



Universidad Autónoma Chapingo

Posgrado en Ingeniería Agrícola y Uso Integral del
Agua

ESTIMACIÓN DE BIOMASA DE MAÍZ FORRAJERO A PARTIR DE IMÁGENES DE DRONES Y APRENDIZAJE PROFUNDO

Tesis

Que como requisito parcial
para obtener el grado de:

**MAESTRO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA**

Presenta:

FRANCISCO MUÑOZ BUSTOS

Bajo la supervisión de:

Gilberto de Jesús López Canteñs

Doctor en Ingeniería Agrícola y Uso Integral del Agua

Chapingo, Estado. de México, noviembre del 2023



ESTIMACIÓN DE BIOMASA DE MAÍZ FORRAJERO A PARTIR DE IMÁGENES DE DRONES Y APRENDIZAJE PROFUNDO

Tesis realizada por **FRANCISCO MUÑOZ BUSTOS** bajo la supervisión del
Comité Asesor indicado, aprobada por el mismo y aceptada como requisito
parcial para obtener el grado de:

MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

Director:



Dr. Gilberto de Jesús López Canteñs

Asesor:



Dr. Irineo Lorenzo López Cruz

Asesor:



Dr. Noel Chávez Aguilera

CONTENIDO

1	INTRODUCCIÓN GENERAL	1
1.1	OBJETIVO GENERAL	4
1.1.1	<i>Objetivos Específicos</i>	<i>4</i>
2	MARCO TEÓRICO	5
2.1	EL MAÍZ	5
2.2	BIOMASA, MÉTODOS DE ESTIMACIÓN	7
2.3	SISTEMAS AÉREOS NO TRIPULADOS.....	9
2.3.1	<i>Sensores</i>	<i>11</i>
2.4	ÍNDICES DE VEGETACIÓN.....	14
2.5	REDES NEURONALES ARTIFICIALES.....	16
2.5.1	<i>Algoritmo de retropropagación del error</i>	<i>20</i>
2.5.2	<i>Entrenamiento de una red neuronal artificial</i>	<i>25</i>
3	MATERIALES Y MÉTODOS	31
3.1	SITIO EXPERIMENTAL	31
3.2	DRON DJI MAVIC 3M.....	32
3.3	PLANEACIÓN DE LOS VUELOS Y MUESTREO EN CAMPO	32
3.4	CÁLCULO DE LOS ÍNDICES DE VEGETACIÓN	35
3.5	PRE-PROCESAMIENTO DE LOS DATOS	36
3.6	DISEÑO DE LA RED NEURONAL ARTIFICIAL	37
3.7	ENTRENAMIENTO DE LA RNA	38
3.8	ANÁLISIS DEL RENDIMIENTO DE LA RNA.....	38
4	RESULTADOS Y DISCUSIÓN.....	40
4.1	ANÁLISIS ESTADÍSTICO DE LOS DATOS DE ALTURA Y PESO.....	40
4.2	ANÁLISIS DEL PRE-PROCESAMIENTO DE LA BASE DE DATOS.....	42
4.3	ANÁLISIS DEL ENTRENAMIENTO DE RED NEURONAL ARTIFICIAL	44
4.4	ANÁLISIS DEL RENDIMIENTO DE LA RNA.....	45
5	CONCLUSIONES	50

6	RECOMENDACIONES.....	51
7	REFERENCIAS	52
8	ANEXO A: CARACTERÍSTICAS DEL DRONE DJI MAVIC 3	59
9	ANEXO B: ARCHIVOS GENERADOS	61

ÍNDICE DE CUADROS

<i>Cuadro 1 Resumen de las características, ventajas y desventajas de los sensores utilizados en drones.....</i>	<i>13</i>
<i>Cuadro 2 Índices de vegetación más utilizados en la estimación de biomasa aérea de maíz forrajero.....</i>	<i>15</i>
<i>Cuadro 3 Funciones de activación más utilizadas en el algoritmo de retropropagación del error y sus derivadas.....</i>	<i>23</i>
<i>Cuadro 4 Estadísticos de las variables número de plantas, altura con espiga y biomasa</i>	<i>40</i>
<i>Cuadro 5 Resumen de los resultados obtenidos</i>	<i>46</i>
<i>Cuadro 6 Errores absolutos del modelo predictivo entrenado y probado con la tercera partición de la base de datos</i>	<i>48</i>

ÍNDICE DE FIGURAS

<i>Figura 1 Comportamiento de la etapas fisiológicas del maíz. Recuperado de https://cienciasagricolas.inifap.gob.mx/index.php/agricolas/article/view/2587/501</i>	6
<i>Figura 2 Corte transversal de una mazorca para mostrar la línea de leche. Recuperado de Endicot, et al., 2015</i>	6
<i>Figura 3 Clasificación de los sistemas aéreos no tripulados. Fuente Propia, Información recuperada de (Pino, 2019)</i>	10
<i>Figura 4 Tipo de drones; Recuperado de: https://www.academiadronchile.cl/estos-los-diferentes-tipos-drones-existen-mercado/</i>	10
<i>Figura 5 Uso de los diferentes sensores, recuperado de (Wang, et. al., 2021)</i>	13
<i>Figura 6 Diagrama de Venn-Euler sobre las partes de la Inteligencia Artificial.</i>	17
<i>Figura 7 Red Neuronal Artificial monocapa</i>	18
<i>Figura 8 Red Neuronal Artificial multicapa</i>	19
<i>Figura 9 Pasos generales para lograr implementar de una RNA para resolver un problema en específico</i>	26
<i>Figura 10 Sitio experimental "La Cerona"</i>	31
<i>Figura 11 Drone DJI Mavic 3M, fuente: https://elvuelodeldrone.com/drones-profesionales/drones-dji/mavic-3-multiespectral/</i>	32
<i>Figura 12 Antena D-RTK 2</i>	33
<i>Figura 13 GPS-RTK Trimble obtenido de https://www.4kequipment.com/trimble-single-r10-m1-v1-receiver-gps-kit-w-tsc3-data-collector-access-software/</i>	33
<i>Figura 14 Ráster del terreno obtenido al aplicar el índice de vegetación NDVI</i>	34
<i>Figura 15 Procedimiento de medición y pesado de las muestras</i>	35
<i>Figura 16 Media de NDVI para la muestra F80</i>	36

<i>Figura 17 Arquitectura de la Red Neuronal Artificial usada para estimar la biomasa del maíz.....</i>	<i>37</i>
<i>Figura 18 Histograma de la altura de las plantas con espiga</i>	<i>41</i>
<i>Figura 19 Histograma del número de plantas por área muestreada</i>	<i>41</i>
<i>Figura 20 Histograma de la biomasa aérea de maíz</i>	<i>41</i>
<i>Figura 21 Matriz de correlación.....</i>	<i>42</i>
<i>Figura 22 Diagrama de dispersión de la altura de las plantas vs la biomasa aérea de maíz.....</i>	<i>43</i>
<i>Figura 23 Varianza explicada por cada componente principal.....</i>	<i>44</i>
<i>Figura 24 Gráfica de los ecm vs épocas, se muestra el comportamiento del ecm para cada entrenamiento de la RNA, a) Primer entrenamiento, b) Segundo entrenamiento, c) Tercer entrenamiento.....</i>	<i>45</i>
<i>Figura 25 Gráfica de regresión lineal y valor de los coeficientes de rendimiento del tercer entrenamiento del modelo de la RNA</i>	<i>46</i>
<i>Figura 26 Gráfica de regresión y valor de los coeficientes de evaluación de la RNA para la tercera base de datos.....</i>	<i>47</i>
<i>Figura 27 Gráfica de regresión y valor de los coeficientes de evaluación de la RNA para la primera base de datos.....</i>	<i>48</i>
<i>Figura 28 Gráfica de regresión y valor de los coeficientes de evaluación de la RNA para la segunda base de datos</i>	<i>49</i>
<i>Figura 29 Código QR a la liga al repositorio de GitHub con los archivos y programas utilizados en el trabajo de investigación.....</i>	<i>61</i>

AGRADECIMIENTOS

Agradezco de sobremanera para la elaboración de esta tesis a la Universidad Autónoma Chapingo, mi segunda alma máter por darme la oportunidad de seguirme formando en el ámbito profesional y personal. Al Tecnológico Nacional de México Campus Iztapalapa II por darme la oportunidad de laborar mientras realizaba mis estudios.

Al programa de Posgrado de Ingeniería Agrícola y Uso Integral del Agua, por concederme los conocimientos y los medios necesarios para que este trabajo llegara a buen puerto.

A mis asesores, los doctores Gilberto de Jesús López Canteñs, Irineo Lorenzo López Cruz y Noel Chávez Aguilera por sus sabios consejos al momento de plantear la etapa experimental y redacción de este documento.

A mi familia, mi padre Francisco Muñoz Gómez que siempre está para ayudarnos, a mi madre Marisela Bustos Santoyo que estuvo apoyando desde su trinchera; a mis hermanos Carolina, Mariana y David; mis sobrinos Emiliano, Bruno, Ximena y Melisa, a mi compañero de vida Erick, mis amigos María, Yiss, Kevin, Bryan, Carlos, Juan, Vanesa y Licha a los que les comparto este logro.

Dedico especialmente este trabajo a Karina Partida Herrera, que se nos adelantó, pero me sigue cuidando desde arriba. Al Ingeniero Jesús Edmundo Ruiz Medina, uno de los mejores profesores que he tenido en la vida, él me despertó ese interés en seguir aprendiendo y ser mejor, descansen en paz.

Muchas gracias a todos.

DATOS BIOGRÁFICOS



Datos personales

Nombre:	Francisco Muñoz Bustos
Fecha de nacimiento:	22 de febrero de 1992
Lugar de nacimiento:	Iztapalapa, Ciudad de México
CURP	MUBF920222HDFXSR07
Profesión:	Ingeniero en mecatrónica
Cédula profesional:	11206166

Desarrollo académico

Bachillerato:	Universidad Nacional Autónoma de México, Colegio de Ciencias y Humanidades, plantel Oriente
Licenciatura:	Universidad Nacional Autónoma de México, Facultad de Ingeniería, Ingeniería en mecatrónica

RESUMEN GENERAL

El maíz (*Zea mays L.*) forrajero es uno de los componentes fundamentales en la alimentación del ganado, por lo que se requiere cuantificar la cantidad de materia verde que se puede cosechar en campo para establecer estrategias de ensilado. En la actualidad, la cuantificación de la materia verde se hace utilizando métodos tradicionales, que no consideran la variabilidad del cultivo, son destructivos y tardados, debido a lo anterior se propone una metodología para estimar biomasa verde de maíz a partir de imágenes multiespectrales de alta resolución y un modelo predictivo basado en una red neuronal artificial (RNA). Para ello, se tomaron 80 muestras georreferenciadas, cada una en un área de medio metro cuadrado obteniéndose las alturas y el peso promedio de las plantas; además se generaron las ortoimágenes del área de cultivo a partir del vuelo del dron Mavic 3M, para el cálculo de los siguientes índices de vegetación NDVI, EVI, GNDVI, WDRVI, Clre, RVI, SAVI, VARI, RGBVI, NGRDVI, ExG, al igual que las bandas R, G, B y el índice de área foliar (LAI). Posteriormente, se obtuvo la matriz de correlación y se aplicó el algoritmo de componentes principales generando una base de datos con seis componentes principales, que se normalizó y se dividió aleatoriamente en entrenamiento con el 90% de los datos y el restante 10% en prueba de la RNA, se generó un modelo predictivo basado en un perceptrón multicapa con las siguientes características, dos capas ocultas con 30 y 5 neuronas respectivamente, con funciones de activación tangente hiperbólica, la capa de salida con una neurona, con función de activación lineal, dicho modelo mostró un buen ajuste entre la biomasa real y la estimada, con un $R^2 = 92.9\%$ y un error absoluto medio del rendimiento de 0.3 kg m^{-1} .

Palabras clave: *Zea mays L.*, Biomasa aérea, Redes Neuronales Artificiales, Índices de vegetación, Drones.

Tesis de Maestría en Ingeniería, Posgrado en Ingeniería Agrícola y Uso Integral del Agua,
Universidad Autónoma Chapingo.

