tomado de Universidad de Sevilla (2023)

En la Figura 9 Se nos muestra una Adaline básica, en donde las conexiones de cada una de las entradas tienen asociadas un valor de ponderación llamado peso w_i .

La unidad procesadora sirve como un sumador y realiza la función umbral según la siguiente ecuación:

$$1 \text{ si } S = \sum_i a_i W_i \geq 0$$

$$X_j =$$

$$-1 \text{ si } S = \sum_i a_i W_i < 0$$

La salida de la unidad Adaline es a diferencia de la arquitectura del Perceptrón que solo permitía valores binarios, es decir 0 y 1. En donde, el entrenamiento se realiza cuando se presenta repetidamente una serie de parejas de entradas y de salidas. Su objetivo es que durante el proceso de adaptación se pueda producir la salida deseada como propia.

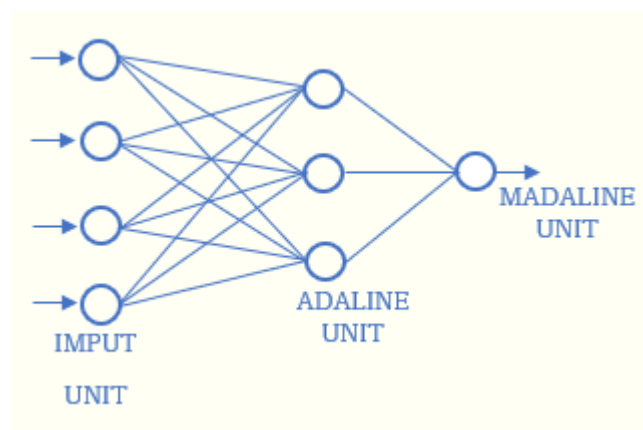
La regla de aprendizaje en la arquitectura es la regla de Widrow-Hoff expresada en la siguiente ecuación:

$$\Delta W_i = \eta a_i (t^* - x)$$

En donde η es la constante de aprendizaje, a_i es la salida de la unidad i , t la salida deseada y x la salida de la unidad Adaline. Sin embargo, la variante de esta regla más utilizada considera el valor de la suma ponderada S en vez del valor de la salida de la unidad Adaline.

Figura 10

Sistema Madaline



Nota: Tomado de Universidad de Sevilla (2023)

En la Figura 10 se muestra el sistema Madaline que posee una capa de unidades. Observamos cuatro unidades en la capa de entrada, tres unidades Adaline en la segunda capa y, por último, una unidad Madaline en la tercera capa.

Para simplificar, las conexiones entre la capa de entrada y de las unidades, Adaline asocia un peso ajustable por cada una de ellas. No obstante, las conexiones entre la capa de Adaline y la unidad Madaline no poseen asociado ningún peso. Es en donde, cada unidad Adaline transmite su salida (-1 ó +1) a la unidad Madaline.

La Madaline emplea una regla de mayorías para obtener su salida: si la mitad o más de las unidades Adaline presentan un valor de salida +1, entonces la salida de la Madaline es +1. En caso contrario el valor de salida de la red Madaline es -1.

Redes Neuronales Convolucionales

Las redes neuronales convolucionales destacan por su eficacia superior al procesar entradas de imágenes, voz o señales de audio. Estas redes están compuestas por tres tipos principales de capas:

1. Capa Convolutiva
2. Capa de agrupación
3. Capa totalmente conectada

La capa convolutiva, que constituye la primera capa de una red convolutiva, puede estar seguida de otras capas convolucionales o de capas de agrupación. La capa final suele ser la capa totalmente conectada. A medida que la CNN progresa a través de estas capas, su complejidad aumenta, permitiéndote identificar partes cada vez más grandes de la imagen. Inicialmente, las primeras capas se enfocan en características simples, como colores y bordes, y a medida que los datos de la imagen avanzan, la CNN reconoce progresivamente elementos o formas más complejas hasta lograr la identificación del objeto deseado (IBM Cloud Education, 2021).

Las curvas ROC

La curva ROC es una herramienta estadística utilizada para analizar el poder discriminatorio de una prueba diagnóstica dicotómica. Es decir, el propósito de una prueba basada en variables de decisión es dividir a los individuos de la población en dos grupos: a un grupo se le presenta el evento de interés y al otro no (Casco et al., 2023).

Esta distinción depende del umbral elegido entre todos los resultados posibles de la variable de decisión, es decir variable, cuyo resultado es la clasificación de cada individuo en uno u otro grupo. Una curva es un gráfico generado expresando las medidas de sensibilidad y especificidad de una prueba de diagnóstico en cada umbral. Por un lado, la sensibilidad determina la proporción de individuos que presentan un evento de interés y que son clasificados como portadores de ese evento en la prueba. Por otro lado, la especificidad determina la proporción de individuos que carecen de especificidad y son clasificados por la prueba. Desde su invención en la investigación militar estadounidense, se ha incorporado al análisis discriminante y a la teoría de detección de señales. Su primera aplicación fue en la detección de señales de radar en la década de 1950. En la década de 1960, Green y Swett lo utilizaron en experimentos psicofísicos y, más tarde, en la década de 1970, el radiólogo Leo Lusted lo aplicó a la toma de decisiones de diagnóstico utilizando imágenes médicas. Desde entonces, muchos investigadores han utilizado la herramienta en atención sanitaria, economía, meteorología y, más recientemente, aprendizaje automático.

El análisis con base en curvas *receiver operating characteristic* (ROC, «característica operativa del receptor», aunque la traducción quizá se ajuste más a «curva de eficacia diagnóstica») constituye un método estadístico para determinar la exactitud diagnóstica de test que utilizan escalas continuas, siendo utilizadas con 3 propósitos específicos: determinar el punto de corte en el que se alcanza la sensibilidad y especificidad más altas, evaluar la capacidad discriminativa del test diagnóstico (Perez y Martin, 2023).

Punto de corte que determina la sensibilidad y la especificidad más altas

Es el que presenta el mayor índice de Youden, calculado según la fórmula (sensibilidad + especificidad - 1). Gráficamente, este corresponde al punto de la curva ROC más cercano al ángulo superior-izquierdo del gráfico (punto 0,1), es decir, más cercano al punto del gráfico cuya sensibilidad y especificidad son del 100% (Olivera y Alex, 2020).

Sin embargo, en este aspecto hay que considerar que este índice de Youden indica cuál es el punto de corte que determina la sensibilidad y especificidad más altas conjuntamente, pero no siempre es la sensibilidad más alta hallada en el test. La sensibilidad más elevada es un punto de corte, sin embargo, le especificidad corresponde a otro corte, lo que podría ocasionar un test en extremo sensible o específico.

En la curva ROC existe un área denominada área bajo la curva (ABC, o AUC que significa *area under the curve*) esta evalúa la facultad discriminativa del test, es decir, su capacidad de diferenciar sujetos sanos versus enfermos. El AUC la podemos entender como la probabilidad de clasificar correctamente a un par de individuos (uno sano y otro enfermo) seleccionados al azar al aplicarles la prueba.

El AUC refleja que tan bueno es el test que queremos utilizar para discriminar un conjunto de datos con y sin características específicas en todo el rango de puntos de cortes.

Comparar la capacidad discriminativa de 2 o más test diagnósticos

Para lograr este fin es necesario, en primer lugar, comprobar que se cumplen los siguientes requisitos: los test a comparar deben ser medidos simultáneamente, aplicados sobre los mismos sujetos y contrastados con el mismo patrón oro (Olivera y Alex, 2020).

El análisis se centra en el AUC respectivo de cada prueba, siendo el AIC más alto el más discriminativo. Para establecer que una prueba tiene una capacidad discriminativa superior, es necesario comparar ambas AUC utilizando los métodos descritos por Hanley y McNeil o por DeLong et al.8, dando preferencia a este último. Cuando estas herramientas no están disponibles, sólo podemos proponer que una prueba diagnóstica discrimina más que la otra, pero no confirmarlo.

Marco conceptual

Exportación de banano

La producción de banano para la exportación se considera una actividad tecnológica y económica diferente a la producción del banano como alimento de primera necesidad. La producción destinada a la exportación se sirve únicamente de unas cuantas variedades seleccionadas por su alto rendimiento, su durabilidad en el transporte de larga distancia, su calidad y su aspecto sin taras. El volumen de bananos exportados a nivel mundial en el

período de 1985 a 2002 creció a una tasa media sin precedentes del 5,3 por ciento anual, el doble que en los últimos 24 años [2,4 por ciento entre 1960 y 1984] (Martínez-Solórzano y Rey-Brina, 2021).

Este aumento fue unido a cambios tecnológicos y cambios en el escenario del comercio mundial, entre los que figuran la apertura de las economías socialistas a los mercados mundiales a comienzos de los años noventa, acciones bilaterales y multilaterales para liberalizar el comercio (Acuerdo General sobre Aranceles Aduaneros y Comercio - GATT, y la Organización Mundial del Comercio - OMC), el aumento de la conciencia ambiental (Protocolo de Montreal en 1987 y la Cumbre de la Tierra de Río de Janeiro en 1992), la creación de un Mercado Único Europeo en 1993, un período de crecimiento económico sin precedentes propiciado por las tecnologías multimedia y «la nueva economía» en el mundo desarrollado, la aplicación de políticas de ajuste estructural en los países productores de banano, y una concentración importante de comercio al por menor. La publicación comienza con una visión general de la evolución de la producción y el comercio en los últimos 15 años, y continúa con una descripción y un análisis en profundidad de los hechos y motivos que han servido de base para estos avances. Se examina la producción y las exportaciones de banano en las principales regiones exportadoras del mundo, la evolución de las importaciones y las políticas de importación de los principales mercados, el cambio tecnológico en los niveles de producción y transporte, las preocupaciones, políticas e instrumentos sociales y en materia de medio ambiente, y la función de las empresas transnacionales en la economía mundial del banano.

A nivel mundial, el banano se ubica entre los principales productos agrícolas, los países con mayores exportadores en la última década son Ecuador, Filipinas y Costa Rica, mientras que los países importadores son Estados Unidos de Norte América, Alemania y Bélgica. El aporte nutricional y la capacidad de producción durante todo el año son elementos predominantes al momento de concretar relaciones comerciales en relación a esta fruta, además de su nivel de asequibilidad puesto que la producción a escala permite reducir los costos de producción y con ello que la fruta se comercializa a valores acordes en los diferentes países adquirentes (Guerrero, 2017).

Machine Learning

El Machine Learning (ML) se ha ido impulsando con el paso del tiempo su implementación en varias ramas y su estudio, en donde, tiene su auge en la actualidad,

posicionándose como uno de los factores esenciales en el avance de diferentes industrias nacionales e internacionales (Management Solutions, 2018).

Como menciona Rouhiainen (2018), el Machine Learning puede desglosarse en tres tipos de algoritmos principales que se desglosan en: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo, estos son de donde los programadores se basan.

Cabe añadir que el término Aprendizaje Automático, a menudo se confunde con el de la Inteligencia Artificial, cuando en definitiva es un subcampo. Es decir, se define como la capacidad del ordenador para poder aprender sin ser necesariamente programado (Asociación para el Progreso de la Dirección, 2019).

