

Estimación del índice de crecimiento de la lechuga mediante el aprendizaje profundo.

Estimation of Lettuce Growth Index Using Deep Learning.

Naomi Azucena Rivera Zenteno (1).
Estudiante Tecnológico Nacional de México/Instituto Tecnológico de Tuxtla Gutiérrez.
l20270787@tuxtla.tecnm.mx.

Carlos César Zebadúa Martínez* (2). Tecnológico Nacional de México/Instituto Tecnológico de Tuxtla Gutiérrez,
l20270787@tuxtla.tecnm.mx.

Néstor Antonio Morales Navarro (3). Tecnológico Nacional de México/Instituto Tecnológico de Tuxtla Gutiérrez,
nestor.mn@tuxtla.tecnm.mx.

Madaín Pérez Patricio (4). Tecnológico Nacional de México/Instituto Tecnológico de Tuxtla Gutiérrez,
madain.pp@tuxtla.tecnm.mx.

Aída Guillermina Cossío Martínez (5). Tecnológico Nacional de México/Instituto Tecnológico de Tuxtla Gutiérrez,
aida.cm@tuxtla.tecnm.mx.

Galdino Belisario Nango Solís (6), Tecnológico Nacional de México/Instituto Tecnológico de Tuxtla Gutiérrez,
galdino.ns@tuxtla.tecnm.mx.

*corresponding author.

Artículo recibido en diciembre 18, 2024; aceptado en enero 10, 2025.

Resumen.

Este proyecto aborda la problemática del crecimiento de cultivos de lechuga en el contexto del cambio climático y la sobrepoblación, que han incrementado la demanda de este alimento y afectado su producción. Se propone el uso del aprendizaje profundo (Deep Learning), Roboflow y las imágenes RGB-D para mejorar el monitoreo del crecimiento de la lechuga hidropónica, optimizando los recursos utilizados en su cultivo. El objetivo principal del proyecto es desarrollar una metodología que permita estimar el peso fresco de la lechuga utilizando imágenes y técnicas de aprendizaje profundo. Para ello, se implementó un sistema de visión por computadora que emplea imágenes RGB-D, que combinan información de color y profundidad, para analizar las características físicas de la lechuga, como altura, diámetro y volumen, lo cual permite predecir su peso. Este trabajo representa una solución moderna para mejorar la eficiencia en la producción agrícola de lechuga hidropónica al aplicar el aprendizaje profundo.

Palabras clave: Aprendizaje profundo, imágenes RGB-D, peso, Roboflow.

Abstract.

This project addresses the issue of lettuce crop growth in the context of climate change and overpopulation, which have increased the demand for this food and affected its production. The proposed solution involves the use of Deep Learning, Roboflow, and RGB-D images to improve the monitoring of hydroponic lettuce growth, optimizing the resources used in its cultivation. The main objective of the project is to develop a methodology to estimate the fresh weight of lettuce using images and deep learning techniques. To achieve this, a computer vision system was implemented that employs RGB-D images, combining color and depth information, to analyze the physical characteristics of lettuce, such as height, diameter, and volume, enabling weight prediction. This work represents a modern solution to improve efficiency in hydroponic lettuce production through the application of deep learning.

Keywords: Deep learning, fresh weight, RGB-D images, Roboflow.

1. Introducción.

La agricultura se enfrenta constantemente al desafío de optimizar procesos para garantizar una producción de alimentos eficiente y sostenible como lo plantea la FAO (2021), en la actualidad, la producción alimentaria y agrícola de todo el mundo se enfrenta a muchos desafíos a causa de la creciente demanda de alimentos por la sobrepoblación, el aumento de hambre, el cambio climático, la sobreexplotación de los recursos naturales, entre otros, en consecuencia la innovación en el sector agrícola como la inteligencia artificial (IA) y el aprendizaje profundo se han vuelto crucial para la mejora de la eficiencia y seguridad alimentaria.

La lechuga es considerada un alimento básico en muchas dietas alrededor del mundo. Para su cultivo en la agricultura tradicional, se requiere el monitoreo e inspección manual de manera constante que, por lo general, es una actividad que se realiza por usos y costumbres, además de realizar anotaciones en una bitácora, en algunos casos. Este control, implica mayor tiempo para el agricultor, impidiéndole realizar otras actividades, y a la vez puede haber anotaciones erróneas dentro de la bitácora, el cual como lo menciona Quetz Aguirre et al (2023), el uso de estas bitácoras digitales o monitoreos automatizados permiten una reducción en el tiempo invertido de los agricultores y una mayor precisión en la detección de enfermedades o plagas en los cultivos.