Autor: Francisco Muñoz Bustos

Director de Tesis: Gilberto de Jesús López Canteñs

GENERAL ABSTRACT

Forage maize (*Zea mays* L.) is a fundamental component in livestock feeding, therefore it is necessary to quantify the amount of green matter that can be harvested in the field to establish ensilage strategies. Currently, green matter quantification is carried out using traditional methods that do not account the crop variability, are destructive, and time-consuming. Due to the above, a methodology is proposed to estimate maize green biomass from high-resolution multispectral images and a predictive model based on an artificial neural network (ANN). To achieve this, 80 georeferenced samples were taken, each in a half-square meter area, obtaining average plant heights and weight. Additionally, orthoimages of the cultivation area were generated from the Mavic 3M drone flight to calculate the following vegetation indices: NDVI, EVI, GNDVI, WDRVI, Clre, RVI, SAVI, VARI, RGBVI, NGRDVI, ExG, as well as the R, G, B bands and the leaf area index (LAI). Subsequently, a correlation matrix was obtained, and the principal component analysis algorithm was applied to generate a database with six principal components, which was normalized and randomly split into a training set with 90% of the data and a remaining 10% for ANN testing. A predictive model based on a multilayer perceptron was generated with the following characteristics: two hidden layers with 30 and 5 neurons, respectively, using hyperbolic tangent activation functions, and the output layer with one neuron and a linear activation function. This model demonstrated a good fit between real and estimated biomass, with an $R^2=92.9\%$ and a mean absolute error of crop yield of 0.3 kg m^{-1} .

Keywords: *Zea mays* L, Aerial Biomass, Artificial Neural Networks, Vegetation Indices, Drones.

Thesis, Universidad Autónoma Chapingo

Author: Francisco Muñoz Bustos

Advisor: Gilberto de Jesús López Canteñs



1 INTRODUCCIÓN GENERAL

El maíz (*Zea mays L.*) es una de las plantas más importantes del reino vegetal, es el cereal más producido en el mundo, por lo que se destaca de otros cultivos. En los últimos 50 años, la producción de este grano ha ido en aumento, convirtiéndose en el grano más importante del planeta. Según datos de (SIAP, 2021) en ese año la superficie cosechada a nivel nacional fue de 596,563.56 Ha para maíz forrajero en verde y de 7,139,620.92 Ha para maíz de grano, generando un valor de producción en miles de pesos de \$12,225,326.84 y \$ 148,601,480.40, respectivamente.

La biomasa del maíz es la materia orgánica acumulada por el ecosistema a través del tiempo, está compuesta por el peso de la materia orgánica aérea y subterránea., es de igual manera un parámetro agronómico básico usado para indicar el estado de crecimiento del cultivo (Han, et. al, 2019). Cuantificarla permite determinar la cantidad de nutrientes en diferentes partes del maíz y estratos de la vegetación, así como evaluar el rendimiento de una parcela. (Fonseca González, 2017).

La forma convencional para calcular la biomasa aérea es usar algún método destructivo, que requiere de la cosecha manual y pesado del cultivo, lo que requiere utilizar una gran cantidad de recursos y tiempo, además de no considerar la variabilidad espacial. Con la introducción de diversas plataformas y sensores remotos se han desarrollado técnicas no destructivas para estimar la biomasa de los cultivos, con base en la agricultura de precisión (Wang, et. al, 2021). La agricultura de precisión (AP) implica el uso de tecnologías (Teledetección, Tecnologías geo-espaciales, Internet de las cosas, Big Data, Inteligencia artificial, entre otras.) con el fin de aumentar la producción de los cultivos con la gestión correcta de los recursos (Bwambale, Abagale, & Anornu, 2022)



Una opción ampliamente utilizada para el monitoreo de la biomasa, es el uso de sistemas aéreos no tripulados (unmanned aerial systems, UAS) equipados con sensores con gran precisión, flexibilidad y bajo costo. Los UAS representan un método de medición sin contacto y no destructivo, que puede obtener las características espectrales, estructurales y dimensionales de los cultivos con una alta resolución espacial y temporal. Los sensores ópticos más usados en la teledetección agrícola son de luz visible (RGB), multiespectrales, hiperespectrales y térmicos. Otro tipo de sensor muy utilizado es LiDAR, acrónimo del inglés (Light Detection and Ranging o Laser Imaging Detectiton and Ranging) un sistema de medición y detección de objetos a través de láser para calcular superficies y mapear espacios tridimensionales; con los cuales se ha demostrado relación con parámetros fenológicos y fisiológicos de los cultivos, dando lugar al fenotipado de alto rendimiento basado en imágenes (Wang, et. al., 2021)

Los sensores remotos se están utilizando para la estimación de biomasa a partir de índices de vegetación, (VI, Vegetation Index) los cuales son parámetros calculados a partir de los valores de la reflectancia a distintas longitudes de onda, que son particularmente sensible a la cubierta vegetal. También, corresponde a un número generado por alguna combinación de bandas espectrales que tiene alguna relación con la cantidad de la vegetación presente en un píxel dado. Estos índices, son utilizados para mejorar la discriminación entre el suelo y la vegetación, reduciendo el efecto del relieve en la caracterización espectral de las diferentes cubiertas. (Muñoz Aguayo, 2013). Una variedad de VIs han sido utilizados para estimar biomasa, los cuales evalúan de manera cuantitativa el verdor y vitalidad de la vegetación en la parcela. El más usado es el NDVI (Normalized Difference Vegetation Index), el cual responde a la variación de la absorción de la clorofila al espectro rojo y al infrarrojo cercano (NIR). Otros VIs utilizados dependiendo de la fase de crecimiento de la planta son GNDVI (Green Normalized Differential Vegetation Index), SAVI (Soil-Adjusted Vegetation Index) y G-R (Green-Red Vegetation Index) presentan mejores resultados en etapas

Capítulo 1: Introducción

tempranas de desarrollo, mientras que para estimar biomasa en etapas tardías el índice usado es el TVI (Triangular Vegetation Index). (Sharma, Leigh, Chang, Maimaitijiang, & Caffé, 2022)

Wang, et. al., (2021) mencionan que en la actualidad los algoritmos de Machine Learning son ampliamente utilizados para procesar información proveniente de UAS, estos algoritmos se utilizan para resolver problemas de clasificación y regresión, los más utilizados son: máquinas de soporte vectorial (SVR, Support Vector Regression), regresión por bosques aleatorios (RFR, Random Forest Regression), redes neuronales artificiales (ANN, Artificial Neural Networks) y técnicas de regresión lineal o múltiples (MLR Multiple Linear Regression). La estimación de biomasa es un problema típico de regresión, el cual puede ser resuelto con un algoritmo de entrenamiento supervisado, basado en una base de datos lo suficientemente grande para que el modelo aprenda correctamente, esta base de datos se obtiene mediante el pesado de una muestra de las plantas cultivadas.



1.1 Objetivo General

Implementar un procedimiento para la estimación de biomasa aérea para maíz forrajero mediante la utilización de una red neuronal artificial e imágenes multiespectrales de alta resolución adquiridas con un dron, con el fin de considerar la variabilidad en la parcela.

1.1.1 Objetivos Específicos

- Planificar y realizar los vuelos del dron para la obtención de las orto imágenes del área de cultivo con el fin de determinar una estrategia de muestreo para obtener la base de datos georreferenciados de las imágenes aéreas y datos fisiológicos del cultivo de maíz
- Determinar los índices de vegetación NDVI, EVI, GNDVI, WDRVI, Clre, RVI, SAVI, VARI, RGBVI, NGRDVI, ExG y seleccionar los que mayor información aportan utilizando un algoritmo de componentes principales.
- Entrenar y evaluar un perceptrón multicapa para la estimación de biomasa verde del cultivo de maíz.



2 MARCO TEÓRICO

2.1 El maíz

El maíz es una planta anual con gran desarrollo vegetativo, tallo nudoso y macizo, contiene de quince a treinta hojas alargadas y abrasadoras, es una planta monoica, es una planta de clima relativamente cálido y cantidades abundantes de agua, principalmente durante la floración. En términos botánicos pertenece a la familia de las *Poaceae* (Gramíneas). La planta es usada para producir granos y forraje, los cuales constituyen la base para la elaboración de alimentos, para consumo humano como animal. (Guía para el cultivo de maíz 1era parte, s.f). La mayor producción del maíz se encuentra entre las latitudes de 55°N y 45°S. Es una planta C4, y su rendimiento por hectárea es el más alto de los cereales, prospera en los meses de verano. El maíz como forraje, se cultiva con el objetivo principal de ser transformado en carne y leche, es utilizado principalmente como fuente de energía en la alimentación animal. (Yara México, 2022)

En palabras de Fassio, et. al., (2018) el maíz pasa por dos fases de crecimiento (Figura 1), la primera es enteramente vegetativa y concierne al crecimiento del tallo y la aparición de hojas hasta el momento en que ocurre la emergencia de la inflorescencia masculina; mientras que la segunda fase, involucra la etapa reproductiva, momento desde que ocurre la polinización, la emergencia de barbas y el consecuente cuajado de granos e inicio de la formación de la mazorca. Luego de la fecundación (cuajado de granos), los nutrientes son finalmente almacenados en los granos que se desarrollan en la flor femenina o mazorca, como almidón. La porción del tallo puede representar un 50% o más de la biomasa total de la planta de maíz. Las características del tallo tales como altura y diámetro, y número por unidad de superficie son importantes porque están estrechamente correlacionadas con el rendimiento de masa seca. Ello se relaciona con que las características del tallo son el reflejo de la tasa de crecimiento y producción de MS durante una importante parte de la estación de crecimiento.

Capítulo 2: Marco Teórico




Figura 1 Comportamiento de la etapas fisiológicas del maíz. Recuperado de <https://cienciasagricolas.inifap.gob.mx/index.php/agricolas/article/view/2587/5016>

La etapa vegetativa óptima para el cultivo del maíz forrajero es la etapa R4, el cual contiene alrededor de 70% de humedad (Endicot, et al., 2015). Jurado, Lara, & Saucedo, (2014) recomiendan para la cosecha de forraje un 65% de humedad, dado que las pérdidas de forraje durante la cosecha se minimizan. Este contenido de humedad se alcanza cuando la línea de leche o línea blanca está a la mitad del grano, Figura 2




Figura 2 Corte transversal de una mazorca para mostrar la línea de leche. Recuperado de Endicot, et al., 2015



2.2 Biomasa, métodos de estimación

La biomasa es la materia orgánica acumulada por un ecosistema a través del tiempo, está compuesta por el peso de la materia orgánica aérea y subterránea., es de igual manera un parámetro agronómico básico usado para indicar el estado de crecimiento de un cultivo (Han, et. al, 2019). Cuantificarla permite determinar la cantidad de nutrientes en diferentes partes de las plantas y estratos de la vegetación, así como evaluar el rendimiento de una parcela. (Fonseca González, 2017)

La biomasa puede ser determinada usando métodos directos o indirectos. (Methods to determine biomass, s.f.). Los métodos directos utilizan técnicas destructivas que cosechan muestras en varios cuadrantes del campo de cultivo para, posteriormente pesarlas en húmedo y en seco, obteniendo así los datos para el tratamiento estadístico. Estos métodos presentan problemas, el más importante es la destrucción del cultivo, un segundo es la gran variabilidad que llegan a tener los resultados, otro más es el tiempo y los recursos invertidos al momento de realizar el muestreo en los cuadrantes, es por eso que se han adoptado los métodos indirectos para la estimación de la biomasa en cultivos. (Harvesting to determine biomass, s.f.)

Los métodos indirectos para determinar la biomasa se basan en desarrollar una relación entre el peso de la planta y varios atributos de fácil medición. Se pueden usar muchos atributos diferentes que describen las dimensiones de la planta para determinar la biomasa. Las mediciones de la altura y diámetro del tallo y el índice de área foliar (IAF o LAI por sus siglas en inglés), se utilizan comúnmente como variables para estimar la biomasa. El método implica desarrollar inicialmente una relación de regresión, registrando las dimensiones apropiadas y cosechando un pequeño número de individuos que se eligen para abarcar el rango de variabilidad presente en las plantas para garantizar que las dimensiones seleccionadas proporcionen una buena predicción de la biomasa aérea ($r^2 > 0.7$, por ejemplo). Generado el modelo se procede a tomar sólo medidas dimensionales, que se

Capítulo 2: Marco Teórico

convierten en valores de biomasa utilizando la ecuación de regresión. Aunque una combinación de las dimensiones de la planta es generalmente un mejor predictor de la biomasa que una sola variable, a veces se puede perder el objetivo de diseñar una estrategia de muestreo más simple. Por ejemplo, aunque se encuentra una fuerte relación entre la biomasa y los múltiples factores de la altura del tallo, el diámetro, número de hojas y el número de tallos, etc. el esfuerzo requerido para recopilar dichos datos no sería práctico en la mayoría de las situaciones. (Indirect methods to determine biomass, s.f.)

Para una interpretación significativa, los datos deben convertirse de una biomasa por planta a una biomasa por área, lo que requiere una estimación adicional de la densidad. La relación de regresión también es específica de la población en la que se recopilan los datos, y se debe tener precaución al intentar aplicarla a otros años u otros sitios. (Plant dimensions, s.f.)