Algoritmos de Machine Learning

Aprendizaje Supervisado. Utiliza una base de datos que anteriormente ya estaba etiquetada dado a que se necesita separarse en 2 conjuntos de datos, uno de entrenamiento y otro que servirá de prueba, debido a que el del entrenamiento se encargará de calibrar los datos para que los algoritmos aprendan sobre la información que es entregada y gracias a los datos de prueba se pueda realizar la correcta clasificación o predicción dependiendo de la utilización que se le dé al modelo (Webs, 2021).

Según la Asociación para el Progreso de la Dirección (2019), es en donde la máquina se enseña con el ejemplo. De esta manera, la persona proporciona al algoritmo de Aprendizaje Automático un conjunto de datos que son conocidos y que incluyen las entradas y las salidas esperadas, y el algoritmo deberá encontrar la manera para determinar cómo llegar hasta las salidas desde las entradas.

El Aprendizaje Supervisado supone tener subcategorías que se diferencian entre sí por los datos de salida que se van a usar, esto ya que, si se desea la clasificación, entonces las variables de salida serán discretas o categóricas, y si es de regresión serán de cuantitativas (Saltos y Villacis, 2022).

El significado que se le da al Aprendizaje Supervisado es vasto, dado que mediante la retención del aprendizaje histórico puede cooperar a la optimización de sistemas en cuanto a la clasificación o la predicción. Según Russo et al., (2018) mencionan como, por ejemplo, la administración de los e-mails, mediante el análisis de datos de entrada, en otras palabras, la

información sobre el correo recibido y aprendiendo la clasificación de los mensajes que son etiquetados como importantes y como spam.

Aprendizaje No Supervisado. Este algoritmo estudia los datos para poder identificar patrones, en donde no se necesita una persona que sirva como instructor ni clave de respuesta. Es más bien, la máquina es la que especifica las correlaciones mediante el análisis de datos disponibles.

Según Camacho y Reyna (2022) aquí interpretan enormes conjuntos de datos y los dirige, en donde intenta organizarlos de manera para describir su estructura, que se vean más organizados. Es importante que cuando este evalúa más datos, mejorará su capacidad para tomar decisiones y se volverá más refinada.

Según Sancho (2021) el Aprendizaje No Supervisado se centra a base de la experiencia, cuando se le introduce la base de datos, la analizará y guarda las características para luego si se introduce nueva base de datos, el modelo comparará entre los datos para realizar la agrupación que tengan mayor similitud. Resulta muy productivo debido que no necesitamos realizar un previo entrenamiento de los datos ni tener conocimiento sobre los datos de salida, este logrará buscar la manera de agrupar de forma correcta mediante sus reconocimientos de patrones, deduciendo los posibles resultados aprendidos. Sin embargo, puede provocar un problema porque si tenemos algoritmos muy complejos, puede haber soluciones que no sean predecibles a diferencia de otros modelos.

Aprendizaje Por Refuerzo. Se centra en los procesos de aprendizajes reglamentados, donde proporcionan algoritmos de Machine Learning con un conjunto de acciones, y valores finales.

Entonces, cuando uno define las normas, el algoritmo de Machine Learning averigua las diversas posibilidades donde evalúa cada resultado para observar el más óptimo.

Por tal razón, este sistema doctrina la máquina a través del proceso de ensayo y error, en donde aprende de las experiencias en el pasado y empieza a adaptar su enfoque según su respuesta a la situación para lograr el mejor escenario con el mejor resultado.

Tabla 4

Tipos de algoritmos de Machine Learning

Algoritmos	Definición
Algoritmos de Regresión	<p>En este tipo, el programa de Aprendizaje Automático debe estimar las relaciones existentes entre las variables. En este análisis, su enfoque es en una variable dependiente y una serie de otras variables cambiantes, siendo útil para el pronóstico y la predicción.</p>
Algoritmos Bayesianos	<p>Este tipo de algoritmos por clasificación están basados en el teorema de Bayes, en donde se clasifican cada valor como independiente de cualquier otro, permitiendo predecir una categoría en función de un conjunto dado de características.</p> <p>El clasificador es muy útil, utilizándose debido a que supera a los métodos de clasificación más sofisticados.</p>

**Algoritmos de
Agrupación**

Es en donde se usan en el Aprendizaje No Supervisado, en donde permiten categorizar datos no etiquetados, en otras palabras, sin que tengan grupos definidos.

Por lo que, mediante la búsqueda de grupos dentro de los datos funciona el algoritmo, con el número de grupos representados por la variable K, funcionando de manera repetitiva para designar cada punto de datos a uno de los K grupos según las características proporcionadas.

**Algoritmos de Árbol
de Decisión**

Es una estructura de árbol que es casi igual a un diagrama de flujo que usa un método de bifurcación para ilustrar cada posible resultado de una decisión, en donde cada nodo dentro del árbol representa una prueba en una variable específica, y el resultado es cada rama de esa prueba.

Algoritmos de Redes Neuronales Una red neuronal artificial (RNA) es la que comprende unidades dispuestas en una serie de capas, en donde se conecta con capas anexas. Toman su inspiración en los sistemas biológicos, el cerebro, observando su procesamiento de la información.

Por ende, son esencialmente un gran número de elementos de procesamiento que se encuentran interconectados trabajando para resolver problemas que sean específicos.

Del mismo modo, estos aprenden con la experiencia y el ejemplo, son muy capaces para modelar relaciones no lineales en datos de gran dimensión, en donde muchas veces la relación entre las variables de entrada es un poco complicada de entender.

Algoritmos de Reducción de Dimensión En donde la reducción de dimensión reduce el número de variables consideradas para encontrar la información exacta que es requerida.

Algoritmos de Aprendizaje Profundo Los algoritmos de Aprendizaje Profundo ejecutan datos a través de muchas capas de algoritmos de las redes neuronales artificiales, las cuales pasan a una representación simplificada de los datos a la próxima capa.

Cabe recalcar que un conjunto de datos no estructurado, como, por ejemplo, el de una imagen, poseen una cantidad tan enorme de características que este proceso se vuelve completamente impracticable.

Inteligencia Artificial

La Inteligencia Artificial se trata de un sistema informático de interpretación y aprendizaje de datos, en la cual se centra en la creación de sistemas que puedan ejecutar tareas de manera automática, permiten reconocer patrones y mejorar las tareas (Stubblefield y Luger, 1990).

La enorme capacidad de adaptación y las aplicaciones prácticas que permiten la automatización de los procesos han logrado que la Inteligencia Artificial se destaque, principalmente por la facilidad de su uso de su programación con muy buenos resultados.

Como menciona Rusell (2019) las diversas aproximaciones de la Inteligencia Artificial se encuentran dada en cuatro enfoques aplicados que se encuentran descritos en el libro Human Compatible. AI and the Problem of Control:

1. La búsqueda de soluciones: Estos son los enfoques de exploración de árboles. (look ahead)
2. Conocimiento y lógica: Observamos lógica proposicional, sistemas expertos y lenguajes formales.
3. Incertidumbre y probabilidad: Encontramos los lenguajes probabilísticos de primer orden, redes bayesianas y la combinación de la teoría de la probabilidad con los lenguajes formales.
4. Aprendizaje a partir de la experiencia: En donde el aprendizaje está basado en casos en donde encontramos el Machine Learning.

Cabe recalcar que, existen diversas ramas de la Inteligencia Artificial como:

- Machine Learning
- Deep Learning
- Neural Networks
- Computer Vision
- Natural Language Processing (NLP)
- Natural Language Generation (NLG)

- ChatBot
- Virtual Digital Assistants
- Recommender Systems
- Predictive Analysis

Marco Legal

Cuando nos referimos al ámbito legal, podemos observar que se han generado varios planes alineados a una normativa legal entre los que podemos resaltar: El Plan Nacional de Telecomunicaciones y Tecnología de Información del Ecuador 2016-2021.

Del mismo modo, el Convenio Marco de Cooperación Interinstitucional que está firmado y avalado con los diferentes entes como el Ministerio de Telecomunicaciones y de La Sociedad de la Información, La Secretaría de Educación Superior, Ciencia, Tecnología e Innovación.

Asimismo, hacemos referencia a Los Planes Nacionales para el Desarrollo (2013-2017), junto con la Ley Orgánica de Telecomunicaciones. También, El Código Orgánico de La Economía Social de los Conocimientos, Creatividad e Innovación.

De igual manera, como los artículos que contemplan el desarrollo de la investigación científica junto con la innovación en la tecnología, de Las Tecnologías de la Información y las Comunicaciones (TIC) y distintas áreas del conocimiento que se encuentran en la Constitución de la República del Ecuador de los cuales se puede acentuar los (Art. 281, Art. 385, Art. 385, Art. 387, Art. 423, Art. 388, Art. 313) que dan la posibilidad de alinearse y ser parte de la adopción de estas tecnologías que están emergiendo para el cambio y la acogida de una cultura transformadora digital para un mejor desarrollo a nivel empresarial, en el ámbito nacional con proyección hacia lo internacional, lo que lo vuelve en un impacto positivo y cambiador.

Cabe resaltar que, la Constitución de la República del Ecuador (2008) en su Art. 313 menciona que “El Estado se reserva el derecho de administrar, regular, controlar y gestionar los sectores estratégicos, de conformidad con los principios de sostenibilidad ambiental, precaución, prevención y eficiencia” (pág. 133). Finalmente, la Constitución de la República del Ecuador (2008) adiciona que en el Art. 321 de la Carta Magna, “El Estado reconoce y garantiza el derecho a la propiedad en sus formas públicas, privadas, comunitarias, estatales, asociativas, cooperativas, mixta, y que deberá cumplir su función social y ambiental” (pág. 149).

Capítulo II

Metodología

Luego de una extensa revisión de literatura, se procedió a escoger el modelo de la red neuronal artificial conocida como Monocapa o mejor dicho como la red de Perceptrones debido a su facilidad de implementación y gracias a su entrenamiento se logra una alta precisión en sus resultados

El actual trabajo es de corte transaccional, debido a que se recolectarán los datos en un tiempo específico, en el cual la técnica de recolección de datos que fue empleada para la investigación proviene de la data pura proporcionada por una empresa encargada de gestionar las exportaciones de banano de diversos proveedores, la cual pidió permanecer anónima, ha otorgado sus datos históricos sobre los dos tipos de banano en su cartera desde 2017 al 2022, la cual cuenta con 95.839 observaciones en total dentro de la base, con el fin del desarrollo del modelo confiable de redes neuronales artificiales para la clasificación.

Figura 11

Número de Observaciones

	Tiempo.de.Maduracion	Precio.x.Caja	Cajas	Exportacion
1	11	6.26	1199	1
2	12	6.26	209	1
3	12	6.26	600	1
4	12	6.26	2495	1
5	11	6.26	1001	1
6	11	6.26	998	1
7	11	6.26	453	1
8	11	6.26	571	1
9	12	6.26	502	1
10	11	6.26	348	1

Showing 1 to 10 of 95,839 entries, 4 total columns

En la Figura 11 se puede identificar las tres variables cuantitativas con las que trabajaremos y la columna Exportación.

Tiempo de Maduración: Esta variable cuantitativa se divide en 3 datos, 11, 12 y 13 semanas. Esta columna especifica en cuantas semanas se dejó madurar y posteriormente se cortar el racimo de bananos.

Precio x Caja: En esta variable cuantitativa, se especifica el precio general al que se vendieron las cajas en los últimos cinco años para todas las observaciones. Estos años conforman desde el 2017 al 2022.

Cajas: Esta variable cuantitativa especifica el número de cajas que se vendieron en el periodo analizado, que van desde 0 - 31200 cajas vendidas.