En la actualidad surge un gran interés en la aplicación de tecnologías innovadoras para gestionar el crecimiento de las plantas. La mayoría de estas tecnologías emergen del aprendizaje profundo, una rama de la inteligencia artificial que se basa en las redes neuronales para realizar un análisis detallado de datos complejos Yu et al. (2024) destacan como la inteligencia artificial (IA) como el aprendizaje profundo están impulsando la innovación en este campo, permitiendo procesar grandes volúmenes de datos en la optimización de crecimiento y calidad de los cultivos. Osorio (2021) afirma que el aprendizaje profundo tiene aplicaciones variadas, desde el reconocimiento de voz hasta la conducción autónoma, y destaca su relevancia en el ámbito agrícola, específicamente en el cultivo de la lechuga. Se señala que, mediante el uso de imágenes de las hojas de lechuga en diversas etapas de desarrollo se pueden extraer información sobre el crecimiento y salud de la planta.

La agricultura en México ha registrado un crecimiento significativo en los últimos años. En 2022, la extensión de tierras dedicadas a la agricultura alcanzó los 32.1 millones de hectáreas, lo que representa un aumento del 2.2% en comparación con 2017. Asimismo, la producción total experimentó un incremento, llegando a 296.7 millones de toneladas, lo que equivale a un aumento del 4.8% en el mismo periodo. Los principales cultivos incluyen maíz, sorgo, frijol, caña de azúcar y trigo, con el maíz destacando por un aumento del 3.9% en su producción en 2022. Las unidades de producción han crecido un 6,7% desde 2017, alcanzando los 5,0 millones en 2022. El acceso al crédito también ha mejorado notablemente, aumentando un 54% en el mismo periodo, alcanzando el 6,1% de las unidades de producción, según datos del INEGI (2022).

En este proyecto, se propone implementar un algoritmo de inteligencia artificial para ayudar a los agricultores a tener un sistema con el cual se podrán obtener a fondo las características cuantitativas de la lechuga como: área foliar, altura, diámetro, peso, etc. Lo anterior, requiere que el algoritmo sea entrenado con un conjunto de datos lo suficientemente

grande, para minimizar los errores en la detección de características. Por medio imágenes se pueden extraer dichas características.

2. Métodos.

Se utilizará un sistema basado en visión por computadora y tecnología de procesamiento de imágenes para analizar imágenes RGB-D de la lechuga para obtener datos como el peso, altura, diámetro. La metodología propuesta de este sistema es la siguiente:

Colección de imágenes.

Se recopilarán imágenes RGB-D de lechugas por medio de un dispositivo que combinará una cámara RGB tradicional con un sensor de profundidad para obtener información tridimensional de la escena. Dichas imágenes deberán ser tomadas en un ambiente bien iluminado asegurando de que haya suficiente contraste entre la lechuga y el fondo para facilitar los procesos de detección y segmentación.

Etiquetado y segmentación.

Se utilizará un algoritmo de segmentación para separar la lechuga del fondo y otras partes de la imagen, además de utilizar tecnología de detección de bordes y contornos para medir el diámetro y la altura de la lechuga. Para esto se llevará a cabo un proceso de etiquetado con la herramienta *Roboflow*.

Preprocesamiento de imágenes.

Se realizará la redimensión de las imágenes obtenidas durante la segmentación, además de la corrección de color y la calibración de la cámara para garantizar una representación precisa del color de la lechuga. Utilizando técnicas de filtrado y reducción de ruido para mejorar la calidad de la imagen y reducir posibles interferencias.

Modelado 3D.

Con las imágenes preparadas se implementará con Python un algoritmo capaz de unir los datos de la lechuga en RGB que representaría las dimensiones 2D del modelo con los datos de la imagen de profundidad, el cual va a representar la altura del modelo, mediante esta combinación se creará el modelo 3D de la lechuga y, con una serie de parámetros específicos, se hará que el mismo algoritmo también sea capaz de obtener el volumen, área, altura y el diámetro correspondiente de la lechuga.