Una opción ampliamente utilizada para el monitoreo de la biomasa, que soluciona los problemas antes descritos, es el uso de sistemas aéreos no tripulados (Unmanned Aerial Systems, UAS) equipados con sensores ópticos o de láser, con gran precisión, flexibilidad y bajo costo. Los UAS representan un método de medición sin contacto y no destructivo, que puede obtener las características espectrales, estructurales y dimensionales de los cultivos en diferentes escalas espacio-temporales. Estos sistemas poseen la habilidad de obtener datos con una gran resolución espacial y temporal, aspectos necesarios en la agricultura de precisión (Wang, et. al., 2021).

El estudio de diversas metodologías para estimar biomasa no es exclusivo del cultivo de maíz, la estimación en ecosistemas forestales es también un nicho muy importante en investigación, autores como Huang, Liu, Wang, Zhou, & Gong,(2019), Nath, et al., (2019), Luo , et al.,(2020), utilizan ecuaciones alométricas para estimar la biomasa de diversos tipos de bosques, Galeana Pizaña, Núñez Hernández, & Corona Romero, (2016) utilizaron índices de vegetación a partir de imágenes satelitales para calcular la biomasa en dos bosques de la Ciudad de México; Zhang,



Ma, Liang, Li, & Li, (2020), Fonseca González, (2017), Bulut, Sivrikaya, & Günlü, (2022), Dang, et al., (2019), Li, Li, Li, & Liu, (2020), Kachamba, Orka, Gobakken, Eid, & Mwase, (2016) hacen una comparación de los diferentes métodos existentes para estimar biomasa a partir de técnicas de machine learning. Los cultivos herbáceos también han sido objeto de estudio para estimar la biomasa, autores como Tackenberg, (2007), Mora Delgado & Holguín, (2018), Pottier & Jabot, (2017), Marcos, et al., (2016), Li, Zhang, Ma, & Li, (2021), se han enfocado a estos tipos de cultivos.

Wang, Nie, Xi, Luo, & Sun, (2017) fueron los primeros en evaluar la aplicación de la combinación de los datos obtenidos de un sensor hiperespectral y LiDAR en la estimación de la biomasa del maíz. Los resultados mostraron que la combinación de ambos tipos de sensores puede incrementar la precisión en la estimación de la biomasa que usando los sensores de manera individual. Zhu, et al, (2019) siguieron esta línea de investigación, usando LiDAR para estimar biomasa aérea (aboveground stem biomass, AGSB) en el mismo cultivo, ya que este tipo de sensor es sensible a la estructura del cultivo; la otra medición realizada fue la estimación de la biomasa de las hojas (aboveground leaf biomass, AGLB) la cual fue medida con el uso de sensores multiespectrales, los cuales son sensibles a los parámetros de vegetación del cultivo. Comparado con el uso individual de los sensores, la combinación de los mismos puede mejorar la estimación de la biomasa.

2.3 Sistemas aéreos no tripulados

Desde el siglo XIX hasta la actualidad se viene dando la evolución y surgimiento de los sistemas o unidades no tripuladas como una tecnología potente desarrollada para el sector civil, específicamente, en el campo de la agricultura de precisión. Tras estos avances científicos y tecnológicos, en la última década, los agricultores comenzaron a usarlos para monitorear sus campos, así como para ayudar a los programas de agricultura de precisión. Hay estimaciones de que 80 a 90% del mercado de sistemas aéreos no tripulados en la próxima década se utilizará en la agricultura. (Pino, 2019). Los UAS se pueden clasificar desde diferentes perspectivas: por el uso, por el tipo de control o por su forma Figura 3 y Figura 4




Figura 3 Clasificación de los sistemas aéreos no tripulados. Fuente Propia, Información recuperada de (Pino, 2019)




Figura 4 Tipo de drones; Recuperado de: <https://www.academiadronchile.cl/estos-los-diferentes-tipos-drones-existen-mercado/>



Pino, (2019) lista los usos más comunes de los drones: a) Conteo de plantas y supervisión de su crecimiento, b) Medición de clorofila, c) Evaluación del estrés hídrico, d) Detectar el estado sanitario de un cultivo, e) Fenología, f) Peritaje de cultivos ante un siniestro mediante el análisis de imágenes multiespectrales.

2.3.1 Sensores

Un aspecto importante son los sensores utilizados. Varios autores entre ellos Chen, Zhang, Bian, Li, & Lv, (2022), Wang, et. al., (2021), Geng, Che, Ma, Tan, & Wang, (2021), Han, et. al., (2019), mencionan que los UAS recopilan información a través de diferentes tipos de sensores de tipos espectrales y profundos. Los sensores espectrales comúnmente incluyen sensores RGB, sensores multiespectrales o sensores hiperespectrales, que pueden obtener el color y texturas de la superficie de cultivo. Las diferencias entre estos tres tipos de sensores es la capacidad de medir las bandas del espectro electromagnético.

Los sensores RGB son un tipo de cámaras que usan el espectro visible, detecta tres bandas: rojo (R), verde (G) y azul (B), cada banda representa la intensidad de color en cada pixel. A pesar de que los sensores RGB tienen una limitante, comparada con los demás sensores espectrales, dado que solo obtienen la información de tres bandas; el bajo precio de adquisición de éstos conlleva una ventaja respecto a los otros dos tipos de sensores. Debido a la necesidad de mantener bajos costos de operación en la estimación de la biomasa del cultivo, los sensores RGB han ganado popularidad en los últimos años. Wang, et. al., (2021), Ballesteros, Ortega, Hernández, & Moreno, (2018), Bendig, et. al., (2014).

Las imágenes de datos multiespectrales contienen algunas regiones del espectro visible y del infrarrojo cercano (NIR, near-infrared). La combinación de las bandas espectrales pueden reflejar diferentes características y aspectos de las plantas utilizados para distinguir de manera efectiva diferentes cultivos. Estos sensores tienen una mejor resolución que los sensores RGB, con el inconveniente del precio elevado comparado con el precio de una cámara RGB. (Wang, et. al., 2021), (Huang, Liu, Wang, Zhou, & Gong, 2019).

Capítulo 2: Marco Teórico

Los sensores hiperespectrales pueden obtener información de un abanico más amplio de bandas espectrales que los otros dos tipos de sensores analizados, la desventaja como la mencionada en los sensores multiespectrales es su costo elevado, otra desventaja es que la resolución de las imágenes obtenidas es baja comparado con las imágenes RGB, lo que podría causar pérdida de información de pequeños objetivos, además mucha de la información de las demás bandas espectrales pueden no ser útiles en algunos casos. (Wang, et. al., 2021)

Los mismos autores menciona que los datos de los sensores espectrales tienen poca robustez en los casos de superposición de objetos, cambios bruscos de iluminación, sombras y escenarios complejos. Los datos obtenidos de sensores láser como el sensor LiDAR no cambian con la intensidad de luz y el color, puede proveer información adicional muy útil en escenarios complejos. LiDAR es un sensor activo de tecnología remota que mide con precisión la distancia, emitiendo pulsos de láser y analizando la energía retornada al rebotar con el objeto de estudio. El uso de LiDAR se ha convertido en una importante fuente de información para la evaluación de la estructura de la cual puede obtenerse información tridimensional del cultivo, el cual es especialmente adaptable a especies que limitan el uso de métodos destructivos para estimar la biomasa. Sin embargo, es un sensor que tiene un costo elevado respecto a los sensores ópticos disponibles en el mercado, además que no permite calcular índices de vegetación, lo que lo vuelve inaccesible en algunas aplicaciones.

Con el desarrollo del sistema de posicionamiento global (GPS, por sus siglas en inglés), unidades de medición de inercia (IMU), la tecnología láser y la computación, han hecho posible que el uso de LiDAR en vehículos aéreos no tripulados sea asequible y muy preciso. Comparado con los sensores espectrales, LiDAR tiende a mejorar la precisión en la estimación de la predicción de la biomasa, ya que, los sensores espectrales suelen saturarse en el medio del cultivo, LiDAR puede mejorar esto a través de la información de profundidad, pero la combinación de ambos tipos de sensores (

Figura 5) han demostrado aumentar aún más la precisión de la estimación de la biomasa (Wang, et. al., 2021), (Zhu, et. al., 2019), (Wang, Nie, Xi, Luo, & Sun, 2017).

A modo de resumen sobre las características de los sensores utilizados en drones se presenta el Cuadro 1




Figura 5 Uso de los diferentes sensores, recuperado de (Wang, et. al., 2021)

Cuadro 1 Resumen de las características, ventajas y desventajas de los sensores utilizados en drones

Tipo de sensor	Características	Ventajas	Desventajas
RGB	Captura información en los tres canales de color primarios: rojo, verde y azul.	Ampliamente utilizado en aplicaciones de fotografía y cartografía básica.	No proporciona información específica sobre el estado de salud de los cultivos, como estrés hídrico o enfermedades.
	Proporciona imágenes visuales de alta resolución con información de color.	Económico comparado con los otros tipos de sensores. Fácil interpretación de las imágenes por parte de los usuarios.	
Multiespectral	Captura información en múltiples bandas espectrales, generalmente más allá del espectro visible (infrarrojo cercano y a veces infrarrojo termal).	Proporciona información adicional sobre el estado de salud de los cultivos, como la clorofila, la humedad del suelo y el estrés hídrico.	Más costosos que los sensores RGB.
		Permite el cálculo de algunos índices de vegetación comúnmente utilizados para la estimación de la biomasa de diversos cultivos, por ejemplo el NDVI.	La resolución espacial puede ser menor en comparación con los sensores RGB. Menor capacidad de discriminar y clasificar con precisión ciertas características de los cultivos en comparación con los sensores hiperspectrales.

Capítulo 2: Marco Teórico

Hiperespectral	Captura información en numerosas bandas espectrales muy estrechas y contiguas, que cubren un amplio rango del espectro electromagnético.	Proporciona información detallada sobre la composición química y la estructura de los cultivos.	Mayor costo en comparación con los sensores RGB y multiespectrales.
		Permite el análisis avanzado y la clasificación precisa de los cultivos, incluyendo la detección de enfermedades, la identificación de especies y la estimación de la calidad del cultivo.	Requiere un procesamiento más complejo y especializado para extraer información útil de los datos recopilados.
LiDAR		Permite un análisis avanzado y una toma de decisiones precisa.	
	Utiliza pulsos láser para medir la distancia entre el sensor y los objetos en la superficie terrestre.	Proporciona información tridimensional detallada sobre la topografía del terreno y la altura de los cultivos.	Mayor costo en comparación con los sensores ópticos.
		Permite la generación de modelos digitales de elevación (MDE) y modelos de superficie del terreno con alta precisión.	Puede requerir una mayor capacidad de procesamiento y almacenamiento de datos debido a la naturaleza tridimensional de la información recopilada.

2.4 Índices de vegetación

En palabras de Muñoz Aguayo, (2013), un Índice de Vegetación, puede ser definido como un parámetro calculado a partir de los valores de la reflectancia a distintas longitudes de onda, y que es particularmente sensible a la cubierta vegetal. También, corresponde a un número generado por alguna combinación de bandas espectrales y que puede tener alguna relación con la cantidad de la vegetación presente en un píxel dado. Estos índices, son utilizados para mejorar la discriminación entre el suelo y la vegetación, reduciendo el efecto del relieve en la caracterización espectral de las diferentes cubiertas.

Autores como Chen, Zhang, Bian, Li, & Lv, (2022), Geng, Che, Ma, Tan, & Wang, (2021), Bahrami, et. al., (2021), Jin, Li, Feng, Ren, & Li, (2019), Nui, Zhang, Zhang, Han, & Peng, (2019), Calou, Teixeira, Moreira, da Rocha Neto, & da Silva, (2019), Han, et. al, (2019) utilizan varios índices de vegetación para estimar la biomasa de maíz, entre los más importantes destacan los siguientes NDVI, RVI, las bandas de



colores R,G,B, el infrarrojo cercano (NIR), WDRVI, EVI, Clred_edge, ExG, SAVI y OSAVI, GNDVI, MTCI, NGRDVI, VARI, RGBVI, así como la altura del cultivo y el índice de área foliar (LAI). Los VIs más utilizados para la estimación de biomasa se muestran en la Cuadro 2.