Exportación: Esta variable dicotómica especificada entre 1 y 0, en el cual 1 significa que estas cajas de bananos fueron exportadas a los diferentes países de destino mientras que 0 significa que esas cajas se quedaron como venta local, es decir, se consideraron de Grado B.

El trabajo es de corte transaccional, debido a que se recolectan estos datos a través del tiempo donde se realizó un análisis con respecto a las variables interrelacionadas. Del mismo modo, la investigación es de corte correlacional de tipo exploratorio porque se busca clasificar a los dos tipos de bananos a través de las variables.

La aplicación de las redes neuronales para la clasificación es utilizada para la clasificación de las distintas variables que deseamos tomar, y será de utilidad mediante los datos de entrenamiento y los datos de prueba provenientes de la misma base de datos, y confirmar si el modelo es el más adecuado.

Metodología en el programa R studio.

En primer lugar, se procede a cargar la base de datos que se estableció a partir de la base proporcionada por la empresa denominada en la base de datos como *Banano* y se procede a cargar la base de datos con la secuencia:

```
Banano <- read.csv2("../Data/TESIS.csv")
```

Debido a que nuestro proyecto es acerca de redes neuronales para la clasificación, necesitaremos datos numéricos por lo que se procede a eliminar las columnas que contienen datos categóricos o cualitativos con el siguiente comando:

```
Banano <- Banano[,c(-1, -5, -6)]
```

Instalación y carga de paquetes

```
Install.packages = ("name of package")
```

Estos son paquetes que abarcan tareas de ciencia de datos tales como: manipulación y limpieza, visualización, programación. A continuación, se procede a realizar una explicación detallada:

- **Caret:** Classification and regression training, en donde existen funciones que facilitan la utilización de métodos complejos de clasificación, regresión y principalmente para la partición de datos.

- **Dplyr:** A Grammar of Data Manipulation. Permite proporcionar una “gramática” para manipular y operar con data frames, permitiendo comunicar nuestro proceso.
- **Ggplot2:** Create Elegant Data Visualisations Using the Grammar of Graphics. Es un sistema que permite la visualización de datos.
- **Lattice:** Trellis Graphics for R. Permite una visualización de datos de alto nivel con énfasis en datos multivariados.
- **Neuralnet:** Training of Neural Networks. Entrena las redes neuronales mediante la retro propagación.
- **Colorspace:** A Toolbox for Manipulating and Assessing Colors and Palettes. Elección de la paleta de colores variados.
- **Grid:** The Grid Graphics Package. Es una reescritura de las capacidades de diseño de gráficos.
- **VIM:** Visualization and Imputation of Missing Values, sirve para la limpieza de datos, es decir, proporciona nuevas herramientas para la visualización de valores faltantes y/o imputados.
- **pROC:** Display and Analyze ROC Curves, proporciona herramientas para visualizar, comparar las características operativas del receptor que son las curvas ROC y permite calcular intervalos de confianza para curvas (p) AUC o ROC.

Por último, se carga las paqueterías instaladas, este código se encarga de actualizar la lista de paquetes para su uso.

```
library ("ggplot2, lattice, caret, dplyr, neuralnet, colorspace, grid, VIM, pROC")
```

Análisis de los Valores Faltantes o “NAS” en las variables

```
aggr(Banano, col = c("green", "red"), numbers = TRUE, sortVars = TRUE, labels
    = names(Banano), cex.axis = 0.5, gap = 1, ylab
    = c("Histograma de NAS", "Patrón"))
```

Con la función *aggr* perteneciente al paquete *VIM*, permite realizar un gráfico de análisis de la presencia de valores faltantes en el conjunto de datos. Esto resulta esencial debido a que nuestra base de datos es extensa y de esta manera no entorpecerá el modelo.

Banano: Es el conjunto de datos empleado en el proyecto.

col: Es un vector de colores que empleamos para representar las barras en el gráfico. En este caso, identificamos al color “green” para indicar la ausencia de NAS y el “red” para indicar los NAS.

numbers: Es un valor lógico en el cual nos mostrará los números en las barras de gráfico.

sortVars: Es un valor lógico en el que indica el orden de las variables de mayor a menor según la cantidad de NAS.

labels: Son las etiquetas de las variables en el conjunto de datos.

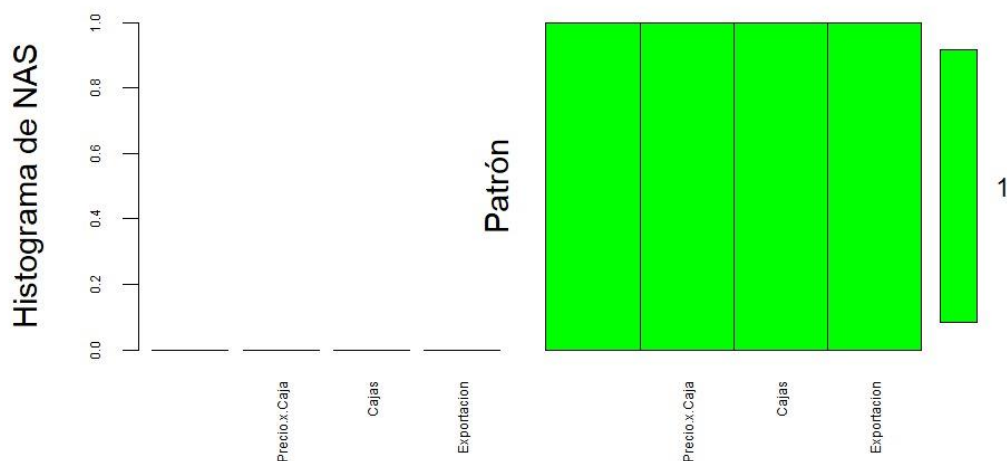
cex.axis: Controla el tamaño de las etiquetas.

gap: Es el espaciado entre las barras en el gráfico.

ylab: Son las etiquetas de los ejes y, utilizadas para describir el contenido de ambas partes, en este caso “Histograma de NAS” y “Patrón”.

Figura 12

Histogramas de Valores Faltantes y Patrón



Como observamos en la Figura 12, todas las variables no tienen valores faltantes, es decir, que no impactara de manera negativa en el entrenamiento y en la efectividad del modelo de redes neuronales para la clasificación.

Una vez que se ha comprobado la ausencia de valores faltantes en la data, se prosigue a convertir en factor a nuestra variable dependiente, es decir, a “Exportación”

```
Banano$Exportacion <- factor(Banano$Exportacion, levels = c(0,1), labels = c(0,1))
```

Banano\$Exportacion: Hace referencia a la columna “Exportacion” en el conjunto de datos empleado en el proyecto.

factor: Es utilizada para transformar una variable numérica en un factor.

levels= c(0,1): Aquí definimos los niveles que va a tomar el factor. Especificando que 0 son aquellos que no fueron exportados y 1 aquellos que si fueron exportados.

labels= c(0,1): Asigna etiquetas a los *levels anteriores*.

Semilla

Proporciona la predicción y reproducción de la secuencia de los datos que son generados por un generador de números pseudo aleatorios (Coder, 2020).

La semilla se instala mediante:

```
set.seed(123)
```

Se puede escoger cualesquiera tipos de semillas, pero para nuestro proyecto enfocado en redes neuronales artificiales para la clasificación, la mejor semilla es la (123).

Lo siguiente es el entrenamiento de los datos, por lo que se realiza con el siguiente código:

```
Particion <- createDataPartition(Banano$Exportacion, p = .70, list = FALSE)
```

Particion: Es el nombre con el que reconocemos el entrenamiento de los datos.

Banano\$Exportacion: Es nuestra variable dependiente.

p=.70: Especificamos la proporción de los datos del conjunto de entrenamiento. Es decir, que el 70% de los datos serán el conjunto de entrenamiento y el 30% se usa en el conjunto de prueba.

list = FALSE: El resultado será devuelto de forma de vector.

```
Entrenamiento1 <- Banano[ Particion, ]
```

```
Pruebas1 <- Banano[-Particion, ]
```

Entrenamiento 1 <- Banano [Particion,]: En donde seleccionamos las filas del conjunto de datos “Banano” indicadas por el vector “Particion”, creamos el conjunto de entrenamiento.

Pruebas 1 <- Banano [-Particion,]: En donde seleccionamos las filas del conjunto de datos “Banano” que no están en el conjunto de entrenamiento indicadas por el vector “- Particion”, creamos el conjunto de pruebas.

Después de crear el conjunto de Entrenamiento y de Pruebas es necesario estandarizar sus valores respectivamente, esto debido a que será importante que no exista crecimiento de errores cuando el modelo vaya aprendiendo.

```
Entrenamiento1[,1:3] <- scale(Entrenamiento1[,1:3])
```

```
Pruebas1[,1:3] <- scale(Pruebas1[,1:3])
```

Entrenamiento1[,1:3] <- scale(Entrenamiento1[,1:3]): Escala las tres primeras columnas del conjunto de entrenamiento.

`Pruebas1[,1:3] <- scale(Pruebas1[,1:3])`: Escala las tres primeras columnas del conjunto de prueba.

Scale: Esta función centra y escala las columnas de la matriz para mantener una media 0 y una desviación estándar de 1.

A continuación, se ejecuta el modelo de la Red Neuronal Artificial mediante el paquete de *Caret*.

```
ModeloRedNeuronal <- caret::train(Exportacion~., Entrenamiento1, method  
= "nnet", trace = FALSE)  
ModeloRedNeuronal  
plot(ModeloRedNeuronal)
```

Train (): Esta función se encuentra en la biblioteca *caret*, que permite entrenar el modelo de la red neuronal artificial.

Method = "nnet": Especificamos que utilizaremos el algoritmo de red neuronal artificial.

Trace = FALSE: Especifica que se desactiva la visualización del proceso de entrenamiento.

Plot: Servirá para producir el gráfico del modelo.

Figura 13

Modelo de Red Neuronal Artificial para la clasificación.



De esta medida, las convergencias de las variables, con las primeras dos capas ocultas no aprendieron mucho, pero ya en la tercera capa oculta empezaba a aprender, logrando que con la quinta capa oculta se optimiza su aprendizaje, esto debido a que tiene un aprendizaje del 0.998, es decir, casi perfecto. En resumen, podemos inferir con lo realizado hasta ahora que el modelo es bueno.

Una vez concluida la metodología a utilizar, pasamos al análisis de los resultados. Esto debido a que en la metodología analizamos las diferentes librerías, y paquetes que vayamos a utilizar en el modelo, observar cualquier variable faltante en los datos y de este modo observar la cantidad de capas ocultas que tendrá nuestra red neuronal artificial.

Capítulo III

Análisis de los Resultados

Para dar inicio a este capítulo, basada en la metodología del capítulo anterior, primero se debe de generar las predicciones del modelo de la red neuronal artificial tanto para el conjunto de Entrenamiento como el conjunto de Pruebas:

```
Entrenamiento1$Class <- predict(ModeloRedNeuronal, Entrenamiento1)
Pruebas1$Class <- predict(ModeloRedNeuronal, Pruebas1)
```

La función *Predict ()*: Se utiliza para obtener las predicciones del modelo para los datos de entrada tanto para el entrenamiento como las pruebas.