Análisis de Datos.

Se utilizará un algoritmo DNN de procesamiento de datos para calcular el peso de la lechuga en función de sus dimensiones, gracias a la serie de datos obtenidos en el modelo 3D.

Una red neuronal profunda (DNN, por sus siglas en inglés) es una técnica de inteligencia artificial diseñada para procesar información a través de nodos interconectados organizados en diferentes capas. Su objetivo principal es identificar patrones y llevar a cabo tareas específicas mediante el aprendizaje automático. Estas redes buscan emular el proceso de aprendizaje del cerebro humano, utilizando algoritmos y programas informáticos que les permiten adaptarse y mejorar su desempeño con base en la experiencia (Sánchez et al., 2023).

Está compuesta principalmente por:

Entradas.

Datos iniciales que se ingresarán en la red, obtenidos a partir de las mediciones del modelo 3D.

Capas ocultas.

Capas intermedias que permiten extraer características de los datos ingresados.

Salidas.

La capa de salida es el resultado final de todo el proceso de aprendizaje por las capas ocultas.

Función de activación.

Las funciones de activación desempeñan un papel crucial en las redes neuronales artificiales, ya que aportan no linealidad al modelo, lo que facilita que la red pueda captar y expresar relaciones complejas en los datos (Lederer, 2021).

Para un mejor entendimiento, se presenta la figura 1, donde se representa la metodología propuesta de manera grafica.

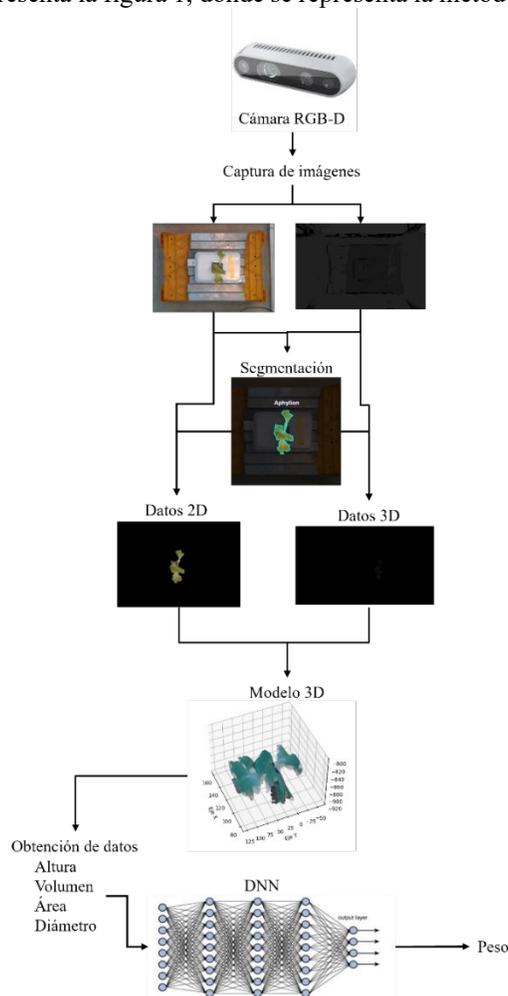


Figura 1. Diagrama de la metodología a usar.

3. Desarrollo.

Como ya se mencionó anteriormente, el desarrollo de este proyecto se estructura en cinco etapas principales: colección de imágenes, etiquetado y segmentación, preprocesamiento de imágenes, modelado 3D y análisis de los datos.

Captura de imágenes.

Para el desarrollo de este proyecto se contó con un conjunto de datos producido por Hemming et al para la sesión de desafío en línea del Tercer Desafío Autónomo de Invernaderos (Third Autonomous Greenhouse Challenge); dicho conjunto de datos consta de 388 imágenes RGB, imágenes de profundidad y datos reales sobre sus medidas correspondientes, y se encuentra disponible en el sitio web 4TU.ResearchData. Dentro del conjunto de datos se especifica que las imágenes se tomaron con una cámara RealSense D415 y que tanto las imágenes RGB como las imágenes de profundidad cuentan con la misma resolución (1080 x 1920 píxeles) y extensión (PNG), sin embargo, las imágenes RGB son de 24 bits mientras que las de profundidad son de 16 bits.

Etiquetado y segmentación.