Cuadro 2 Índices de vegetación más utilizados en la estimación de biomasa aérea de maíz forrajero

Índice de vegetación (VI)	Fórmula	Aplicación	Autor
NDVI (Normalized Difference Vegetation Index)	$NDVI = \frac{NIR - R}{NIR + R}$	Estimación de la cobertura vegetal	Rouse et al. (1974)
EVI (Enhanced Vegetation Index)	$EVI = 2.5 \left(\frac{NIR - R}{NIR + 6R - 7.5B + 1} \right)$	Análisis y monitoreo de la vegetación	Huete et al. (2002)
GNDVI (Green Normalized Difference Vegetation Index):	$GNDVI = \frac{NIR - G}{NIR + G}$	Análisis del estado de la vegetación	Gitelson et al. (1996)
WDRVI (Wide Dynamic Range Vegetation Index):	$WDRVI = \frac{0.1 * NIR - Red\ Edge}{0.1 * NIR + Red\ Edge}$	Reducir la influencia de la variabilidad del brillo de fondo	Ceccato P. , Flasse, Tarantola, Jacquemoud, & Grégoire, (2001)
Cl _{red edge} (Chlorophyll Index Red-Edge)	$Cl_{re} = \frac{NIR}{Red\ Edge} - 1$	Estimación de la distribución espacial de la clorofila	Gitelson et al., (2003)
RVI(Ratio vegetation index)	$RVI = \frac{NIR}{R}$	Monitoreo de la actividad fotosintética de la biomasa.	Rouse et al. (1974)
SAVI (Soil-Adjusted Vegetation Index)	$SAVI = 1.5 * \frac{NIR - R}{NIR + R + 0.5}$	Medición de vegetación cuando se considera el brillo del suelo, aplicable cuando el cultivo no ha cubierto el suelo totalmente	Huete et al. (1988)
VARI (Variable Atmospherically Resistant Index)	$VARI = \frac{G - R}{G + R - B}$	Índice de cobertura foliar y biomasa	Gitelson, Merzlyak & Chivkunova (2002)
RGBVI (Red-Green-Blue Vegetation Index)	$RGBVI = \frac{G^2 - RB}{G^2 + RB}$	Cobertura del cultivo	Bendig et. al (2015)
NGRDVI (Normalized Green/Red Difference Vegetation Index)	$NGRDVI = \frac{G - R}{G + R}$	Cobertura del cultivo	Ceccato, Flasse, Tarantola, Jacquemoud, & Grégoire, (2001)
ExG (Excess Green Index)	$ExG = 2 * G - R - B$	Evaluar el vigor y la salud de la vegetación.	Schirrmann, et. al., (2016)

2.5 Redes Neuronales Artificiales

Según el Diccionario de la Real Academia la definición de Inteligencia Artificial (IA) es la siguiente: Informática, "Disciplina científica que se ocupa de crear programas informáticos que ejecutan operaciones comparables a las que realiza la mente humana, como el aprendizaje o el razonamiento lógico." Elaine Rich, de la Universidad de Texas en Austin definió la IA como: "el estudio de cómo hacer que los ordenadores hagan cosas que, por ahora, los humanos hacemos mejor." El aprendizaje automático, proporciona mecanismo mediante los cuales la computadora es capaz de aprender por si misma a resolver un problema. (Berzal, 2018).

Arthur Samuel, de IBM, definió el aprendizaje automático como el campo de estudio que dota a las computadoras de la capacidad de aprender a resolver problemas para los que no han sido explícitamente programados. En IA, el aprendizaje se entiende como un proceso por el cual una computadora es capaz de mejorar su habilidad en la resolución de un problema a través de la adquisición de conocimiento, conocimiento que obtiene a través de la experiencia. (Berzal, 2018).

Como lo mencionan Hagan, Demuth, Beale, & De Jesús, (2014) , Haykin, (2005), Ponce Cruz, (2010), Palma Méndez & Marín Morales, (2008), y Berzal, (2018), la clasificación de los tipos de aprendizaje automático se puede obtener del proceso de adquisición del conocimiento en a) Aprendizaje supervisado y b) Aprendizaje no supervisado. En el aprendizaje supervisado, los ejemplos de entrenamiento van acompañados de la salida deseada o correcta que el sistema deberá ser capaz de reproducir. El entrenamiento de un modelo de aprendizaje supervisado consiste en ajustar los parámetros para que sea capaz de reproducir una salida lo más parecida posible a la deseada. Una vez entrenado el modelo, lo verdaderamente importante es que sea capaz de generalizar correctamente. Esa capacidad de generalización consiste en que el modelo proporcione salidas adecuadas para datos de entrada diferentes a los datos utilizados durante su entrenamiento. El aprendizaje por refuerzo es un tipo de aprendizaje supervisado que consiste básicamente en clasificar un conjunto de datos con un mecanismo de prueba y error. En el



aprendizaje no supervisado, será el método de aprendizaje el que decida cómo ha de agruparse los datos del conjunto de entrenamiento basándose en las características de dicho conjunto.

Una Red Neuronal Artificial (RNA), conocidas bajo el término de Deep Learning es un paradigma de procesamiento de información inicialmente inspirado en el modo en el que lo hace el cerebro. El elemento clave de este paradigma es su estructura. (Palma Méndez & Marín Morales, 2008). Es una corriente de la IA llamada conexionista, se inspiran en la estructura del cerebro humano y construye modelos formados por múltiples unidades relativamente simples llamadas neuronas artificiales. Estas neuronas se conectan entre sí para formar capas y varias capas forman redes neuronales artificiales. (Berzal, 2018)

Las técnicas de Deep learning son un subconjunto de las técnicas de aprendizaje automático y éstas a su vez es un subconjunto de lo que llamamos Inteligencia Artificial. (Figura 6)




Figura 6 Diagrama de Venn-Euler sobre las partes de la Inteligencia Artificial

Capítulo 2: Marco Teórico

El éxito actual de las redes neuronales artificiales se debe fundamentalmente a tres características bioinspiradas: su plasticidad, que les permite adaptarse y aprender; su organización jerárquica, que les faculta para resolver problemas complejos por composición y, por último, su forma de modelar la percepción, que les proporciona mecanismos para resolver problemas. (Haykin, 2005)

En las redes neuronales tipo feed-forward, se clasifican dependiendo del número de capas ocultas que se utilicen:

- Redes simples, con una única capa o monocapa. Es el caso más simple de una red neuronal; las neuronas de la capa de entrada, cuya función es recibir las señales de entrada provenientes del exterior, redistribuyen esas entradas a las neuronas de la capa de salida, que es la única capa de la red que realmente hace algo. Los perceptrones son tal vez, el modelo más conocido de RNA con una sola capa. (Berzal, 2018). Una red monocapa con S neuronas artificiales se muestra en la Figura 7, con R entradas que se conectan a cada elemento procesador a través de la matriz de pesos con S filas y R columnas. (Hagan, Demuth, Beale, & De Jesús, 2014)




Figura 7 Red Neuronal Artificial monocapa

- Redes multicapa: Esta arquitectura se compone de una o más capas ocultas además de las capas de entrada y salida. La presencia de capas ocultas dota a la red multicapa de la capacidad de aproximador universal. Este tipo de redes fue muy popular desde los años 80 hasta finales del siglo XX. Las redes profundas (Deep Networks), son un ejemplo de redes con varias capas ocultas, muy buenas a la hora de implementar técnicas de Deep Learning para dar soluciones a problemas complejos. (Ponce Cruz, 2010)

Cada capa posee su propia matriz de pesos $\mathbf{W}$, su vector de sesgos $\mathbf{b}$, un vector de entradas netas $\mathbf{n}$ y un vector de salidas $\mathbf{a}$. Para lograr distinguir este tipo de arquitecturas se usará la siguiente nomenclatura: Se ocuparán superíndices para identificar las capas, así la matriz de pesos de la primera y segunda capa estarán representados por $\mathbf{W}^I, \mathbf{W}^{II}$ respectivamente. (Hagan, Demuth, Beale, & De Jesús, 2014). Las capas de una red multicapa se dividen en dos categorías: capas visibles y capas ocultas. Las capas visibles son aquellas capas parcialmente observables desde el exterior de la red. Todas las capas intermedias diferentes a las de entrada y salida reciben el nombre de capas ocultas (Berzal, 2018), en la Figura 8 se muestra una red multicapa utilizando la nomenclatura propuesta por (Hagan, Demuth, Beale, & De Jesús, 2014)




Figura 8 Red Neuronal Artificial multicapa

Capítulo 2: Marco Teórico

El uso de múltiples capas de neuronas ocultas es lo que permite a las redes neuronales artificiales utilizadas en Deep Learning extraer características más complejas a partir de otras características más simples. Las capas ocultas le permiten a la red neuronal construir un modelo interno de la forma en que los patrones de datos de entrada están relacionados con las salidas deseadas. Esta capacidad de representaciones es lo que dota a las redes neuronales de un rendimiento muy bueno en aquellos dominios de aplicación en los que los datos de entrada se pueden interpretar construyendo una estructura jerárquica de características. (Berzal, 2018)

2.5.1 Algoritmo de retropropagación del error

Para que una red neuronal sea capaz de generalizar correctamente, se tiene que entrenar, el entrenamiento de una RNA se puede definir como el proceso donde se ajustan los pesos sinápticos y sesgos, de tal manera que la red resuelva correctamente el problema para la cual fue diseñada.

A continuación, utilizando la notación propuesta por (Hagan, Demuth, Beale, & De Jesús, 2014), para cada ejemplo de entrenamiento con la forma

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}$$

donde $\mathbf{p}_q$ es cualquiera de los Q patrones de entrenamiento y $\mathbf{t}_q$ es la salida deseada del patrón elegido se calcula la salida real del perceptrón $\mathbf{a}_q$, esta se compara con la salida deseada $\mathbf{t}_q$, para calcular el error de la RNA definido en la Ec. 2-1

$$\mathbf{e}_q = \mathbf{t}_q - \mathbf{a}_q \quad \text{Ec. 2-1}$$

La retropropagación del error permite calcular el gradiente del error con respecto a los diferentes parámetros de la red, esto es como cambia el error conforme varían los parámetros de la red. Combinado con una técnica de optimización como el gradiente descendente se obtiene un algoritmo de entrenamiento para redes



multicapa. El gradiente se calcula para una función de error, también conocida como función de pérdida, y el método de optimización ajusta los pesos de la red con el objetivo de minimizar esa función de error o pérdida.

El algoritmo del descenso de gradiente se muestra en la Ec. 2-2

$$\mathbf{x}_{(t+1)} = \mathbf{x}_t - \alpha \nabla E \quad \text{Ec. 2-2}$$

Donde ∇E es el gradiente de la función de error o pérdida y α una constante que se llama tasa de aprendizaje. El algoritmo del descenso del gradiente es un algoritmo iterativo que calcula el gradiente del error ∇E y realiza ajustes en los parámetros de la red en sentido opuesto a dicho gradiente, lo que hace caer por la pendiente de la superficie de error en dirección a un mínimo local. (Berzal, 2018)

En palabras de Hagan, Demuth, Beale, & De Jesús, (2014) y Berzal, (2018) el método del descenso del gradiente converge a una solución óptima $\mathbf{x}^*$ lentamente. De hecho, el valor de la tasa de aprendizaje α tiene consecuencias con respecto a la velocidad de convergencia o divergencia del algoritmo:

- La tasa α es pequeña, los pasos siguen una trayectoria sobreamortiguada, en la que lentamente se acerca al óptimo de la función de error.
- La tasa α excede un valor crítico, la trayectoria oscila, por lo que el algoritmo diverge.

El algoritmo del descenso de gradiente para el entrenamiento de redes neuronales artificiales se puede escribir como en las Ec. 2-3 y Ec. 2-4. (Hagan, Demuth, Beale, & De Jesús, 2014)

$$\mathbf{W}_{t+1} = \mathbf{W}_t - \alpha \frac{\partial E}{\partial \mathbf{W}} \quad \text{Ec. 2-3}$$

$$\mathbf{b}_{t+1} = \mathbf{b}_t - \alpha \frac{\partial E}{\partial \mathbf{b}} \quad \text{Ec. 2-4}$$

Capítulo 2: Marco Teórico

A continuación, se listan las ecuaciones y pasos para aplicar el algoritmo de retropropagación del error, mismo que se encuentra referenciado en Hagan, Demuth, Beale, & De Jesús, (2014).

Paso 1: Inicializar los parámetros de la red con las recomendaciones que dan Hagan, Demuth, Beale, & De Jesús(s.f), Haykin, (2005) y Berzal, (2018), es importante inicializar correctamente los parámetros de la red antes de comenzar el proceso de entrenamiento. Un error muy habitual consiste en inicializar todos los pesos en cero o con los mismos valores, lo que haría que el algoritmo entrene a las neuronas siempre con el mismo valor, dado que el gradiente del error siempre será el mismo para todas las neuronas. Lo más habitual consiste en inicializar los pesos de la red de forma aleatoria con valores pequeños tanto positivos como negativos. En una red neuronal resulta de interés que existan tanto sinapsis excitatorias como sinapsis inhibitorias. La inicialización de los valores de los sesgos puede realizarse de la misma manera o inclusive todos con valores nulos y dejar que sea el entrenamiento de la red quien determine sus valores.