Generamos la matriz de confusión con el siguiente código:

```
EntreMC
<- confusionMatrix(Entrenamiento1$Class, as.factor(Entrenamiento1$Exportacion))
EntreMC
PruebaMC <- confusionMatrix(Pruebas1$Class, as.factor(Pruebas1$Exportacion))
PruebaMC
```

Nuestra matriz de confusión nos arroja un resultado muy satisfactorio a primera vista, es decir que los tipos de banano están correctamente clasificados según los criterios que se impusieron en la columna “Exportación”, donde: el 0 son los no aptos para la exportación y el 1 son los aptos para exportación.

Figura 14

Matriz de Confusión

Entrenamiento		Prueba	
Confusion Matrix and Statistics		Confusion Matrix and Statistics	
	Reference		Reference
Prediction	0 1	Prediction	0 1
0	32323 0	0	13852 0
1	0 34765	1	0 14899
	Accuracy : 1		Accuracy : 1
	95% CI : (0.9999, 1)		95% CI : (0.9999, 1)
	No Information Rate : 0.5182		No Information Rate : 0.5182
	P-Value [Acc > NIR] : < 2.2e-16		P-Value [Acc > NIR] : < 2.2e-16
	Kappa : 1		Kappa : 1
	Mcnemar's Test P-Value : NA		Mcnemar's Test P-Value : NA
	Sensitivity : 1.0000		Sensitivity : 1.0000
	Specificity : 1.0000		Specificity : 1.0000
	Pos Pred Value : 1.0000		Pos Pred Value : 1.0000
	Neg Pred Value : 1.0000		Neg Pred Value : 1.0000
	Prevalence : 0.4818		Prevalence : 0.4818
	Detection Rate : 0.4818		Detection Rate : 0.4818
	Detection Prevalence : 0.4818		Detection Prevalence : 0.4818
	Balanced Accuracy : 1.0000		Balanced Accuracy : 1.0000
	'Positive' Class : 0		'Positive' Class : 0

Tanto los valores de predicción de exportación y no exportación en los datos de Entrenamiento y de Prueba están correctamente clasificados, esto lo podemos afirmar porque tiene una efectividad de un 0.9999 es decir casi perfecto en ambos casos y es bastante significativo debido a que su valor es $2.2e^{-16}$ es menor a 0.05.

El siguiente paso es comprobar la importancia de las tres variables analizadas:


```
varImp(ModeloRedNeuronal)
```

```
plot(varImp(ModeloRedNeuronal))
```

VarImp: Esta función devuelve el objeto que contiene la información sobre la importancia de la variable en el modelo.

Figura 15

Importancia de las Variables



La aplicación de las Curvas ROC nos ayuda a observar cuales son las variables que más influyen según la varianza en el modelo de la red neuronal artificial para la clasificación. En este caso, observamos que la variable que tiene la mayor influencia es la variable: “Tiempo de maduración”.

```
dfcor <- Entrenamiento1
```

```
dfcor$Class <- as.numeric(dfcor$Class)
```

```
ROC1 <- plot.roc(dfcor$Class, dfcor$Tiempo.de.Maduracion, main =  
  "Confidence intervals", percent = TRUE, ci = TRUE, print.auc = TRUE)
```

```
ROC2 <- plot.roc(dfcor$Class, dfcor$Precio.x.Caja, main = "Confidence intervals", percent  
  = TRUE, ci = TRUE, print.auc = TRUE)
```

```
ROC3 <- plot.roc(dfcor$Class, dfcor$Cajas, main = "Confidence intervals", percent = TRUE, ci  
  = TRUE, print.auc = TRUE)
```

Plot.roc (): Se utiliza para generar curvas ROC.

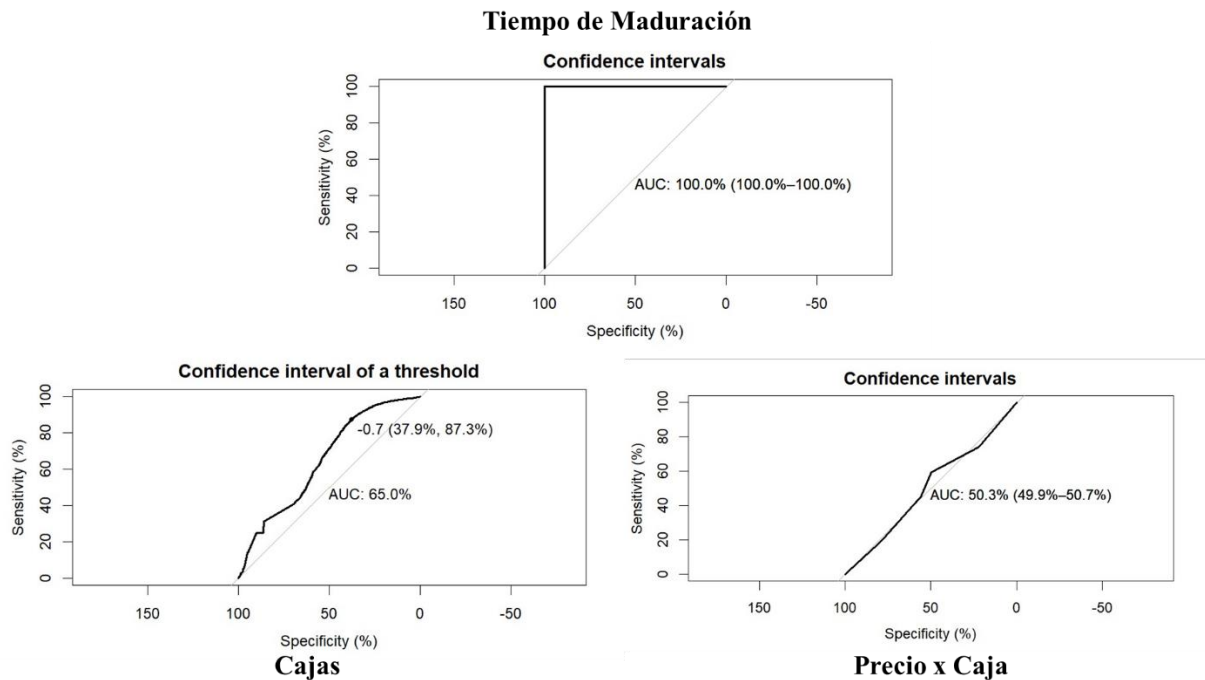
Percent = TRUE: Estas permiten mostrar los valores en porcentaje.

ci = TRUE: Esta permite mostrar los intervalos de confianza.

`print.auc=TRUE`: Imprime el valor del área bajo la curva (AUC).

Figura 16

Curvas ROC



En la Figura 16 observamos las Curvas ROC de las tres variables, la predicción de la clasificación del tiempo de maduración, cajas y precio x caja. Una Curva ROC efectiva debe de tener una forma de triángulo invertido de 90°, que significa que la varianza fue explicada en la totalidad de sus datos. Por ende, la Curva ROC de Tiempo de Maduración es la variable más influyente, siguiéndole el número de cajas.

Creamos un intervalo de confianza para la curva ROC:

```
ciobj <- ci.se(ROC1, specificities = seq(0, 100, 5))
```


```
plot(ciobj, type = "shape", col = "#1c61b6AA")
```

`ci.se ()`: Permite el cálculo del intervalo de confianza para la curva ROC, en intervalos de 5.

A continuación, graficamos la combinación de las Curvas ROC:

Figura 17

Combinación de las Curvas ROC de Tiempo de Maduración y Cajas.



En la Figura 17, observamos la fusión que menciona el Tiempo de Maduración versus las Cajas. A medida que el Tiempo de Maduración se optimiza, el número de cajas se va estabilizando. En otras palabras, a mejor tiempo de maduración habrá más pedidos de cajas de banano.

Proseguimos con el cálculo de la potencia estadística:

```
power.roc.test(roc)
```

```
power.roc.test(ncases = 600, ncontrols = 57, auc = 0.90, sig.level = 0.01)
```

power.roc.test: realiza una prueba de poder especificando con los siguientes argumentos.

Nclases: Número de verdaderos positivos.

Ncontrols: Número de verdaderos negativos.

auc: Es el área bajo la curva AUC.

Sig.level: Nivel de significancia para la prueba.

Figura 18

Potencia Estadística

```
One ROC curve power calculation
```

```
ncases = 600
ncontrols = 57
auc = 0.9
sig.level = 0.01
power = 1
```

Por último, se analiza la potencia estadística del objeto, el número de casos que se observó fueron 600, en donde salió que la Curva ROC es garantizada.

```
Predictor1 <- plot.roc(dfcor$Class,dfcor$Tiempo.de.Maduracion, main
  = "Statistical comparison", col = "#1c61b6")

Predictor2 <- lines.roc(dfcor$Class,dfcor$Cajas, col = "#008600")


testobj <- roc.test(Predictor1,Predictor2)

text(.5,.5,labels = paste("p - value = ",format.pval(testobj$p.value)),adj = c(0,.5))

legend("bottomright",legend = c("Maduracion","Cajas"), col = c("#1c61b6", "#008600"),lwd
  = 2)
```