Teniendo nuestro conjunto de datos, las imágenes son organizadas según las variedades: Salanova, Lugano, Satine y Aphyllion; una vez hecho esto las imágenes se etiquetarán en Roboflow, este proceso es fundamental para que el algoritmo de Deep Learnin detecte de manera automática a las lechugas y debe ser lo más preciso posible. Lo que Roboflow hará será generar automáticamente tres conjuntos de imágenes para el entrenamiento, la validación y las pruebas del algoritmo de YOLOv7, el cual es un detector de objetos de última generación en tiempo real. Con esto se procede a entrenar el modelo que permitirá identificar lechugas según su variedad; lo que resulta en la generación de imágenes npy las cuales son necesarias para filtrar los fondos, ya que ahora las imágenes se encuentran en blanco (valor 1) y negro (valor 0), blanco para la lechuga y negro para el fondo.

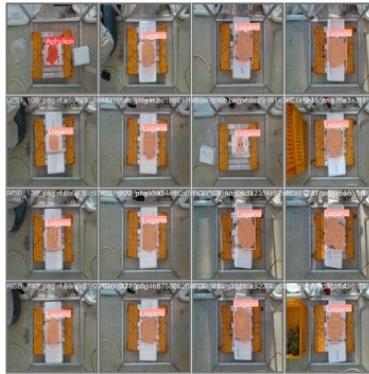


Figura 2. Etiquetado de las imágenes de la lechuga.

Preprocesamiento de imágenes.

Dado que las imágenes están trabajadas en Roboflow se redimensionan automáticamente a 640 x 640 píxeles, deberán ser devueltas a su dimensión original para que todos los píxeles de la imagen npy coincidan con las imágenes originales RGB y con las imágenes de profundidad. De esta manera podrán ser combinadas para dar origen al modelo 3D.

Con dicho proceso, se obtiene como resultado la imagen de la lechuga en blanco y negro ya redimensionada (Figura 3).



Figura 3. Imagen de la lechuga .npy redimensionada.

Teniendo las mismas redimensiones se multiplica la imagen npy con la imagen RGB para que así el fondo, cuyo valor es 0, se multiplique con los mismos pixeles de la imagen RGB convirtiéndolos también en negro mientras que los pixeles de la parte de la lechuga permanecerán tal como están en la imagen original, conservando el color que originalmente se tenía como observa en la (Figura 4).

De igual manera la imagen npy se va a combinar con la imagen de profundidad para que así se cuente con la imagen RGB y de profundidad sin fondo, con el fin de al momento de graficarlo solo se grafique la lechuga y no el fondo.

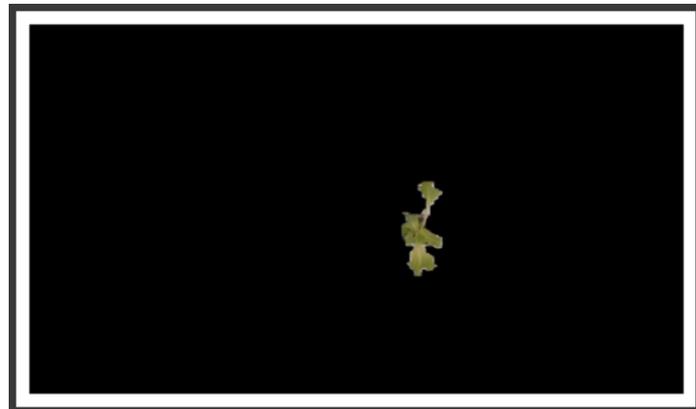


Figura 4. Imagen RGB segmentada.

Modelado 3D.

Teniendo las imágenes RGB y de profundidad sin fondo, se creó un algoritmo capaz de combinarlas, A partir de estas imágenes, se obtuvieron las medidas de largo y ancho de la imagen RGB, mientras que la altura se obtuvo a partir de la imagen de profundidad. En esta última, los valores varían según la distancia, donde las partes más cercanas de la lechuga presentan valores diferentes a las más lejanas, permitiendo así determinar su altura.

Primero en la creación del código se cargan las imágenes mediante la librería cv2 previamente instalada, después se declaran en variables todos los parámetros que por defecto tiene la cámara, como los datos para la matriz de calibración, el vector de traslación y rotación. Los cuales, son datos de suma importancia para obtener las medidas más precisos de la lechuga.