Paso 2: Propagar las entradas a través de las capas y calcular la salida de la red

$$\mathbf{a}^0 = \mathbf{p} \quad \text{Ec. 2-5}$$

$$\mathbf{a}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1}\mathbf{a}^m + \mathbf{b}^{m+1}) \text{ para } m = 0, 1, \dots, M-1 \quad \text{Ec. 2-6}$$

$$\mathbf{a} = \mathbf{a}^M \quad \text{Ec. 2-7}$$

Paso 3: Propagar las sensibilidades desde la última capa a la primera

$$\delta^M \rightarrow \delta^{M-1} \rightarrow \dots \rightarrow \delta^2 \rightarrow \delta^1$$

$$\delta^M = -2\dot{\mathbf{F}}^M(\mathbf{n}^M)(\mathbf{t} - \mathbf{a}) \quad \text{Ec. 2-8}$$

$$\delta^m = \dot{\mathbf{F}}^m(\mathbf{n}^m) \cdot (\mathbf{W}^{m+1})^T \cdot \delta^{m+1}; \text{ para } m = M-1, M-2, \dots, 2, 1 \quad \text{Ec. 2-9}$$

donde



$$\mathbf{F}^m(\mathbf{n}^m) = \begin{bmatrix} f^m(n_1^m) & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & f^m(n_{S^m}^m) \end{bmatrix}$$

Paso 4: Actualizar los parámetros de la red utilizando el algoritmo del descenso del gradiente

$$\mathbf{W}^m(k+1) = \mathbf{W}^m(k) - \alpha \delta^m (\mathbf{a}^{m-1})^T \quad \text{Ec. 2-10}$$

$$\mathbf{b}^m(k+1) = \mathbf{b}^m(k) - \alpha \delta^m \quad \text{Ec. 2-11}$$

Las funciones de activación más utilizadas para las redes neuronales multicapa y sus derivadas se listan en el **¡Error! No se encuentra el origen de la referencia.**

Cuadro 3 Funciones de activación más utilizadas en el algoritmo de retropropagación del error y sus derivadas

Función	Expresión matemática	$f^M(n)$
Logarítmica sigmoidea	$a = \frac{1}{1 + e^{-n}}$	$(1 - a)(a)$
Tangente sigmoidea	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	$1 - a^2$
Lineal	$a = n$	1

Berzal, (2018) y Hagan, Demuth, Beale, & De Jesús, (2014) comentan que existen variaciones del algoritmo de retropropagación del error que reducen el número de iteraciones necesarias para que el algoritmo converja. entre las opciones disponibles en la actualidad están las siguientes modificaciones.

Momentos

Se utiliza una analogía física para la actualización de los pesos. Al movimiento del punto que busca el mínimo se le agrega cierto grado de inercia, lo que provoca que éste no se quede estancando un un mínimo local, cosa que pasa en la versión clásica del algoritmo backpropagation. (Berzal, 2018). Con el uso del momento se

Capítulo 2: Marco Teórico

pueden ocupar tasas de aprendizajes más grandes manteniendo la estabilidad del algoritmo. (Hagan, Demuth, Beale, & De Jesús, 2014).

Adam (Adaptative momento estimation)

Adam se mantienen dos medias móviles de los gradientes, una para los momentos Ec. 2-12 y Ec. 2-13 y otra para el algoritmo RSMprop Ec. 2-14 y Ec. 2-15:

$$mW_{i,j_t}^m = \beta_1 mW_{i,j_{t-1}}^m + (1 - \beta_1) \delta_i^m a_j^{m-1} \quad \text{Ec. 2-12}$$

$$mb_{i_t}^m = \beta_1 mb_{i_{t-1}}^m + (1 - \beta_1) \delta_i^m \quad \text{Ec. 2-13}$$

$$vW_{i,j_t}^m = \beta_2 vW_{i,j_{t-1}}^m + (1 - \beta_2) (\delta_i^m a_j^{m-1})^2 \quad \text{Ec. 2-14}$$

$$vb_{i_t}^m = \beta_2 vb_{i_{t-1}}^m + (1 - \beta_2) (\delta_i^m)^2 \quad \text{Ec. 2-15}$$

A partir de estos valores se actualizan los pesos sináptico y sesgos de la red:

$$w_{i,j_{t+1}}^m = w_{i,j_t}^m - \alpha \frac{mW_{i,j_t}^m}{\sqrt{vW_{i,j_t}^m + \varepsilon}} \quad \text{Ec. 2-16}$$

$$b_{i_{t+1}}^m = b_{i_t}^m - \alpha \frac{mb_{i_t}^m}{\sqrt{vb_{i_t}^m + \varepsilon}} \quad \text{Ec. 2-17}$$

Las estimaciones se inicializan en cero y β_1 y β_2 son las constantes que controlan las medias móviles, tienen valores cercanos a 1, con valores típicos $\beta_1 = 0.9$ y $\beta_2 = 0.999$. Adam suele considerarse bastante robusto con respecto a los valores iniciales de sus hiperparámetros (α , β_1 , β_2), aunque en ocasiones se tendrá que ajustar manualmente la tasa de aprendizaje de referencia α . (Berzal, 2018).

Para redes multicapa, los algoritmos de entrenamiento están basados en el uso del gradiente, éstos pueden ser implementados de modo incremental, es decir presentando uno a uno los patrones de ejemplo, calculando el gradiente estocástico y actualizando los parámetros de la red con base en ese gradiente o en lotes, donde



se presentan todos los ejemplos a la red y se calcula el gradiente total, actualizando los parámetros una vez por iteración. (Hagan, Demuth, Beale, & De Jesús, 2014)

Un problema de los algoritmos de entrenamiento de redes neuronales basados en el gradiente es la posibilidad de que el algoritmo converja a un mínimo local de la función de error. En la práctica, no suele suponer un problema, ya que se puede cambiar la topología de la red u otros parámetros del algoritmo de entrenamiento, si el error calculado es demasiado grande. Cuando la red obtiene una solución aceptable para el problema, no se sabe si ésta sea la mejor solución posible, ya que nunca se sabrá si se está en un mínimo local en vez de en el mínimo global. (Berzal, 2018).

2.5.2 Entrenamiento de una red neuronal artificial

Berzal (2018) menciona que casi todos los algoritmos de IA se basan en una serie de pasos aplicados para resolver un problema en concreto:

- Recopilar un conjunto de datos, entre más datos se tengan disponibles mejor.
- Diseñar una función de pérdida o coste.
- Seleccionar el modelo de RNA y establecer sus hiperparámetros.
- Aplicar un algoritmo de entrenamiento para ajustar los parámetros de la RNA.
- Evaluar el rendimiento de la RNA

La Figura 9 ilustra el proceso de entrenamiento de una red neuronal artificial. Este es un proceso iterativo que comienza con la recolección y pre-procesamiento de los datos. El objetivo principal del pre-procesamiento de los datos es facilitar el entrenamiento de la red, el pre-procesamiento consta de algunos pasos como normalización, aplicación de transformaciones no lineales, extracción de características, codificación o discretización de las entradas y salidas (para problemas de clasificación), manejo de datos faltantes, etc. (Hagan, Demuth, Beale, & De Jesús, 2014).




Figura 9 Pasos generales para lograr implementar de una RNA para resolver un problema en específico

Berzal, (2018) y Hagan, Demuth, Beale, & De Jesús, (2014) recomiendan que el conjunto de entrenamiento cumpla con las siguientes propiedades:

- La media de cada variable de entrada en el conjunto de entrenamiento debería ser cercana a cero.
- La escala de las variables de entrada debería ajustarse para que sus varianzas sean similares.
- Si es posible, las variables de entrada deberían estar decorrelacionadas



Existen dos métodos para normalizar los datos, el primer método escala los datos a un rango establecido, típicamente entre 0 a 1, utilizando la siguiente ecuación

$$p_i^{norm} = \frac{p_i - p^{min}}{(p^{max} - p^{min})} \quad \text{Ec. 2-18}$$

Donde p^{min} es el valor más pequeño de la variable i -ésima, p^{max} , el valor máximo de dicha variable, p_i el valor de la variable a normalizar.

El segundo método es la normalización de los datos de entrada y salida empleando la transformación normal

$$pz = \frac{p_i - \mu}{\sigma} \quad \text{Ec. 2-19}$$

donde p_i es el valor de la variable, μ es la media del conjunto de entrenamiento y σ su desviación estándar. De esta forma, cada variable del conjunto de entrenamiento pasa a tener media 0 y varianza 1, generalmente la normalización se aplica tanto en al conjunto de entradas como en el de salidas.

La decorrelación de los datos contribuyen a que las secciones transversales de la superficie de error sean menos alargadas lo que facilita al mínimo de la función de error, para lograr la decorrelación entre las variables se aplica el algoritmo PCA (Principal Component Analysis), cuya traducción al español sería Análisis de Componentes Principales. El análisis de componentes principales, aplica no sólo para decorrelacionar las variables de entrada, sino como mecanismo de reducción de la dimensionalidad de los datos. Además, ayuda a reducir significativamente la dimensionalidad de los datos de entrada y, de paso, el número de parámetros entrenables necesarios para la red neuronal. (Haykin, 2005), (Berzal, 2018)

Después del pre-procesamiento de los datos, la base de datos se divide en dos conjuntos: entrenamiento y prueba, el conjunto de entrenamiento generalmente abarca del 70 al 90% del conjunto de los datos originales, según la cantidad de datos disponibles, el conjunto de prueba el restante porcentaje. Es importante que

Capítulo 2: Marco Teórico

estos dos subconjuntos de datos sean representativos, es decir el conjunto de prueba esté en la misma región del espacio de entradas que el conjunto de entrenamiento. El método más simple para dividir el conjunto de datos original es seleccionar muestras aleatorias para cada uno de los subconjuntos, usualmente este método proporciona buenos resultados. (Hagan, Demuth, Beale, & De Jesús, 2014), (Haykin, 2005), (Berzal, 2018).

El siguiente paso es seleccionar el tipo adecuado de red dependiendo del problema a resolver, Hagan, Demuth, Beale, & De Jesús (2014) dividen estos problemas en cuatro grupos: problemas de aproximación, clasificación, clustering o agrupación y problemas de predicción. En los problemas de aproximación o de regresión, se busca que la red neuronal aproxime una función, dado un vector de entradas. El tipo de red neuronal típico es el perceptrón multicapa, con la tangente hiperbólica como función de activación en las capas de entrada y ocultas y la función lineal en la capa de salida dado que la salida de la red es una variable continua. Para la mayoría de los problemas una capa oculta es suficiente, pero si los resultados no son los esperados se puede agregar otra capa oculta más; es muy raro ocupar más de dos capas en este tipo de problemas.

Después de la selección de la arquitectura base, se especifican la cantidad de capas y el número de neuronas en cada capa. En el caso de las redes multicapa, el procedimiento estándar es inicializar la red con una capa oculta, si el índice de rendimiento no es satisfactorio se agrega otra capa oculta y se vuelve a entrenar la red. También es necesario seleccionar el número de neuronas en las capas ocultas, éstas dependen de la complejidad del problema a resolver; en el caso de la capa de entrada, el número de neuronas viene dado por el número de variables del problema y la cantidad de neuronas en la capa de salida está definido por el número de componentes del vector de salidas. (Hagan, Demuth, Beale, & De Jesús, 2014).

Para la mayoría de las aplicaciones basadas en redes neuronales, el error en el entrenamiento nunca será igual a cero, exceptuando problemas linealmente separables utilizando redes monocapa. Sin embargo, esto casi nunca pasa en las



redes multicapa, por esta razón se necesita de un criterio de finalización para detener el algoritmo de entrenamiento. Un criterio es detener el entrenamiento cuando el error alcance un valor pequeño cercano a cero. Otro es la cantidad de iteraciones o épocas que ha entrenado la red, generalmente un número elevado de épocas. Si se llega a alcanzar el número máximo de épocas y los parámetros de la red no convergieron, se reinicia el entrenamiento partiendo de los últimos pesos calculados como condición inicial del algoritmo. Otro criterio de finalización es utilizar la norma del vector gradiente de la función de coste. Cuando la norma del gradiente alcanza un valor pequeño cercano a cero, el algoritmo puede dejar de entrenar, dado que gradiente vale cero en los puntos críticos de la función, en este caso un mínimo. Desafortunadamente, la superficie de error para redes multicapa puede tener muchas regiones planas, donde la norma del gradiente puede ser muy pequeño, sin llegar a ser un mínimo de la función. (Hagan, Demuth, Beale, & De Jesús, 2014)

El criterio más utilizado es utilizar el error cuadrático medio, Ec 2-20

$$E = \frac{1}{QS^M} \sum_{q=1}^Q (\mathbf{t}_q - \mathbf{a}_q)^T (\mathbf{t}_q - \mathbf{a}_q) \quad \text{Ec. 2-20}$$

Posteriormente se escoge el algoritmo de entrenamiento apropiado al tipo de red seleccionada y del problema que se desea resolver. Entrenada la red, se desea analizar el desempeño, esto permite encontrar problemas con el conjunto de entrenamiento, la arquitectura de la red o el algoritmo de entrenamiento.