Figura 19

Comparación de las 2 Curvas ROC

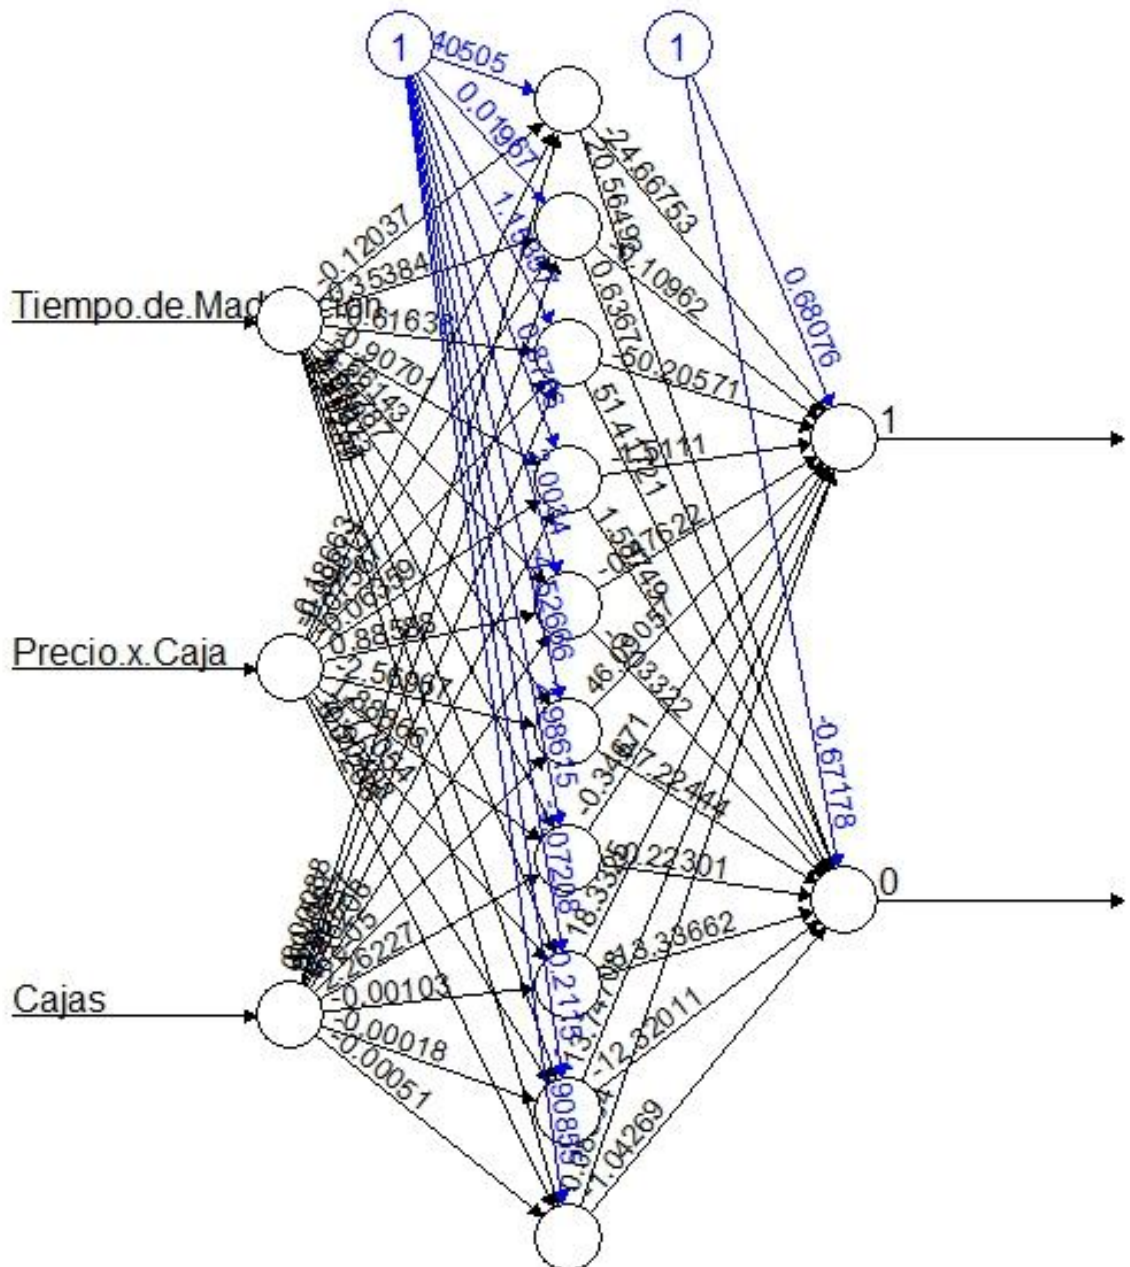


Los datos al ser recopilados en un archivo de Excel, se encuentra con formato .csv que permite la estructura tabular al proyectar valores y tablas en R studio. Como se mencionó anteriormente la base es llamada: "Banano" en honor a la investigación a realizar.

Se ejecuta el modelo de la red neuronal artificial para la clasificación optimizada, anteriormente se observó que las capas ocultas eran de 5, pero para estar más seguros utilizados 10 capas ocultas para el modelo.

Figura 20

Red Neuronal Artificial para la Clasificación



La red neuronal artificial para la clasificación posee diez capas ocultas, a pesar de esto, mediante su función de activación necesitó dos nodos estabilizadores que tratan de estabilizar la varianza para encontrar un patrón de comportamiento que ajuste dentro del modelo y disminuye la raíz del error cuadrático medio, en resumen, reduce los errores de clasificación, tanto para la capa oculta como para la capa de salida; en otras palabras, aquellos que son exportados y aquellos que no lo son, esto es debido a que existe mucha variabilidad en el número de cajas que se ha pedido a lo largo de los años analizados.

Se escogió diez datos al azar para comprobar la efectividad del modelo.

Tabla 5

Predicción de los Productos exportables y no exportables.

Tiempo de Maduración	Precio x Caja	Cajas	Exportación	Prob [, 1]	Prob [, 2]	Class [, 1]	Class [, 2]
11	6,26	1199	1	1,87E-11	1,00E+06	0	1
11	6,26	1001	1	1,46E-11	1,00E+06	0	1
12	6,3	500	1	6,37E-02	0,9999	0	1
12	6,3	359	1	6,37E-02	0,9999	0	1
12	6,3	399	1	6,35E-02	0,9999	0	1
13	6,4	1000	0	0,9999947	8,05E+00	1	0
13	6,4	1196	0	0,9999942	8,29E+00	1	0
13	6,4	1200	0	0,9999941	8,31E+00	1	0
13	6,26	1080	0	1	1,10E-02	1	0
13	6,26	2160	0	1	4,50E-02	1	0

Como podemos observar en la Tabla 5, el modelo ha clasificado muy bien los productos exportables y aquellos que se quedan como venta local. En definitiva, como podemos comprobar que, a trece días de maduración, el producto ya no es recomendable para exportación, sino más bien es considerado como venta local. Siempre y cuando sean entre once semanas y cercano a doce días, existe una alta probabilidad de exportar el producto.

Conclusiones

Se pudo determinar que mediante la revisión de literatura exhaustiva sobre las teorías y conceptos de la Inteligencia Artificial, Machine Learning y las Redes Neuronales Artificiales para su clasificación nos permitió comprender como está el conocimiento general

sobre estos temas de actualidad y a su vez los diversos factores que afectan directamente en la producción de los diferentes tipos de banano ecuatoriano nos brindó un enfoque más específico y exacto de lo que significa este sector en la economía del Ecuador. Por ende, se puede concluir que esta investigación ha resultado satisfactoria al recopilar diversas fuentes de teorías para su posterior análisis.

De igual manera, la identificación del mejor modelo a utilizar que fueron las redes neuronales artificiales para la clasificación, y su metodología correspondiente ha permitido identificar un modelo de clasificación de datos el cual nos permitiría comprender el procedimiento de engloba las redes neuronales artificiales para la clasificación y de este modo aportar para su continua innovación.

La implementación de las redes neuronales artificiales para la clasificación ha demostrado tener un gran impacto en diversos aspectos tanto en ramas económicas y sociales, siendo una pieza clave de la innovación. Estas tienen la capacidad de manejar datos bastantes complejos, logrando aprender patrones complejos a partir de los datos y permitiendo una identificación precisa de las categorías de productos y las tendencias de las exportaciones de banano.

Empleando este modelo, se permitió vislumbrar diversos datos cuantitativos, y facilitando los gráficos para la interpretación garantizando un análisis efectivo y rápido, y de esta manera, encontrar la correcta clasificación. Es esencial recalcar que, en este caso, el banano siendo el producto exportable analizado, su tiempo de maduración resultó ser de carácter fundamental para determinar si es exportable o queda como venta local, observando que el modelo clasificó correctamente los tipos de banano sean exportables o no, permitiendo identificar variables de las cuales los productores pueden tomar en cuenta para mejorar sus cultivos, y aprovechar al máximo la cosecha.

Para concluir, queremos especificar un estudio similar a nuestro proyecto para recalcar el gran uso que tiene la utilización de las redes neuronales artificiales para la clasificación.

Según Aguilar-Alvarado y Campoverde-Molina (2020), en el presente estudio se desarrolló un prototipo de clasificación de banano por calidad basado en redes neuronales convolucionales con el objetivo de disminuir el tiempo de selección de racimos de banano para su clasificación y exportación el cual contribuye al sector bananero colombiano.

Este proceso de operación se lo realizaba manualmente y de manera empírica por los trabajadores y llegaba a tomar casi 4 horas según la norma NTC 1190. Utilizando una red neuronal convolucional que se utiliza en una Raspberry Pi3 B y una cámara que captura una base de datos aumentada con un total de 1050 fotos divididos para 3 categorías. Se probó diferentes valores de lote para dos arquitecturas diferentes dando como resultado que MobileNetV2 la cual es una arquitectura liviana hecha para ser implementada en dispositivos móviles para su mayor precisión obtuvo mejores resultados frente a Inception V3 con diferentes valores de lote.

Esta arquitectura MobileNetV2 fue entrenada mediante la técnica de aprendizaje de datos para ahorrar tiempo de procesamiento y el costo computacional donde logró la precisión más consistente con 100 lotes. Por otro lado, los resultados de la matriz de confusión muestran una buena generalización de estas categorías y por tanto un rendimiento óptimo de la clasificación del modelo.

El resultado es un modelo MobileNetV2 con una precisión del 87%, una puntuación F1 del 86,3%, una especificidad del 93,3% y una precisión del 87%, por lo que este trabajo contribuye a la posibilidad de una clasificación de entidades automática, rápida y confiable. Ayuda a los empleados de la empresa bananera a realizar la tarea de manera eficiente, ahorrando tiempo.

De los resultados recopilados, podemos concluir que el aprendizaje por transferencia es una excelente técnica para obtener un modelo suficiente para resolver el problema reduciendo las iteraciones de entrenamiento.

También se debe de considerar que MobileNet V2 logró el mejor rendimiento a pesar de tener un modelo más pequeño en comparación con otras arquitecturas; por lo tanto, es posible que utilizar una red grande no proporcione los mejores resultados.

Para problemas como este, donde hay una pequeña cantidad de datos disponibles para tareas de entrenamiento y validación, el uso de modelos previamente entrenados es una ventaja significativa, ya que al reducir el tiempo de procesamiento y utilizar una arquitectura específica con buena evidencia de rendimiento, los investigadores pueden centrarse en la obtención de más datos en vez de crear un modelo desde cero.

Por lo expuesto anteriormente, podemos inferir que el uso de las redes neuronales artificiales permite la resolución de problemas diversos como la clasificación debido a que consiste en diversas capas de filtro convolucionales que recibe una imagen de entrada con matrices de Kernel. Las capas convolucionales están destinadas a extraer características de las imágenes de entrada, las capas de submuestreo reducen tanto el tamaño espacial como la complejidad computacional, y las capas totalmente conectadas clasifican los datos.

Por ende, la aplicación de las redes neuronales artificiales para la clasificación, permite extraer patrones complejos contribuyendo a la correcta toma de decisiones, donde estas decisiones estratégicas pueden tener un gran impacto significativo en el éxito comercial. En resumen, en este mundo globalizado, las redes neuronales artificiales para la clasificación debido a su gran capacidad de procesamiento, permite que nos adaptemos a cambios dinámicos, mejorando la precisión de la clasificación contribuyendo a la mejoría en todos los aspectos.

Referencias

- Ácaro-Chamba, L. M., Córdoba-Montoya, A. N., Vega-Granda, A. del C., y Sánchez-Quezada, T. X. (2021). Evolución en las exportaciones de banano e impacto del desarrollo económico, provincia de El Oro 2011-2020, prepandemia, pandemia; aplicando series de tiempo. *Polo Del Conocimiento*, 6(8), 257–277. <http://repositorio.utmachala.edu.ec/handle/48000/17663>
- Acosta-Palomeque, G., Pazmiño-Arroyo, H., y Cerda-Prado, N. (2018). Inversión Extranjera Directa, Exportaciones y Crecimiento Económico en América Latina. *Economía y Negocios*, 9(2), 14-25. <https://doi.org/10.29019/eyn.v9i2.502>
- Agronet (2019). *La inteligencia artificial ayuda a los productores de banano a proteger la fruta favorita del planeta*. <https://www.agronet.gov.co/Noticias/Paginas/La-inteligencia-artificial-ayuda-a-los-productores-de-banano-a-proteger-la-fruta-favorita-del-planeta.aspx>
- Aguilar-Alvarado y Campoverde-Molina (2020). *Clasificación de frutas basadas en redes neuronales convolucionales*. Dialnet <https://dialnet.unirioja.es/servlet/articulo?codigo=7436055>
- Alpaydin, E. (2020). *Introduction to Machine Learning*. Londres, Inglaterra: Massachusetts Institute of Technology. <https://mitpress.mit.edu/9780262043793/introduction-to-machine-learning/>
- Aprende IA. (2021). *Todo sobre aprendizaje supervisado en Machine Learning*: <https://aprendeia.com/category/machine-learning-o-aprendizaje-automatico/>
- Arreaga, A. (2020) *Diseño de modelo Six Sigma para optimización de proceso de Asociación para el Progreso de la Dirección*. Tesis de Maestría, Universidad Tecnológica Empresarial de Guayaquil]. <http://biblioteca.uteg.edu.ec:8080/bitstream/handle/123456789/1161/Dise%C3%B1o%20de%20modelo%20Six%20Sigma%20para%20optimizaci%C3%B3n%20de%20proceso%20de%20producci%C3%B3n%20bananera%20en%20la%20compa%C3%B1%C3%ADa%20Marisbell%20S.A..pdf?sequence=1&isAllowed=y>
- Asociación para el Progreso de la Dirección (2019). *¿Cuáles son los tipos de algoritmos del machine learning?* <https://www.apd.es/algoritmos-del-machine-learning/>
- Basogain (2023) *Redes Neuronales Artificiales y sus Aplicaciones*. Escuela Superior de Ingeniería de Bilbao, EHU.