En el algoritmo 1 considerando la imagen de profundidad y los parámetros de la cámara se crea la nube de puntos que permitirá crear la graficar de la lechuga.

Algoritmo 1. Creación de la nube de puntos y aplicando los vectores de rotación y traslación.

```

h, w = imagen_profundidad.shape
u, v = np.meshgrid(np.arange(w), np.arange(h))
x = (u - cx) * imagen_profundidad / fx
y = (v - cy) * imagen_profundidad / fy
z = imagen_profundidad

# Aplicar rotación y traslación
points = np.array([x.flatten(), y.flatten(), z.flatten()]).T
rotated_points = (R @ points.T).T + T

```

En el algoritmo 2 se muestra el código donde se grafica la nube de puntos de acuerdo con la imagen Yolo, que es la imagen RGB sin fondo, el cual contiene los valores de 1s y 0s donde los valores 1s es donde se encuentra la lechuga y los 0s el fondo, como resultado solo graficara los puntos de la nube que corresponden a la lechuga, el cual se encuentra representada en la figura 5.

Algoritmo 2. Graficación del modelo 3d de la lechuga.

```

[m,n] = rotated_points.shape
#p3d1 = np.zeros([207360,3])
vector = np.array(imagen_yolo.flatten())
p3d = []
c = []
d=imagen_rgb.reshape(-1, 3)
contador = 0
for i in range (0,m,1):
    #print(i)
    if vector[i] >= 1 and rotated_points[i, 2] > 100 and rotated_points[i, 2] <= 915:
        p3d.append(rotated_points[i])
        contador += 1
        c.append(d[i] / 255)
p3d = np.array(p3d)
c = np.array(c)

fig = plt.figure()
ax = fig.add_subplot(111, projection='3d')

ax.scatter(p3d[:, 0], p3d[:, 1], -p3d[:, 2], c=c_original)

plt.xlabel('Eje X')
plt.ylabel('Eje Y')
ax.view_init(elev=0, azim=90)
plt.show()

```

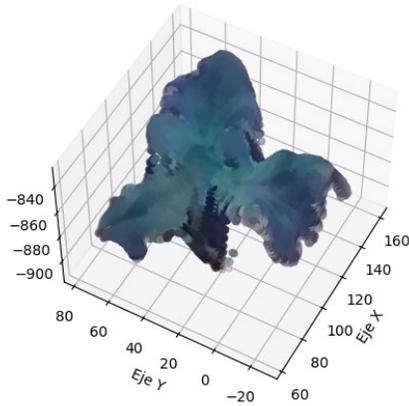


Figura 5. Modelo 3d de la lechuga.

Análisis de datos.

Teniendo listo el modelo 3d de la lechuga ahora se procede a calcular todos los datos de la lechuga, esto lo logramos con distintos métodos para cada medida, por ejemplo, para calcular la altura se hace por medio del algoritmo 3. EL cual calcula el punto máximo de la lechuga y lo resta por el punto más bajo esto se realiza así, para que solo nos quede el rango de valores donde está la lechuga, posteriormente se multiplica por la escala que tiene por defecto la cámara para que nos dé el resultado más cercano a la realidad.

Algoritmo 3. Código del cálculo de la altura de la lechuga.

```
altura = (np.max(z_values) - np.min(z_values)) * depth_scale
altura_cm = altura * 100
```

Para calcular el volumen y área de la lechuga se usó el Algoritmo 4. El cual calcula las medidas gracias a la biblioteca de convexHull, que crea una malla alrededor de la nube de puntos de la lechuga y teniendo los atributos de .volume y .area se calcula automáticamente de acuerdo con dicha malla, el cual por último se multiplica por la escala de la cámara con sus respectivas conversiones.

Algoritmo 4. Cálculo del volumen y área de la lechuga.

```
hull = ConvexHull(p3d)

volumen = hull.volume * (depth_scale ** 3)
area_superficie = hull.area * (depth_scale ** 2)

volumen_cm3 = volumen * 1e6 # cm³
area_cm2 = area_superficie * 1e4 # cm²
```

En el algoritmo 5 se muestra el cálculo del diámetro, el cual calcula la distancia máxima que hay entre la nube de puntos a partir de los datos de profundidad.