Las técnicas más utilizadas al momento de evaluar redes neuronales artificiales entrenadas para resolver problemas de predicción de valores es el cálculo de la ecuación de regresión entre las salidas deseadas o reales y las salidas calculadas por la RNA. Además de la ecuación de regresión es típico calcular el coeficiente de determinación R^2 y de correlación R . El valor de R está en el rango de -1 a 1, siendo el valor de 1 o cercano a éste el esperado cuando se evalúa el rendimiento de una RNA, el valor de R^2 (coeficiente de determinación) en ocasiones es usado en lugar

Capítulo 2: Marco Teórico

de R , el coeficiente de determinación representa la porción de la variabilidad en los datos que es explicada por el modelo de regresión. Cuando los valores de R^2 o R son significativamente menores a 1, la red neuronal no realiza una buena aproximación de la función a predecir. Estos pasos se repiten hasta que el índice de desempeño de la red es satisfactorio. (Hagan, Demuth, Beale, & De Jesús, 2014).

3 MATERIALES Y MÉTODOS

3.1 Sitio experimental

El experimento se llevó a cabo en el campo experimental “La Xerona” perteneciente al Departamento de Irrigación de la Universidad Autónoma Chapingo. La parcela seleccionada es un campo de 4.5 hectáreas, los suelos tienen una composición franco-arenoso y franco-arcilloso, ubicado en las siguientes coordenadas geográficas 19°29'02"N, 98°53'43"W (**¡Error! No se encuentra el origen de la referencia.**).



Figura 10 Sitio experimental "La Cerona"

La semilla sembrada fue maíz de la variedad ocelote, utilizado principalmente como forraje. Según la página de Asgrow, (s.f.), la altura de la planta va desde los 210 a los 270 cm, tiene un ciclo vegetativo precoz que tarda entre 63 a 65 días en floración y 155 a 165 días para su cosecha. La siembra se llevó a cabo el día 29 de mayo del

2023, con una distancia entre surcos de 80 cm y una separación entre plantas de 15 cm.

3.2 Dron DJI Mavic 3M

El 21 de septiembre, transcurridos 88 días después de la siembra se realizó el primer vuelo en el horario de 12:00 a las 13:30 hr. Para la toma de las imágenes se utilizó el dron DJI Mavic 3 Multiespectral (Figura 11) equipado con cámaras multiespectral y RGB. En el Anexo A se presentan las características principales del dron mencionado.



Figura 11 Drone DJI Mavic 3M, fuente: <https://elvuelodeldrone.com/drones-profesionales/drones-dji/mavic-3-multiespectral/>

3.3 Planeación de los vuelos y muestreo en campo

Para este experimento se planificaron dos vuelos utilizando el software DJI Pilot 2 con los siguientes parámetros, 50 y 30 m respectivamente para el primer y segundo vuelo, 80% de traslape frontal, 70% de traslape lateral, posición nadir (90°) de la cámara respecto al terreno.

Para georreferenciar las imágenes aéreas se utilizó una estación móvil GNSS de alta precisión D-RTK 2 (Figura 12) y para la georreferenciación de los puntos de muestreo en campo un GPS-RTK topográfico marca Trimble® (Figura 13)



Figura 12 Antena D-RTK 2



Figura 13 GPS-RTK Trimble obtenido de <https://www.4kequipment.com/trimble-single-r10-m1-v1-receiver-gps-kit-w-tsc3-data-collector-access-software/>

Capítulo 3: Materiales y Métodos

El primer vuelo se realizó con el fin de caracterizar la variabilidad del cultivo en la parcela, para ello, se generó el ortomosaico del terreno del cultivo y así calcular el índice de vegetación NDVI. En la Figura 14 se muestra el mapa NDVI generado, se clasificó dos zonas principales, aquellas con valor NDVI mayor a 0.6 identificadas con el color verde y zonas anaranjadas con un valor de NDVI entre 0.3 y 0.6, los caminos y zonas donde el cultivo no creció se identificaron en color negro. Con base en el análisis del mapa NDVI se tomó la decisión de tomar 80 muestras aleatorias para cubrir la mayor variabilidad posible del campo. El terreno de cultivo está seccionado en siete partes de las cuales se tomaron seis, nombradas desde la A hasta F, los puntos de muestreo se georreferenciaron utilizando el equipo GPS-RTK Trimble® con una precisión planialtimétrica de 2.5 centímetros.

Posteriormente esta información se ingresó al software Qgis para mostrar los puntos en el mapa. Basándose en las características de plantación, se tomó la decisión que el área de muestreo fuera de medio metro cuadrado, abarcando dos surcos de plantación y medio metro de ancho.




Figura 14 Ráster del terreno obtenido al aplicar el índice de vegetación NDVI

Las plantas contenidas dentro del área de muestreo se cosecharon a ras de suelo, se identificaban con una etiqueta de papel asignándole la letra del sector al que pertenecían y el número de muestra tomada. Se midió la altura de cada planta de maíz con y sin espiga, así como el peso total de la muestra (Figura 15), estos datos se anotaron en el formato de registro de datos.



Figura 15 Procedimiento de medición y pesado de las muestras

3.4 Cálculo de los índices de vegetación

El segundo vuelo se realizó el día 23 de septiembre de 2023 en horas similares al del primer vuelo, a una altura de 30 metros con un tamaño de pixel de 1cm en caso de las bandas RGB y de 1.9 cm para las bandas multiespectrales. Con las imágenes tomadas se generó la ortoimagen y se calcularon los índices de vegetación listados en la Cuadro 2.

Los índices de vegetación se calcularon utilizando el software Qgis® 3.32.2; como primer paso se separaron las bandas de los ortomosaicos RGB y Multiespectrales generados en Agisoft Metashape®. Posteriormente, en la calculadora ráster se ingresaba la fórmula para cada índice de vegetación, generando una nueva imagen

Capítulo 3: Materiales y Métodos

tipo ráster. En la Figura 16 se puede observar como el software calcula ciertas estadísticas del área analizada, siendo el promedio del valor del índice de vegetación el utilizado como parámetro de entrada a la RNA. Este procedimiento se repitió en los 80 puntos de muestreo generando así la base de datos del experimento.




Figura 16 Media de NDVI para la muestra F80

Para el cálculo del índice de área foliar (LAI) se aplicó la fórmula propuesta por Waters, Allen, Tasumi, Trezza , & Bastiaanssen, (2002) que indican que dicho valor puede obtenerse a partir del valor del índice de vegetación SAVI.(Ec 3-1)

$$LAI = -\frac{1}{0.91} * \ln\left(\frac{0.69 - SAVI}{0.59}\right) \quad \text{Ec. 3-1}$$

3.5 Pre-procesamiento de los datos

El Preprocesamiento de los datos consistió en tres etapas en la primera, se determinó la matriz de correlación entre las variables de entrada, índices de vegetación, número de plantas por área muestreada, altura de la planta con espiga y sin espiga y el índice de área foliar respecto a la biomasa del maíz,



seleccionándose las que tuvieron una correlación positiva. La segunda consistió en aplicar el algoritmo de componentes principales al subconjunto de variables. Como tercera etapa, las componentes principales se normalizaron utilizando la Ec 2.19, mientras que los valores de la biomasa se escalaron entre 0 y 1 utilizando la Ec 2.18. Como último paso se separó, de manera aleatoria la base de datos en dos subconjuntos, el 90% de los datos, es decir, 72 muestras para el entrenamiento de la RNA y el restante 10%, o sea 8 muestras para la base de prueba; esto se repitió tres veces generando tres diferentes bases de entrenamiento y prueba, con la finalidad de comprobar si el modelo de red propuesto generalizaba correctamente.

3.6 Diseño de la red neuronal artificial

La arquitectura de la red neuronal artificial es una red multicapa, ésta tiene tres capas, la capa de entrada con 30 neuronas, función de activación tangente hiperbólica, la capa oculta con 5 neuronas con función de activación tangente hiperbólica y la capa de salida con una neurona y función de activación lineal (Figura 17). Para el entrenamiento se ocupó el algoritmo de retropropagación del error con la variante ADAM cuyos hiperparámetros son $\alpha = 0.001, \beta_1 = 0.9, \beta_2 = 0.999$, con 2,500 épocas de entrenamiento, con criterio de finalización al alcanzar un $ecm \leq 5 \times 10^{-4}$.




Figura 17 Arquitectura de la Red Neuronal Artificial usada para estimar la biomasa del maíz

3.7 Entrenamiento de la RNA

Para el entrenamiento y selección de los hiperparámetros de la RNA, se utilizó el algoritmo del descenso del gradiente, este es un proceso estocástico, que converge a un mínimo local, lo que implica un continuo proceso de entrenamiento y prueba hasta obtener resultados idóneos. De igual manera la cantidad de capas ocultas y el número de neuronas en cada capa es un proceso de prueba y error, no hay alguna metodología que indique cual es el número óptimo de estos hiperparámetros, por lo que la experiencia del programador al momento de generar modelos de RNA le indicará si hay que aumentar o disminuir el número de neuronas por capa o agregar nuevas capas ocultas. En el caso de modelos predictivos utilizando perceptrones multicapa, Berzal, (2018), (Hagan, Demuth, Beale, & De Jesús, (2014), Haykin, (2005), indican que una o dos capas ocultas son suficientes. Para el número de neuronas es ir viendo la rapidez en la convergencia del algoritmo y la capacidad que tiene el modelo entrenado para predecir patrones de pruebas, si éste no tiene los resultados esperados se recomienda primero cambiar el número de neuronas de la primera capa oculta, probar los resultados, sino se obtienen los valores deseados, cambiar el número de neuronas de la segunda capa, así hasta que el modelo empiece a predecir correctamente. Otro aspecto a tener en cuenta al momento de entrenar el modelo son los hiperparámetros del algoritmo de entrenamiento, el algoritmo ADAM es un algoritmo que en cada época va adaptando las tasas de aprendizaje para que éste converja más rápido al mínimo local, aunque estos valores provocasen oscilaciones en otros algoritmos de entrenamiento, por ejemplo, en backpropagation cuya tasa de aprendizaje permanece constante.

3.8 Análisis del rendimiento de la RNA

Para el análisis del rendimiento del modelo predictor de biomasa aérea propuesto se calculó la ecuación de regresión entre las salidas de la red y las salidas deseadas. Para el cálculo de la ecuación de regresión lineal (Ec 3-2) se da solución al siguiente sistema de ecuaciones



$$\begin{bmatrix} Q & \sum t \\ \sum t & \sum t^2 \end{bmatrix} \begin{bmatrix} c \\ m \end{bmatrix} = \begin{bmatrix} \sum a \\ \sum ta \end{bmatrix}$$

$$\hat{a} = mt + c$$

Ec. 3-2

Además de la ecuación de regresión se calculan los coeficientes de determinación R^2 (Ec. 3-3) y de correlación R (Ec. 3-4), la raíz del error cuadrado medio (RMSE), (Ec 3-5) y el error absoluto medio (MAE), (Ec 3-6) entre t_q y a_q

$$R^2 = 1 - \frac{\sum_{q=1}^Q (t_q - a_q)^2}{\sum_{q=1}^Q (t_q - \bar{t})^2}$$

Ec. 3-3

$$R = \sqrt{R^2}$$

Ec. 3-4

$$RSME = \sqrt{\frac{1}{Q} \sum_{q=1}^Q (t_q - a_q)^T (t_q - a_q)}$$

Ec. 3-5

$$MAE = \frac{1}{Q} \sum_{q=1}^Q \frac{|t_q - a_q|}{t_q}$$

Ec 3-6

Donde:

- Q = Número de muestras en la base de entrenamiento
- t = Valor de la biomasa real
- a = Valor de la biomasa calculada por la RNA
- c = ordenada al origen de la recta de regresión
- m = pendiente de la recta de regresión

En el anexo B, se encuentra el código QR que redirige a un repositorio de GitHub donde se encuentran los archivos en Python, así como la base de datos utilizada para generar, entrenar y evaluar el modelo predictivo de biomasa de maíz forrajero.