- https://ocw.ehu.es/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf
- Becker, S. (1991). Unsupervised Learning Procedures for Neural Networks. *International Journal of Neural Systems*, 2, 17-33. https://www.researchgate.net/publication/220117478_Unsupervised_Learning_Procedures_for_Neural_Networks
- Berrú, M. A. E. (2021). Análisis de regulación del precio de la caja de banano en Ecuador período 2015- 2020. Erazo Berrú | *Revista Metropolitana de Ciencias Aplicadas*. <https://remca.umet.edu.ec/index.php/REMCA/article/view/429/449>
- Berzal, F. (2023). *Redes Neuronales*. Departamento de Ciencias de la Computación e I.A. Universidad de Granada. <https://elvex.ugr.es/decsai/deep-learning/slides/NN0%20Neural%20Networks.pdf>
- Calderón, A., Dini, M. y Stumpo, G (2016) Los desafíos del Ecuador para el cambio estructural con inclusión social. CEPAL. Recuperado de: <https://repositorio.cepal.org/server/api/core/bitstreams/8de176a8-8d04-457e-9e4f-bec66245ce5b/content>
- Camacho, M. y Reyna, C. (2022) *Análisis de la clasificación basado en el concepto Machine Learning por tipo de cliente en la empresa Tecopesca C.A.* [Tesis de Grado, Universidad Católica Santiago de Guayaquil]. <http://repositorio.ucsg.edu.ec/bitstream/3317/18340/1/T-UCSG-PRE-CEAC-CNI-24.pdf>
- Carrión, R. (2020). *Predicción de precios de criptomonedas con random forest*. [Tesis del Proyecto Fin de Carrera / Trabajo Fin de Grado. Escuela Técnica Superior de Ingeniería Industrial]. <https://oa.upm.es/62842/>
- Casco, R. J. E., Camargo, M. R. S., Taípe, M. A. V., Del Carmen Gonzales-Sánchez, A., Romero-Carazas, R., y Chiparra, W. E. M. (2023). *Metodología Y Estadística En La Investigación Científica. En Puerto Madero Editorial eBooks*. <https://doi.org/10.55204/pmea.17>
- Coba, G. (2022) 2022 se perfila como un año complejo para el sector bananero. Primicias. Recuperado de: <https://www.primicias.ec/noticias/economia/exportaciones-banano-ecuador-problemas-precio/>
- Coder, R. (2020) *Fijar semilla en R*. R CODER. <https://r-coder.com/fijar-semilla-r/>
- Date, S. (2020). *Generalized Linear Models*. <https://towardsdatascience.com/generalized-linear-models-9ec4dfe3dc3f>

- Díaz Muñoz, G. A., Quintana Lombeida, M. D., y Fierro Mosquera, D. G. (2021). La Competitividad como factor de crecimiento para las organizaciones. *INNOVA Research Journal*, 6(1), 145–161. <https://doi.org/10.33890/innova.v6.n1.2021.1465>
- El Ministerio de Agricultura y Ganadería, Acuacultura y Pesca [MAGAP] (2020) *MAGAP fijó nuevo precio para la caja de banano*. *Agricultura*. <https://www.agricultura.gob.ec/magap-fijo-nuevo-precio-para-la-caja-de-banano/>
- Elbehri, A., G. Calberto, C. Staver, A. Hospido, L. Roibas, D. Skully, P. Siles, J. Arguello, I. Sotomayor, y A. Bustamante. (2015) Cambio climático y sostenibilidad del banano en el Ecuador: Evaluación de impacto y directrices de política. Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), Roma, Italia. Recuperado de: <https://www.fao.org/3/i5116s/i5116s.pdf>
- Erazo Berrú, M. A., Prado Carpio, E., Cervantes Álava, A., & Vite Cevallos, H. (2021). Análisis de regulación del precio de la caja de banano en Ecuador período 2015- 2020. *Revista Metropolitana de Ciencias Aplicadas*, 4(S1), 210-217. Recuperado de: <https://remca.umet.edu.ec/index.php/REMCA/article/download/429/449>
- Gálvez, J.M (2017) El cultivo de banano se ve afectado por el cambio climático. *BananoTecnica*. Recuperado de: <https://bananotecnia.com/noticias/el-cultivo-de-banano-se-ve-afectado-por-el-cambio-climatico/>
- Guerrero, A. L. (2017). Análisis de la Cadena de Producción y Comercialización del Banano en Ecuador-Periodo 2013- 2015”. In *Super Intendencia del control de poder de mercado*.
- Gutiérrez-Rosas, P., Vásquez-López, J., Hernández-Ripalda, M. y Ríos-Lira, A. (2012) Aplicación de la Red Neuronal Probabilística para la clasificación de productos conforme a sus especificaciones. *Eleventh LACCEI Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2013) Innovation in Engineering, Technology and Education for Competitiveness and Prosperity” August 14 - 16, 2013 Cancun, Mexico*. <https://laccei.org/LACCEI2013-Cancun/RefereedPapers/RP015.pdf>
- Haenlein, M., y Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), 5–14. <https://journals.sagepub.com/doi/abs/10.1177/0008125619864925>
- Haleem, A., Javaid, M., Qadri, M. A., Singh, R. P., y Suman, R. (2022). Artificial intelligence (AI) Applications for Marketing: A literature-based study. *International Journal of Intelligent Networks*, 3, 119-132. <https://doi.org/10.1016/j.ijin.2022.08.005>

- IBM Cloud Education. (2021). *Redes neuronales*. IBM. <https://www.ibm.com/cloud/learn/neural-networks>
- Instituto para la Innovación Tecnológica de la agricultura [INTAGRI] (2018) *Requerimientos de Clima y Suelo para el Cultivo de Banano*. <https://www.intagri.com/articulos/frutales/requerimientos-de-clima-y-suelo-para-el-cultivo-de-banano> - Esta información es propiedad intelectual de INTAGRI S.C., Intagri se reserva el derecho de su publicación y reproducción total o parcial.
- International Business Machine Corporation. (2017). *¿Qué es Machine Learning?* <https://www.ibm.com/mx-es/analytics/machine-learning#:~:text=Machine%20learning%20es%20una%20forma,m%C3%A1s%20>
- Jiménez, D. (2019). Universidad del País Vasco.
- Lean, G. (2019). *Qué son las redes neuronales y sus funciones*. <https://www.atriainnovation.com/que-son-las-redes-neuronales-y-sus-funciones/#:~:text=Las%20redes%20neuronales%20artificiales%20son,entrada>
- Lee, J. (2019). *Autoencoders: Neural Networks for Unsupervised Learning*. <https://medium.com/intuitive-deep-learning/autoencoders-neural-networks-forunsupervised-learning-83af5f092f0b>
- León, L., Arcaya, M., Barbotó, N. y Bermeo, Y. (2018) Ecuador: Análisis comparativo de las exportaciones de banano orgánico y convencional e incidencia en la balanza comercial, 2018. *Revista Científica y Tecnológica UPSE*. Vol. 7, Nº 2 Diciembre 2020, 38-46. <https://incyt.upse.edu.ec/ciencia/revistas/index.php/rctu/article/view/521/482>
- Loaiza, Y. (2023). *Por el fenómeno de El Niño se perderán 50.000 hectáreas de banano en Ecuador. infobae*. <https://www.infobae.com/america/america-latina/2023/07/04/por-el-fenomeno-de-el-nino-se-perderan-50000-hectareas-de-banano-en-ecuador/>
- López, A. (2017) *Análisis de la Cadena de Producción y Comercialización del Banano en Ecuador-Periodo 2013 – 2015*. <https://docplayer.es/151783802-Version-publica-tema-analisis-de-la-cadena-de-produccion-y-comercializacion-del-banano-en-ecuador-periodo.html>
- Madan, I., Saluja, S., y Zhao, A. (2022). *Automated Bitcoin Trading via Machine Learning Algorithms*. Stanford University. IA & Research Department: <https://cs229.stanford.edu/proj2014/Isaac%20Madan,%20Shaurya%20Saluja,%20Aojia%20Zhao,Automated%20Bitcoin%20Trading%20via%20Machine%20Learning%20Algorithms.pdf>

- Management Solutions. (2018). *Machine Learning, una pieza clave en la transformación de los modelos de negocio*. © Management Solutions, 1(1).
<https://www.managementsolutions.com/es/publicaciones-y-eventos/informes-sectoriales/white-papers/machine-learning-una-pieza-clave-en-la-transformacion-de-los-modelos-de-negocio>
- Martínez-González, M., Balois-Morales, R., Alia-Tejacal, I., Cortes-Cruz, M.A., Palomino-Hermosillo, Y.A y López-Gúzman, G.G (2017) Poscosecha de frutos: maduración y cambios bioquímicos. Instituto Nacional de Investigaciones. Recuperado de: <https://www.redalyc.org/journal/2631/263153823018/html/>
- Martínez-Solórzano, G.E. y Reya-Brina, J.C (2021) Bananos (Musa AAA): Importancia, producción y comercio en tiempos de Covid-19. Universidad de Costa Rica. Recuperado de: <https://www.redalyc.org/journal/437/43768194023/html/>
- Matich, D. (2001). *Redes neuronales: conceptos básicos y aplicaciones*. Universidad Tecnológica Nacional.
https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadoral/monografias/matich-redesneuronales.pdf
- Ministerio de Comercio Exterior (2017) *Informe Sector Bananero Ecuatoriano*.
<https://www.produccion.gob.ec/wp-content/uploads/2019/06/Informe-sector-bananero-espa%C3%B1ol-04dic17.pdf>
- Mitchell, T. (2021). *Machine Learning*. McGraw-Hill.
- Montaño, J. (2018). *Redes Neuronales Artificiales aplicadas al análisis de datos*. [Tesis Doctoral Universitat de les illes balears].
<https://www.tdx.cat/handle/10803/9441#page=1>
- Olivera, B. M. y Alex, S. (2020). *Valoración de la estabilidad y el rendimiento de modelos bayesianos en meta-análisis de pruebas diagnósticas, basada en estudios de simulación*. <https://doi.org/10.14201/gredos.143554>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO] (2021) *Capítulo 1. Panorama General de la Producción y El Comercio Mundial del Banano*.
<https://www.fao.org/3/y5102s/y5102s04.htm>
- Padilla Barreto, A., Guillen, M., y Bolancé, C. (2017). *Disposit USB. Bigdata Analytics In Insurance*, 23. ESAP. Big Data Analytics in Insurance:
<http://diposit.ub.edu/dspace/bitstream/2445/120173/1/676957.pdf>
- Parra, P. (2018) *Desarrollo de un Sistema de Automatización y Gestión de la Información en una Línea de Producción de Banano*. [Tesis de Maestría Universidad Politécnica