Algoritmo 5. Cálculo del diámetro de la lechuga.

```

distances = pdist(p3d)

diametro = np.max(distances) * depth_scale
diametro_cm = diametro * 100 # cm

```

Predicción de peso usando una DNN.

Teniendo todos los datos registrados, se crea una DNN con el algoritmo 6, el cual primero se importan las librerías necesarias para su creación. Después se cargan los datos obtenidos en el modelo 3d, los cuales se incorporaron en una hoja de Excel imagen por imagen, también se indican los nombres de las columnas en su respectiva distribución, se identifican los datos de entrada y de salida en las variables X y Y, donde los datos de entrada son los datos obtenidos anteriormente (diámetro, área, volumen y altura), y los datos de salida es el peso real de la lechuga, de esta manera, la DNN se entrenará relacionando los parámetros de entrada con el peso de la lechuga, por este medio se tendrá un modelo que prediga el peso de una lechuga basada en su diámetro, área, volumen y altura. Con los datos identificados, se crea la DNN el cual va a ser un modelo secuencial, ya que para lo que se necesita es la más adecuada, para la capa de entrada se crean las mismas dimensiones que tiene X_train el cual tiene las columnas de entrada, nuestra red neuronal cuenta con 4 capas ocultas ya que, si se ponen menos o más afecta el porcentaje de acierto del modelo, ya sea por un sobreajuste o por un mal ajuste, para la capa de salida solo pondrá un nodo haciendo referencia al peso.

Creado el modelo de la red neuronal, se le pasan todos los datos de entrenamiento para que aprenda a predecir el peso bajo estos parámetros, para la predicción, se crea una variable llamada y_pred el cual va guardar todos los predichos, los cuales se calculan con el atributo .predict e indicándole los datos de entrada de prueba, para que se pueda conocer el porcentaje de acierto de modelo se crea la variable r2 el cual compara los datos de peso reales con los predichos por el modelo.

Algoritmo 6. Creación de la DNN.

```

# librerías
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from sklearn.metrics import mean_absolute_error, r2_score
import matplotlib.pyplot as plt

data = pd.read_excel('Datos/DatosRedneuronal.xlsx', header=None)
data.columns = ['Diametro', 'area', 'volumen', 'altura', 'Peso']

X = data.iloc[:, 0:4] # Primeras 4 columnas (Diametro, Area, Volumen, Altura)
y = data.iloc[:, 4] # Última columna (Peso)

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# DNN

```

```

modelo_dnn = Sequential()
modelo_dnn.add(Dense(128, activation='relu', input_shape=(X_train.shape[1],)))
modelo_dnn.add(Dense(64, activation='relu'))
modelo_dnn.add(Dense(32, activation='relu'))
modelo_dnn.add(Dense(32, activation='relu'))
modelo_dnn.add(Dense(16, activation='relu'))
modelo_dnn.add(Dense(1))
modelo_dnn.compile(optimizer='adam', loss='mean_squared_error')

historial = modelo_dnn.fit(X_train, y_train, epochs=500, batch_size=10, verbose=1,
validation_data=(X_test, y_test))

y_pred = modelo_dnn.predict(X_test)

mae = mean_absolute_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

print(f"Error Medio Absoluto (MAE): {mae}")
print(f"Coeficiente de Determinación (R2): {r2}")

porcentaje_acierto = r2 * 100
print(f"\nPorcentaje de acierto del modelo: {porcentaje_acierto:.2f}%")

```

El resultado de la predicción del modelo fue un 85.73% de acierto en el peso predicho el cual fue el resultado de 500 ciclos de 355 imágenes de entrenamiento con el proceso de pérdidas durante el entrenamiento representadas en la figura 6, las cuales podemos entender como la diferencia entre el peso real con el peso predicho que hay en el resultado de cada ciclo, por lo cual se puede distinguir que en cada ciclo o época la pérdida es menor. Este resultado es muy favorable por el motivo de que es un porcentaje alto.

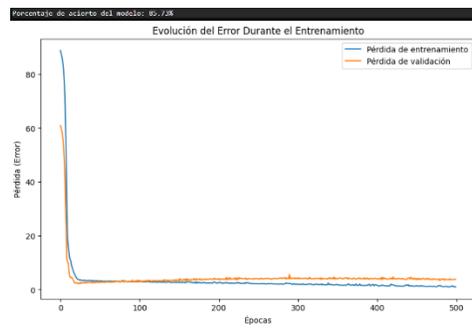


Figura 6. Gráfica de la pérdida durante el entrenamiento.