4 RESULTADOS Y DISCUSIÓN

4.1 Análisis estadístico de los datos de altura y peso

Se muestran en las Figuras 18 a la 20. El histograma de las alturas de las plantas la mayoría de éstas, 46 de las 80 muestras se encuentran en una altura de 235 a 255 cm, la media fue de 236.7 cm con un coeficiente de variación de 0.167 valor pequeño que significa que no existe mucha variabilidad en los datos. Respecto a la cantidad de plantas por área muestreada siete u ocho plantas fue la frecuencia más repetida siendo la moda de este conjunto de datos siete plantas por cada medio metro cuadrado, el coeficiente de variación fue de 0.123, de igual manera valor pequeño que indica una variabilidad pequeña en este conjunto de datos. De la biomasa promedio por área muestreada, la mayoría de las plantas pesaban entre 3.5 a 5.5 kg, la media de todas las muestras es de 4.44 kg, el coeficiente de variación fue de 0.338 presentando una mayor variabilidad en comparación de las otras dos variables. Los tres histogramas presentan cierta normalidad en los datos. En el Cuadro 4 se muestran las medidas de tendencia central y de dispersión de las tres variables analizadas.

Cuadro 4 Estadísticos de las variables número de plantas, altura con espiga y biomasa

Estadístico	Número Plantas	Altura Espiga [cm]	Peso [kg]
Media	7.6	236.71	4.44
Mediana	7.5	241.75	4.42
Moda	7	259.86	5.58
Des. Estándar	1.26	29.02	1.50
CV	0.167	0.123	0.338




Figura 18 Histograma de la altura de las plantas con espiga




Figura 19 Histograma del número de plantas por área muestreada




Figura 20 Histograma de la biomasa aérea de maíz

Capítulo 4: Resultados y Discusión

4.2 Análisis del pre-procesamiento de la base de datos

La base de datos se pre-procesó utilizando el framework scikit-learn de Python, se calculó la matriz de correlaciones para observar el tipo de relación presentes entre la biomasa del cultivo y las diferentes variables medidas. En la Figura 21 en la última fila se puede apreciar que existen variables que están fuertemente relacionadas (>0.75), medianamente correlacionadas (>0.5 y <0.75) y débilmente relacionadas (<0.5) con la biomasa. Con base en esa información se seleccionaron las variables positivamente relacionadas con el peso del cultivo, por lo tanto, el índice de vegetación RGBVI, ExG y las Banda roja (BR), Banda verde (BG) y Banda azul (BB) se eliminaron del análisis al igual que la altura de la planta sin espiga ya que, esta variable es redundante con la altura de la planta con espiga. Quedando el siguiente subconjunto de variables de entrada: número de plantas por área muestreada, altura de la planta con espiga, NDVI, EVI, GNDVI, WDRVI, Clre, RVI, SAVI, VARI, NGRDVI y LAI




Figura 21 Matriz de correlación



Dado los resultados de la matriz de correlación, se obtuvo que la altura de la planta con espiga es el parámetro mejor correlacionado con la biomasa aérea. En la Figura 22 se muestra el diagrama de dispersión de ambas variables, observándose que justamente la relación entre altura y biomasa sigue una tendencia lineal positiva, en alturas pequeñas la biomasa tiende un valor más lineal que cuando la planta es más alta, presentando mayor variabilidad. Esto es debido al poco número de muestras tomadas, lo que no muestra la variabilidad en el caso de pesos bajos y alturas pequeñas.




Figura 22 Diagrama de dispersión de la altura de las plantas vs la biomasa aérea de maíz

Siguiendo la recomendación de Hagan, Demuth, Beale, & De Jesús, (2014) se aplicó el análisis de componentes principales (PCA) a las variables seleccionadas. En la Figura 23 se muestra el nivel de varianza explicada por cada componente principal calculado, se puede observar que con seis componentes principales el porcentaje de varianza explicada es de 99%, por lo que fue esa cantidad de componentes principales seleccionada para generar la base de entrenamiento y prueba de la RNA.




Figura 23 Varianza explicada por cada componente principal

4.3 Análisis del entrenamiento de red neuronal artificial

Del modelo de red neuronal artificial propuesto se realizaron tres entrenamientos con tres diferentes particiones aleatorias de la base de datos, con el fin de verificar si los hiperpárametros de la arquitectura generalizaba correctamente. Se generaron las gráficas del error cuadrado medio contra la cantidad de épocas, esta gráfica indica si los hiperparámetros de entrenamiento seleccionados (α, β_1, β_2) hacen que el algoritmo converja a un mínimo local. En la Figura 24 se observa el comportamiento de los tres entrenamientos concluyendo que la arquitectura de la RNA propuesta y los hiperparámetros del algoritmo converge a un mínimo local de la función de error, cada uno con un número diferente de épocas, debido al carácter aleatorio del algoritmo.




Figura 24 a




Figura 24 b




Figura 24 c

Figura 24 Gráfica de los ecm vs épocas, se muestra el comportamiento del ecm para cada entrenamiento de la RNA, a) Primer entrenamiento, b) Segundo entrenamiento, c) Tercer entrenamiento

4.4 Análisis del rendimiento de la RNA

En el Cuadro 5 se resumen los resultados obtenidos durante el entrenamiento del modelo predictivo propuesto con las tres diferentes particiones, se observa que los rendimientos son similares, buenos coeficientes de determinación, errores cuadrados medios con valores bajos, así como el error absoluto medio. El modelo entrenado con la tercera partición mostró un coeficiente de determinación menor a los otros dos entrenamientos, pero el MAE más bajo de los tres, así como la ecuación de regresión, que fue la más cercana a los valores ideales o teóricos, por lo que, esta participación de la base de datos es la mejor de las tres.

Capítulo 4: Resultados y Discusión

Cuadro 5 Resumen de los resultados obtenidos

Partición de la base de datos	R^2 [%]	ECM [Kg ²]	RECM [kg]	MAE [kg]	Ecuación de regresión
1	95.44	0.07	0.264	0.157	$a=1.158t-0.596$
2	95.3	0.11	0.33	0.2	$a=0.941t+0.33$
3	92.87	0.05	0.23	0.15	$a=1.027t-0.12$

En la Figura 25 se muestra el diagrama de dispersión entre la biomasa real y la biomasa estimada por el modelo predictivo y la gráfica de la ecuación de regresión lineal. En la gráfica del entrenamiento de la red neuronal se observa que el modelo aprendió la mayoría de los patrones de entrenamiento, sin sobre entrenarse. El análisis del rendimiento presenta errores cuadrados y absolutos medios pequeños, la ecuación de regresión tiene pendiente cercana a uno y una ordenada al origen próximo a cero.




Figura 25 Gráfica de regresión lineal y valor de los coeficientes de rendimiento del tercer entrenamiento del modelo de la RNA



En la Figura 26 se presenta el diagrama de dispersión de la prueba de la RNA y la ecuación de regresión calculada, observándose que el modelo predictor de biomasa estima correctamente los valores de los patrones de prueba, ya que, los errores fueron pequeños y la ecuación de regresión valores cercanos a los ideales. La tercera partición presentó un $R^2 = 92.9 \%$, el $ECM=0.055[\text{kg}^2]$, un $RECM= 0.235 [\text{kg}]$ y un $MAE= 0.15[\text{kg}]$, valores más pequeños obtenido por los tres entrenamientos.




Figura 26 Gráfica de regresión y valor de los coeficientes de evaluación de la RNA para la tercera base de datos

En el Cuadro 6 se presentan los resultados obtenidos por el modelo al momento de predecir los valores de biomasa al presentársele la base de prueba. Al analizar los errores se observa que solo tiene un error mayor al 10%, el caso del error absoluto de 12.36%, los otros errores son menores al 5%.

Capítulo 4: Resultados y Discusión

Cuadro 6 Errores absolutos del modelo predictivo entrenado y probado con la tercera partición de la base de datos

Muestra	1	2	3	4	5	6	7	8
Peso real [kg]	3.63	4.85	4.90	3.68	6.28	4.46	5.43	5.05
Peso estimado [kg]	3.61	5.45	4.70	3.65	6.32	4.29	5.38	4.97
Error [kg]	0.03	0.60	0.20	0.03	0.04	0.18	0.05	0.08
Error [%]	0.71%	12.36%	4.01%	0.91%	0.60%	3.97%	0.84%	1.64%

Las gráficas de las pruebas de la RNA con las otras dos particiones se muestran en las Figura 27 y Figura 28, en ellas se observa, al igual que en la Figura 26, que los tres entrenamientos tuvieron problemas al estimar valores de biomasa entre 4.5 y 6 kg, esto debido a la variabilidad presente en el muestreo.




Figura 27 Gráfica de regresión y valor de los coeficientes de evaluación de la RNA para la primera base de datos




Figura 28 Gráfica de regresión y valor de los coeficientes de evaluación de la RNA para la segunda base de datos

5 CONCLUSIONES

Los índices de vegetación NDVI, EVI, RVI, SAVI, VARI, NGRDVI al igual que la altura de la planta fueron los mejores correlacionados con la biomasa según la matriz de correlaciones, por lo que, el uso de estos índices al momento de predecir biomasa no debe de ser omitidos.

Las redes neuronales artificiales son modelos de aprendizaje profundo con muy buenos resultados al momento de predecir la biomasa aérea de maíz, el perceptrón multicapa propuesto obtuvo resultados de $R^2= 92.87\%$, un $ECM=0.5[kg^2]$ y un $MAE=0.15 [kg]$ por cada metro cuadrado.

La RNA propuesta se entrenó tres veces con diferentes particiones de la base de datos, con la finalidad de probar que dicha arquitectura generalizaba correctamente la biomasa.



6 RECOMENDACIONES

Como sugerencia para aumentar la eficiencia en tiempos al momento de entrenar una RNA sería cambiar el enfoque del algoritmo, en vez de utilizar los algoritmos de entrenamiento clásicos basados en la regla del descenso del gradiente, utilizar algoritmos de aprendizaje de máquina o machine learning, por ejemplo, algoritmos genéticos, computación evolutiva o el algoritmo de optimización por enjambre de partículas (PCO). Estos algoritmos, cada uno a su modo, proponen una nube de soluciones iniciales, el algoritmo va buscando en el dominio de búsqueda la solución óptima no importando si la función de objetivo tenga varios mínimos locales. Estos algoritmos convergen a mínimos globales o mínimos locales fuertes, lo que quita ese inconveniente de los algoritmos basados en el descenso del gradiente que se estancan en un mínimo local sea fuerte o débil.

De igual manera se recomienda utilizar vuelos oblicuos para generar el modelo digital de elevación y así estimar la altura de las plantas.

De igual manera el número de plantas por área muestreada igualmente se puede estimar utilizando drones, por lo que, las variables necesarias para estimar la biomasa de maíz forrajero utilizando el modelo predictor propuesto en esta investigación pueden ser obtenidos sin la necesidad de muestrear valores en campo.



7 REFERENCIAS

Asgrow. (s.f.). *Asgrow*. Recuperado el 14 de Septiembre de 2023, de Ocelote: <https://www.asgrow.com.mx/es-mx/productos/maiz/product-detail-template.html/ocelote-occidente.html>

Bahrami, H., Homayouni, S., Safari, A., Mirzaei, S., Mahdianpari, M., & Reisi-Gahrouei, O. (3 de Julio de 2021). Deep Learning-Based Estimation of Crop Biophysical Parameters Using Multi-Source and Multi-Temporal Remote Sensing Observations. *Agronomy*. doi:doi.org/10.3390/agronomy11071363

Ballesteros, R., Ortega, J. F., Hernández, D., & Moreno, M. (2018). Onion biomass monitoring using UAV-based RGB imaging. *Precision Agriculture*. doi:10.1007/s11119-018-9560-y

Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., & Bareth, G. (2014). Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. *Remote Sensing*, 11. doi: <https://doi.org/10.3390/rs61110395>

Berzal, F. (2018). *Redes Neuronales & Deep Learning*. Granada.