- Salesiana en Electrónica y Automatización].
<https://dspace.ups.edu.ec/bitstream/123456789/21170/1/UPS-CT009298.pdf>
- Perez, J., y Martin, P. P. (2023). La curva ROC. *Medicina de Familia. SEMERGEN*, 49(1), 101821. <https://doi.org/10.1016/j.semerg.2022.101821>
- Prieto, A. (2018). *Redes Neuronales: modelos y aplicaciones*. Universidad de Granada. <https://digibug.ugr.es/handle/10481/55772?show=full>
- Ramírez, C. y Solórzano, S (2012) Banano rechazado para exportación en Ecuador: propuesta de creación de valor para lograr su introducción al mercado internacional. Universidad Politécnica Salesiana sede Guayaquil, Maestría en Administración de Empresas. Recuperado de: <https://repositorio.cepal.org/server/api/core/bitstreams/8de176a8-8d04-457e-9e4f-bec66245ce5b/content>
- Ramírez, D. (2018). *El Machine Learning a través de los tiempos, y los aportes a la humanidad*.
<https://repository.unilibre.edu.co/bitstream/handle/10901/17289/EL%20MACHINE%20LEARNING.pdf?sequence=1&isAllowed=y>
- Rouhiainen, L. (2018). Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro [Digital]. Alianza Editorial.
https://proassetspdlcom.cdnstatics2.com/usuaris/libros_contenido/arxius/40/39307_Inteligencia_artificial.pdf
- Rusell (2019) Inteligencia Artificial. Un enfoque moderno. Segunda Edición, PEARSON.
<https://luismejias21.files.wordpress.com/2017/09/inteligencia-artificial-un-enfoque-moderno-stuart-j-russell.pdf>
- Russo, C., Ramón, H., Alonso, N., Cicerchia, B., Esnaola, L., y Tessore, J. P. (2018). *Tratamiento Masivo de Datos Utilizando Técnicas de Machine Learning*. Buenos Aires, Argentina: Instituto de Investigación y Transferencia en Tecnología.
<https://repositorio.unnoba.edu.ar/xmlui/handle/23601/107?show=full>
- Saltos, D. y Villacis, O. (2022) *Implementación de Machine Learning en el área de ventas de la empresa Zapec S.A.* [Tesis de Grado Universidad Católica Santiago de Guayaquil].
<http://repositorio.ucsg.edu.ec/bitstream/3317/18337/1/T-UCSG-PRE-CEAC-CNI-21.pdf>
- Sancho, F. (2021). *Aprendizaje Supervisado y No Supervisado*:
<http://www.cs.us.es/~fsancho/?e=77>
- Somosmarketing. (2020). *La inteligencia artificial mejora la personalización y el customer experience – somos marketing*. <https://somosmarketing.lasprovincias.es/tendencias/la->

[inteligencia-artificial-mejora-la-personalizacion-y-el-customer-experience/#:~:text=La%20definici%C3%B3n%20que%20de%20inteligencia,travel%20de%20la%20adaptaci%C3%B3n%20flexible%20BB.](#)

Stubblefield y Luger. (1990). *Artificial Intelligence and the Design of Expert Systems*. Semantic Scholar. <https://www.semanticscholar.org/paper/Artificial-Intelligence-and-the-Design-of-Expert-Luger-Stubblefield/826af5087384f59ae540068eaf6ed04a8a38a7ee>

Suárez, L. G. (2019). Tierra, trabajo y tóxicos: sobre la producción de un territorio bananero en la costa sur del Ecuador. *Estudios Atacameños*, 63(63), 341–364. <https://doi.org/10.22199/ISSN.0718-1043-2019-0034>

Team, D. (2023). Inteligencia artificial: definición, historia, usos, peligros. *Formation Data Science* | *DataScientest.com*. <https://datascientest.com/es/inteligencia-artificial-definicion>

The Observatory of Economic Complexity [OEC] (2017 - 2021) *Plátanos, Product Trade, Exporters and Importers*. <https://oec.world/es/profile/hs/bananas>

Tostado, S., Ornelas, M., Espinal, A., y Puga, H. J. (2015). Implementación De Algoritmos De Inteligencia Artificial Para El Entrenamiento De Redes Neuronales De Segunda Generación. *Jóvenes en la ciencia*, 1(3), 1-5. <http://www.repositorio.ugto.mx/bitstream/20.500.12059/3203/1/Implementaci%C3%B3n%20de%20Algoritmos%20de%20Inteligencia%20Artificial%20para%20el%20Entrenamiento%20de%20Redes%20Neuronales%20de%20Segunda%20Generaci%C3%B3n.pdf>

Universidad de Sevilla (2023) *Conceptos Básicos. Redes Neuronales*. <https://grupo.us.es/gtocom/pid/pid10/RedesNeuronales.htm>

Vásquez-Castillo, W., Racines-Oliva, M., Moncayo, P., Viera, W. y Seraquive, M. (2019) Calidad del fruto y pérdidas poscosecha de banano orgánico (*Musa acuminata*) en el Ecuador. Universidad UTE. Recuperado de: <https://doi.org/10.29019/enfoque.v10n4.545>


Webs, J. (2021). *Aprendizaje supervisado | Qué es y en qué se diferencia del aprendizaje no supervisado*: [https://futuroelectrico.com/aprendizaje-supervisado/#Que es el aprendizaje supervisado](https://futuroelectrico.com/aprendizaje-supervisado/#Que%20es%20el%20aprendizaje%20supervisado)

Yiu, T. (2019). *Understanding Random Forest*. <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>

Anexos

Figura 21

Tipos de arquitectura basadas en el cerebro



Script completo R studio

```
2 Banano <- read.csv2("../Data/TESIS.csv")
3 Banano <- Banano[,c(-1,-5,-6)]
4 install.packages("caret")
5 install.packages("dplyr")
6 library(ggplot2)
7 library(lattice)
8 library(caret)
9 library(dplyr)
10 library(neuralnet)
11 library(colorspace)
12 library(grid)
13 library(VIM)
14 library(pROC)
15 #Analizo si hay NAS en las variables
16 install.packages("VIM")
17 library(VIM)
18 aggr(Banano,
19      col=c("green", "red"),
20      numbers = TRUE,
21      sortVars= TRUE,
22      labels= names(Banano),
23      cex.axis = 0.5,
24      gap = 1,
25      ylab = c("Histograma de NAS", "Patrón"))
26
27 #Paso a factor mi variable dependiente
28 Banano$Exportacion <- factor(Banano$Exportacion,
29                              levels = c(0,1),
30                              labels = c(0,1))
31 #Generamos el entrenamiento
32 set.seed(123)
33
34 Particion <- createDataPartition(Banano$Exportacion, p=.70, list = FALSE)
35
36 Entrenamiento1 <- Banano[ Particion,]
37 Pruebas1 <- Banano[-Particion,]
38
39 #Escalamos las variables independientes
40 Entrenamiento1[,1:3] <- scale(Entrenamiento1[,1:3])
41 Pruebas1[,1:3] <- scale(Pruebas1[,1:3])
42
43 #Modelo
44 ModeloRedNeuronal <- caret::train(Exportacion~.,
45                                  Entrenamiento1,
46                                  method = "nnet",
47                                  trace = FALSE)
48 ModeloRedNeuronal
49
50 plot(ModeloRedNeuronal)
51
52 #Generar Predicciones
53 Entrenamiento1$class <- predict(ModeloRedNeuronal,Entrenamiento1)
54 Pruebas1$class <- predict(ModeloRedNeuronal,Pruebas1)
55
```

```

55
56 #Matriz de confusion
57 EntreMC <- confusionMatrix(Entrenamiento1$class, as.factor(Entrenamiento1$Exportacion))
58 EntreMC
59
60 PruebaMC <- confusionMatrix(Pruebas1$class, as.factor(Pruebas1$Exportacion))
61 PruebaMC
62
63 install.packages("pROC")
64 library(pROC)
65
66 #Importancia de las variables
67 varImp(ModeloRedNeuronal)
68 plot(varImp(ModeloRedNeuronal))
69
70 #creo las curvas sobre las que trabajaré.
71 dfcor<-Entrenamiento1
72 dfcor$class <- as.numeric(dfcor$class)
73
74
75 ROC1 <- plot.roc(dfcor$class,dfcor$Tiempo.de.Maduracion,main="Confidence intervals", percent=TRUE,ci=TRUE,print.auc=TRUE)
76 ROC2 <- plot.roc(dfcor$class,dfcor$Precio.x.Caja,main="Confidence intervals", percent=TRUE,ci=TRUE,print.auc=TRUE)
77 ROC3 <- plot.roc(dfcor$class,dfcor$Cajas,main="Confidence intervals", percent=TRUE,ci=TRUE,print.auc=TRUE)
78
79 #creamos objeto para plotear el IC por defecto al 95% CI. Boots Default: 2000.
80 ciobj <- ci.se(ROC1, specificities=seq(0, 100, 5))
81
82 #insertamos el IC
83 plot(ciobj, type="shape", col="#1c61b6AA") # plot as a blue shape
84
85 #le inserto el punto de corte sobre la gráfica con su IC
86 umbral<-plot.roc(dfcor$class,dfcor$Tiempo.de.Maduracion,
87                 main="Confidence interval of a threshold",
88                 percent=TRUE,ci=TRUE,
89                 of="thresholds",thresholds="best",
90                 print.thres="best")
91
92 umbral<-plot.roc(dfcor$class,dfcor$Cajas,
93                 main="Confidence interval of a threshold",
94                 percent=TRUE,ci=TRUE,
95                 print.auc=TRUE, of="thresholds",
96                 thresholds="best",
97                 print.thres="best")
98
99 plot(ciobj, type="shape", col="#1c61b6AA") # plot as a blue shape
100
101 #potencia estadística de tu objeto.
102 power.roc.test(roc)
103 power.roc.test(ncases=600, ncontrols=57, auc=0.90, sig.level=0.01)
104
105 #Comparacion de 2 curvas
106 Predictor1 <- plot.roc(dfcor$class,dfcor$Tiempo.de.Maduracion,
107                       main="Statistical comparison", col="#1c61b6")
108
109 Predictor2 <- lines.roc(dfcor$class,dfcor$Cajas, col="#008600")
110
111 testobj <- roc.test(Predictor1, Predictor2)
112 text(.5, .5, labels=paste("p-value =", format.pval(testobj$p.value)), adj=c(0, .5))
113 legend("bottomright", legend=c("Maduracion", "Cajas"), col=c("#1c61b6", "#008600"), lwd=2)
114
115 library(neuralnet)
116
117
118
119 rn <- neuralnet(Exportacion~., data = Banano[Particion,], hidden = 10, act.fct="logistic",
120                linear.output = FALSE)
121 plot(rn)
122
123 #Objeto de condicion
124 RnPredEnt <- compute(rn,Banano)
125 Banano$Prob <- RnPredEnt$net.result
126 Banano$class <- ifelse(Banano$Prob>=0.5,1,0)
127
128 #Creamos la matriz de confusion
129 table(Banano$Exportacion,Banano$class[,1],dnn = c("Actual","Predicho"))
130 table(Banano$Exportacion,Banano$class[,2],dnn = c("Actual","Predicho"))
131