Bulut, S., Sivrikaya, F., & Günlü, A. (2022). Evaluating statistical and combine method to predict stand above-ground biomass using remotely sensed data. *Arabian Journal of Geosciences*. doi:<https://doi.org/10.1007/s12517-022-10140-3>

Bwambale, E., Abagale, F., & Anornu, G. (2022). Smart irrigation monitoring and control strategies for improving water uses efficiency in precision agriculture: A review. *Agricultural Water Management*. doi:10.1016/j.agwat.2021.107324

Calou, V., Teixeira, A., Moreira, L., da Rocha Neto, O., & da Silva, J. (2019). ESTIMATION OF MAIZE BIOMASS USING UNMANNED AERIAL



- VEHICLES. *Engenharia Agrícola*. doi:<https://doi.org/10.1590/1809-4430-Eng.Agric.v39n6p744-752/2019>
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., & Grégoire, J. (2001). Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment*, 22-33.
- Chen, J., Zhang, H., Bian, Y., Li, X., & Lv, G. (2022). Construction of Remote Sensing Model of Fresh Corn Biomass Based on Neural Network. *Hindawi Computational Intelligence and Neuroscience*, 8. doi:<https://doi.org/10.1155/2022/2844563>
- Dang, A., Nandy, S., Srinet, R., Luong, N., Ghosh, S., & Kumar, A. (2019). Forest aboveground biomass estimation using machine learning regression algorithm in Yok Don National Park, Vietnam. *Ecological Informatics*, 24-32. doi:<https://doi.org/10.1016/j.ecoinf.2018.12.010>.
- Endicot, S., Brueland, B., Keith, R., Schon, R., Bremer, C., Farnham, D., . . . Carter, P. (2015). *Maiz Crecimiento y desarrollo*. Obtenido de DuPont Pioneer: https://www.pioneer.com/CMRoot/International/Latin_America_Central/Chile/Servicios/Informacion_tecnica/Corn_Growth_and_Development_Spanish_Version.pdf
- Fassio, A., Ibañez, W., Fenández, E., Cozzolino, D., Pérez, O., Restaino, E., . . . Vergara, G. (2018). *El cultivo de maíz para la producción de forraje y grano y la influencia del agua*. Uruguay: Instituto nacional de investigación agropecuaria.
- Fonseca González, W. (2017). Revisión de métodos para el monitoreo de biomasa y carbono vegetal en ecosistemas forestales tropicales. *Ciencias Ambientales*, 91-109. doi:<http://dx.doi.org/10.15359/rca.51-2.5>

Referencias

- Galeana Pizaña, J. M., Núñez Hernández, J. M., & Corona Romero, N. (2016). Remote Sensing-Based Biomass Estimation. En *Environmental Applications of Remote Sensing* (pág. 418). doi:<http://dx.doi.org/10.5772/61813>
- Geng, L., Che, T., Ma, M., Tan, J., & Wang, H. (16 de Junio de 2021). Corn Biomass Estimation by Integrating Remote Sensing and Long-Term Observation Data Based on Machine Learning Techniques. *Remote Sensing*(13). doi:<https://doi.org/10.3390/rs13122352>
- Gitelson, A., Gritz, Y., & Merzlyak, M. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271-282.
- Gitelson, A., Kaufman, Y., & Merzlyak, M. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289-298.
- Guía para el cultivo de maíz 1era parte. (s.f de s.f de s.f). *Hydro Environment*. Recuperado el 07 de 07 de 2022, de Guía para el cultivo de maíz 1era parte: https://www.hydroenv.com.mx/catalogo/index.php?main_page=page&id=371
- Hagan, M., Demuth, H., Beale, M., & De Jesús, O. (2014). *Neural Network Design* (Segunda ed.).
- Han, L., Yang, G., Dai, H., Xu, B., Yanh, H., Feng, H., & Li, Z. (04 de Febrero de 2019). Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. *Plant Methods*, 15(10). doi:<https://doi.org/10.1186/s13007-019-0394-z>
- Harvesting to determine biomass. (s.f.). *Rangelands Gateway*. Recuperado el 08 de julio de 2022, de <https://rangelandsgateway.org/inventorymonitoring/bioharvest>



- Haykin, S. (2005). *Neural Networks, A Comprehensive Foundation*. Ontario: Pearson.
- Huang, H., Liu, C., Wang, X., Zhou, X., & Gong, P. (2019). Integration of multi-resource remotely sensed data and allometric models of forest aboveground biomass estimation in China. *Remote Sensing of Environment* .
- Huete, A., Didan, K., & Miura, T. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213.
- Hunt, E., & Rock, B. (1989). Detection of changes in leaf water content using near- and middle-infrared reflectances. *Remote Sensing of Environment*, 30(1), 43-54.
- Indirect methods to determine biomass. (s.f.). *Rangelands Gateway*. Recuperado el 08 de julio de 2022, de <https://rangelandsgateway.org/inventorymonitoring/bioindirect>
- Jin, X., Li, Z., Feng, H., Ren, Z., & Li, S. (18 de Julio de 2019). Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index. *The Crop Journal*. doi:<https://doi.org/10.1016/j.cj.2019.06.005>
- Kachamba, D. J., Orka, H. O., Gobakken, T., Eid, T., & Mwase, W. (2016). Biomass Estimation Using 3D Data from Unmanned Aerial Vehicle Imagery in a Tropical Woodland. *Remote Sensing*, 8(11), 968. doi:<https://doi.org/10.3390/rs8110968>
- Li, W., Zhang, C., Ma, T., & Li, W. (2021). Estimation of summer maize biomass based on a crop growth model. *Emirates Journal of Food and Agriculture*., 742-750. doi:doi: 10.9755/ejfa.2021.v33.i9.2757

Referencias

- Li, Y., Li, M., Li, C., & Liu, Z. (2020). Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. *Scientific Reports*. doi:<https://doi.org/10.1038/s41598-020-67024-3>
- Luo , Y., Wang, X., Ouyang, Z., Lu, F., Feng, L., & Tao, J. (2020). A review of biomass equations for China's tree species. *Earth System Science Data*, 21-40. doi:<https://doi.org/10.5194/essd-12-21-2020>
- Marcos, J. L., Gil, M., Ortiz, J., Martínez, S., Garrido, F., Sánchez, L. F., . . . Ortiz, L. (2016). Determinación de biomasa en parcelas de cultivos herbáceos mediante cámaras ópticas elevadas por medio de vehículos aéreos no tripulados (UAV). *Investigación Cualitativa en Ingeniería y Tecnología*.
- Methods to determine biomass. (s.f.). *Rangelands Gateway*. Recuperado el 08 de julio de 2022, de <https://rangelandsgateway.org/inventorymonitoring/biomassmethods>
- Mora Delgado, J., & Holguín, V. (2018). Aplicación de modelos matemáticos no lineales para la estimación de biomasa forrajera de *Tithonia diversifolia* (Hemsl.) A. Gray. *Rev. U.D.C.A Act & Div. Cient.*, 43-50.
- Muñoz Aguayo, P. (2013). Apuntes de Teledetección; Índices de vegetación. *Centro de Información de Recursos Naturales*.
- Nath, A. J., Tiwari, B. K., Sileshi, G., Sahoo, U. K., Brahma, B., Deb, S., . . . Gupta, A. (2019). Allometric Models for Estimation of Forest Biomass in North East India. *Forest*, 103. doi:<https://doi.org/10.3390/f10020103>
- Nui, Y., Zhang, L., Zhang, H., Han, W., & Peng, X. (28 de Mayo de 2019). Estimating Above-Ground Biomass of Maize Using Features Derived from UAV-Based RGB Imagery. (11). doi:<https://doi.org/10.3390/rs11111261>
- Palma Méndez, J., & Marín Morales, R. (2008). *Inteligencia Artificial, técnicas, métodos y aplicaciones*. España: Mc Graw Hill.



- Pino, E. V. (2019). Los drones una herramienta para una agricultura eficiente: un futuro de alta tecnología. *IDESIA*, 37(1), 75-84.
- Plant dimensions. (s.f.). *Rangelands Gateway*. Recuperado el 08 de julio de 2022, de <https://rangelandsgateway.org/inventorymonitoring/plantdimensions>
- Ponce Cruz, P. (2010). *Inteligencia Artificial con aplicaciones a la ingeniería*. Ciudad de México: Alfaomega.
- Pottier, J., & Jabot, F. (2017). Non-destructive biomass estimation of herbaceous plant individuals: A transferable method between contrasted environments. *Ecological Indicators*, 769 - 776. Obtenido de <https://hal.archives-ouvertes.fr/hal-01521547>
- Rouse, J., Haas, R., Schell, J., & Deering, D. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication*, 351, 309-317.
- Schirrmann, M., Giebel, A., Gleiniger, F., Pflanz, M., Lentschke, J., & Dammer, K.-H. (2016). Monitoring Agronomic Parameters of Winter Wheat Crops with Low-Cost UAV Imagery. *Remote Sens*.
- Sharma, P., Leigh, L., Chang, J., Maimaitijiang, M., & Caffé, M. (2022). Above-Ground Biomass Estimation in Oats Using UAV Remote Sensing and Machine Learning. *Sensors*, 22. doi:<https://doi.org/10.3390/s22020601>
- SIAP. (2021). Recuperado el 05 de 05 de 2023, de Anuario Estadístico de la Producción Agrícola: <https://nube.siap.gob.mx/cierreagricola/>
- Tackenberg, O. (2007). A New Method for Non-destructive Measurement of Biomass, Growth Rates, Vertical Biomass Distribution and Dry Matter Content Based on Digital Image Analysis. *Oxford journals*. doi:doi:10.1093/aob/mcm009, available online at www.aob.oxfordjournals.org

Referencias

- Tucker, C. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127-150.
- Wang, C., Nie, S., Xi, X., Luo, S., & Sun, X. (2017). Estimating the biomass of maize with hyperspectral and LiDAR data. *Remote Sens*, 9-11. doi:10.3390/rs9010011
- Wang, T., Liu, Y., wang, M., Fan, Q., Tian, H., Qiao, X., & Li, Y. (09 de abril de 2021). Applications of UAS in Crop Biomass Monitoring: A Review. *Frontiers in Plant Science*. doi:10.3389/fpls.2021.616689
- Waters, R., Allen, R., Tasumi, M., Trezza , R., & Bastiaanssen, W. (2002). *Surface Energy Balance Algorithms for Land*. Idaho.
- Yara México. (2022). *Principios agronómicos*. Recuperado el 08 de 07 de 2022, de <https://www.yara.com.mx/nutricion-vegetal/maiz/principios-agronomicos/#:~:text=La%20mayor%20producci%C3%B3n%20del%20ma%C3%ADz,m%C3%A1s%20alto%20de%20los%20cereales>.
- Zhang, Y., Ma, J., Liang, S., Li, X., & Li, M. (2020). An Evaluation of Eight Machine Learning Regression Algorithms for Forest Aboveground Biomass Estimation from Multiple Satellite Data Products. *Remote Sensing*. doi: <https://doi.org/10.3390/rs12244015>
- Zhu, Y., Zhao, C. J., Yang, G. J., Han, L., Li, Z. H., Xu, B., . . . Lei, L. (17 de Septiembre de 2019). Estimation of maize above-ground biomass based on stem-leaf separation strategy integrated with LiDAR and optical remote sensing data. *PeerJ*, 7-30. doi:10.7717/peerj.7593



8 ANEXO A: CARACTERÍSTICAS DEL DRONE DJI MAVIC 3

Característica	Métrica
AERONAVE	
Peso neto (con hélices y módulo RTK)	951 [g]
Dimensiones (plegada/desplegada)	Plegada (sin hélices): 223 × 96.3 × 122.2 mm (largo × ancho × alto) Desplegada (sin hélices): 347.5 × 283 × 139.6 mm (largo × ancho × alto)
Tiempo máx. de vuelo (sin viento)	43 [minutos]
GNSS	GPS + Galileo + BeiDou + GLONASS (GLONASS solo es compatible cuando el módulo RTK está activado)
CÁMARA RGB	
Sensor de imagen	CMOS 4/3. Píxeles efectivos: 20 MP
Objetivo	Campo de visión: 84° Distancia focal equivalente: 24 mm Apertura: de f/2.8 a f/11 Enfoque: de 1 m a ∞
Velocidad de obturación	Obturador electrónico: 8-1/8000 s Obturador mecánico: 8-1/2000 s
Tamaño máx. de imagen	5280×3956
Sistema de archivo compatible	exFAT

Anexo A: Características del Drone DJI Mavic 3

Formato de imagen	JPEG/DNG (RAW)
Característica	Métrica
CÁMARA MULTIESPECTRAL	
Sensor de imagen	CMOS de 1/2.8 pulgadas; píxeles efectivos: 5 MP
Objetivo	Campo de visión: 73.91° (61.2° x 48.10°) Distancia focal equivalente: 25 mm Apertura: f/2.0 Enfoque: Enfoque fijo
Banda de cámara multiespectral	Verde (G): 560 ± 16 nm; Rojo (R): 650 ± 16 nm; Borde rojo (RE): 730 ± 16 nm; Infrarrojo cercano (NIR): 860 ± 26 nm
Tamaño máx. de imagen	2592×1944
Formato de imagen	TIFF



9 ANEXO B: ARCHIVOS GENERADOS

Se presenta el siguiente código QR de la liga al repositorio en GitHub, donde se encuentran almacenados todos los archivos generados, tanto en Python como las bases de datos, entrenamiento y prueba en extensión csv, que contienen los datos utilizados para este experimento.



Figura 29 Código QR a la liga al repositorio de GitHub con los archivos y programas utilizados en el trabajo de investigación