```

Muestra de las observaciones

Periodo	Producto	Tiempo de Maduración	Precio x Caja	Cajas	Zona	País de Destino
2017	Cavendish	11	6,26	1199	Los Rios	Rusia
2017	Cavendish	12	6,26	209	Los Rios	Rusia
2017	Cavendish	12	6,26	600	Los Rios	Rusia
2017	Cavendish	12	6,26	2495	Los Rios	Rusia
2017	Cavendish	11	6,26	1001	Los Rios	Rusia
2017	Cavendish	11	6,26	998	Los Rios	Rusia
2017	Cavendish	11	6,26	453	Los Rios	Rusia
2017	Cavendish	11	6,26	571	Los Rios	Rusia
2017	Cavendish	12	6,26	502	Los Rios	Rusia
2017	Cavendish	11	6,26	348	Los Rios	Rusia
2017	Cavendish	11	6,26	546	Los Rios	Rusia
2017	Cavendish	11	6,26	1210	Guayas	Rusia
2017	Cavendish	12	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	2420	Los Rios	Rusia
2017	Cavendish	13	6,26	960	Los Rios	ECUADOR
2017	Cavendish	13	6,26	1080	Los Rios	ECUADOR
2017	Cavendish	13	6,26	500	Los Rios	ECUADOR
2017	Cavendish	13	6,26	364	Los Rios	ECUADOR
2017	Cavendish	13	6,26	624	Los Rios	ECUADOR
2017	Cavendish	13	6,26	1080	Los Rios	ECUADOR
2017	Cavendish	13	6,26	2160	Los Rios	ECUADOR
2017	Baby banana u orito	13	6,26	3080	Los Rios	ECUADOR
2017	Cavendish	11	6,26	2000	Los Rios	Rusia
2017	Cavendish	12	6,26	420	Los Rios	Rusia
2017	Cavendish	12	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	3630	Guayas	Rusia
2017	Cavendish	11	6,26	1210	El Oro	Rusia
2017	Cavendish	12	6,26	709	Los Rios	Rusia
2017	Cavendish	11	6,26	383	Los Rios	Rusia
2017	Cavendish	11	6,26	500	Los Rios	Rusia
2017	Cavendish	11	6,26	576	Los Rios	Rusia
2017	Cavendish	11	6,26	553	Los Rios	Rusia
2017	Cavendish	11	6,26	1049	Los Rios	Rusia
2017	Cavendish	11	6,26	499	Guayas	Rusia
2017	Cavendish	12	6,26	998	Los Rios	Rusia
2017	Cavendish	11	6,26	789	Los Rios	Rusia
2017	Cavendish	11	6,26	800	Los Rios	Rusia
2017	Baby banana u orito	13	6,26	1540	Los Rios	ECUADOR
2017	Cavendish	13	6,26	2160	Los Rios	ECUADOR
2017	Cavendish	13	6,26	486	Los Rios	ECUADOR

2017	Cavendish	13	6,26	790	Los Rios	ECUADOR
2017	Cavendish	11	6,26	600	Los Rios	Rusia
2017	Cavendish	11	6,26	610	Los Rios	Rusia
2017	Cavendish	11	6,26	510	Los Rios	Rusia
2017	Cavendish	11	6,26	700	Los Rios	Rusia
2017	Cavendish	11	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	2329	Los Rios	Rusia
2017	Cavendish	11	6,26	3020	Guayas	Rusia
2017	Cavendish	11	6,26	701	Los Rios	Rusia
2017	Cavendish	11	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	1210	El Oro	Rusia
2017	Cavendish	11	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	1267	Los Rios	Rusia
2017	Cavendish	11	6,26	1153	Los Rios	Rusia
2017	Cavendish	11	6,26	3630	Guayas	Rusia
2017	Cavendish	12	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	1210	Los Rios	Rusia
2017	Cavendish	13	6,26	1080	Los Rios	ECUADOR
2017	Cavendish	13	6,26	711	Los Rios	ECUADOR
2017	Cavendish	13	6,26	449	Los Rios	ECUADOR
2017	Cavendish	13	6,26	2160	Los Rios	ECUADOR
2017	Baby banana u orito	13	6,26	2690	Los Rios	ECUADOR
2017	Baby banana u orito	13	6,26	390	Los Rios	ECUADOR
2017	Baby banana u orito	13	6,26	390	Los Rios	ECUADOR
2017	Baby banana u orito	13	6,26	1540	Los Rios	ECUADOR
2017	Cavendish	13	6,26	2160	Los Rios	ECUADOR
2017	Cavendish	13	6,26	282	Los Rios	ECUADOR
2017	Cavendish	13	6,26	640	Los Rios	ECUADOR
2017	Cavendish	13	6,26	580	Los Rios	ECUADOR
2017	Cavendish	12	6,26	1210	El Oro	Rusia
2017	Cavendish	12	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	4840	Guayas	Rusia
2017	Cavendish	12	6,26	1200	Los Rios	Rusia
2017	Cavendish	12	6,26	1210	Guayas	Rusia
2017	Cavendish	13	6,26	2160	Los Rios	ECUADOR
2017	Cavendish	13	6,26	700	Los Rios	ECUADOR
2017	Cavendish	13	6,26	707	Los Rios	ECUADOR
2017	Cavendish	13	6,26	643	Los Rios	ECUADOR
2017	Cavendish	13	6,26	2400	Los Rios	ECUADOR
2017	Cavendish	12	6,26	3630	Guayas	Rusia
2017	Cavendish	11	6,26	1210	Los Rios	Rusia
2017	Cavendish	11	6,26	1210	Los Rios	Rusia
2017	Cavendish	12	6,26	117	Guayas	Rusia
2017	Cavendish	11	6,26	11	Los Rios	Rusia

2017	Cavendish	12	6,26	280	Los Rios	Rusia
2017	Cavendish	11	6,26	552	Los Rios	Rusia
2017	Cavendish	12	6,26	308	Los Rios	Rusia
2017	Cavendish	12	6,26	390	Los Rios	Rusia
2017	Cavendish	12	6,26	901	El Oro	Rusia
2017	Cavendish	11	6,26	560	Los Rios	Rusia
2017	Cavendish	11	6,26	569	Guayas	Rusia
2017	Cavendish	11	6,26	660	Los Rios	Eslovenia
2017	Cavendish	12	6,26	299	Los Rios	Eslovenia
2017	Cavendish	11	6,26	213	Los Rios	Eslovenia
2017	Cavendish	12	6,26	1414	Los Rios	Eslovenia
2017	Cavendish	11	6,26	22	Los Rios	Eslovenia
2017	Cavendish	11	6,26	995	Los Rios	Eslovenia



**Presidencia
de la República
del Ecuador**



**Plan Nacional
de Ciencia, Tecnología,
Innovación y Saberes**



DECLARACIÓN Y AUTORIZACIÓN

Nosotros, **Bravo Mero, Josselyn Camilla** con C.C: #0951068543 y **Riofrio Cedeño, María José**, con C.C: #0957961907 autores del trabajo de integración curricular: **Optimización de las exportaciones de banano ecuatorianas mediante un clasificador basado en redes neuronales**. previo a la obtención del título de **Licenciado en Negocios Internacionales** en la Universidad Católica de Santiago de Guayaquil.

1.- Declaro tener pleno conocimiento de la obligación que tienen las instituciones de educación superior, de conformidad con el Artículo 144 de la Ley Orgánica de Educación Superior, de entregar a la SENESCYT en formato digital una copia del referido trabajo de integración curricular para que sea integrado al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública respetando los derechos de autor.

2.- Autorizo a la SENESCYT a tener una copia del referido trabajo de integración curricular, con el propósito de generar un repositorio que democratice la información, respetando las políticas de propiedad intelectual vigentes.

Guayaquil, 09 de febrero de 2024

f. _____
Bravo Mero, Josselyn Camilla

C.C: 0951068543

f. _____
Riofrio Cedeño, María José

C.C: 0957961907



REPOSITORIO NACIONAL EN CIENCIA Y TECNOLOGÍA

FICHA DE REGISTRO DE TRABAJO DE INTEGRACIÓN CURRICULAR

TEMA Y SUBTEMA:	Optimización de las exportaciones de banano ecuatorianas mediante un clasificador basado en redes neuronales.		
AUTOR(ES)	Bravo Mero, Josselyn Camilla y Riofrio Cedeño, María José		
REVISOR(ES)/TUTOR(ES)	Ing. Carrera Buri, Félix Miguel, Mgs.		
INSTITUCIÓN:	Universidad Católica de Santiago de Guayaquil		
FACULTAD:	Facultad de Economía y Empresas		
CARRERA:	Negocios Internacionales		
TÍTULO OBTENIDO:	Licenciado en Negocios Internacionales		
FECHA DE PUBLICACIÓN:	09 de febrero de 2024	No. DE PÁGINAS:	68
ÁREAS TEMÁTICAS:	Ciencia de decisiones, Negocios, administración y contabilidad, Ciencias computacionales, Análisis de datos y modelado predictivo.		
PALABRAS CLAVES/ KEYWORDS:	Innovación, Análisis de datos, Inteligencia Artificial, Redes Neuronales Artificiales para la clasificación, exportaciones, banano.		
RESUMEN/ABSTRACT:	<p>Las exportaciones son parte esencial para el crecimiento del país en la actualidad, donde la innovación y la automatización de procesos con el uso del análisis de datos es una herramienta eficaz para mejorar la clasificación de los productos identificando las variables claves que influyen directamente. No obstante, el entendimiento y la utilización de conceptos de inteligencia artificial, como lo son las redes neuronales artificiales para la clasificación siguen siendo un desafío, esto porque es un proceso complejo y que se está desarrollando e innovando periódicamente. Pese a estos desafíos, es fundamental que las empresas vayan adaptando sus procesos a esta nueva era de la digitalización para poder desarrollar una ventaja competitiva. La clasificación de los productos y la identificación de las variables que afectan en su exportación son primordiales, debido a que permiten a las empresas adoptar nuevas estrategias para la producción de los productos. La presente investigación se enfoca en el desarrollo de un modelo de redes neuronales artificiales para la clasificación de bananos ecuatorianos para la exportación, en el cual se espera lograr un mínimo error en la predicción de clasificación de los tipos de banano. El objetivo es determinar cuáles son las variables que afectan directamente a la exportación del banano. La aplicación de las redes neuronales artificiales para la clasificación se justifica debido a que este sector es una de las principales industriales en la economía de nuestro país.</p>		
ADJUNTO PDF:	<input checked="" type="checkbox"/> SI	<input type="checkbox"/> NO	
CONTACTO CON AUTOR/ES:	Teléfono: +593-939822853 +593-959209103	E-mail: jossybravo2002@gmail.com Majoriofrioc@gmail.com	
CONTACTO CON LA INSTITUCIÓN (COORDINADOR DEL PROCESO UIC):	Nombre: Freire Quintero Cesar Enrique		
	Teléfono: +593-990090702		
	E-mail: cesar.freire@cu.ucsg.edu.ec		
SECCIÓN PARA USO DE BIBLIOTECA			
Nº. DE REGISTRO (en base a datos):			
Nº. DE CLASIFICACIÓN:			
DIRECCIÓN URL (tesis en la web):			