Conclusión.

En este trabajo se puede observar que utilizando técnicas de aprendizaje profundo se logra predecir el peso de la lechuga mediante haciendo uso del análisis de imágenes RGB-D. Esta predicción se logra con un porcentaje aceptable del 85.73%, con dicho resultado queda claro que con estas innovaciones en el sector agrícola puede llevar a un proceso muy eficiente de monitoreo automático en grandes cultivos utilizando únicamente una cámara especializada y una DNN bien configurada.

Créditos.

Los autores agradecen al Instituto Tecnológico de Tuxtla Gutiérrez y al asesor Néstor Antonio Morales Navarro por el apoyo brindado durante el desarrollo del proyecto.

Referencias bibliográficas.

- Instituto Nacional de Estadística y Geografía (INEGI). (2023).** Resultados Definitivos del Censo Agropecuario 2022. https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2023/CA_Def/CA_Def2022.pdf.
- Lederer, J. (2021, 25 enero).** Activation Functions in Artificial Neural Networks: A Systematic Overview. arXiv.org. <https://arxiv.org/abs/2101.09957>.
- Osorio Delgado, A. K. (2021).** Método para la estimación de maleza en cultivos de lechuga utilizando aprendizaje profundo e imágenes multiespectrales (Doctoral dissertation, Universidad Nacional de Colombia).
- Quetz Aguirre, G. M., Méndez Moreno, M., Can Cabrera, Á. F., Chuc Armendáriz, M. B.-H., & González Rodríguez, F. de J. (2023).** Tecnologías para la trazabilidad productiva en el sureste mexicano: caso de prueba de bitácora digital sobre lactuca *sativa*. *Multidisciplinas de la Ingeniería*, 11(18), 40–48. <https://doi.org/10.29105/mdi.v11i18.279>.
- Sánchez, W. A. C., Escobar, B. R. P., & Huincho, F. V. (2023).** Artificial neural networks: a measurement of forecast learnings as potential demand. *Universidad Ciencia y Tecnología*, 27(118), 51-60. <https://doi.org/10.47460/uct.v27i118.686>.
- The State of Food Security and Nutrition in the World 2021. (2021).** En FAO, IFAD, UNICEF, WFP and WHO eBooks. <https://doi.org/10.4060/cb4474en>.
- Yu, J., M. Welch, S., L. Negus, K., & Li, X. (2024).** The role of artificial intelligence in crop improvement. *ScienceDirect*, 184, ISSN 0065-2113. <https://www.sciencedirect.com/science/article/pii/S0065211323001141?via>.

Información de los autores.



Naomi Azucena Rivera Zenteno, Ingeniera en sistemas computacionales del Instituto Tecnológico de Tuxtla Gutiérrez. Cuenta con experiencia con la herramienta de Android Studio y con los lenguajes de Java y Python. Interesada en el desarrollo de aplicaciones móviles y desarrollo de algoritmos de Inteligencia Artificial.



Carlos César Zebadúa Martínez, Ingeniero en sistemas computacionales del Instituto Tecnológico de Tuxtla Gutiérrez. Trabaja con los lenguajes de programación de Python, Java, HTML y CSS. Interesado en el desarrollo de videojuegos. Con experiencia en diseño gráfico con Photoshop y desarrollo de algoritmos de Inteligencia Artificial.



Néstor Antonio Morales Navarro, Doctor en Desarrollo Tecnológico. Docente del departamento de la carrera de Ingeniería en Sistemas Computacionales y jefe del departamento del Centro de Cómputo del Tecnológico Nacional de México campus Tuxtla Gutiérrez. Miembro del Sistema Nacional de Investigadores, nivel Candidato. Se especializa en el área de Visión e Inteligencia Artificial.



Madain Pérez Patricio es graduado como Doctor en Ciencias en Automatización y Computación Industrial en 2005, por la Universidad de Ciencias y Tecnologías de Lille, Francia. Investigador y Docente desde 1997 en el Departamento de Posgrado y la Carrera en Sistemas Computacionales del Instituto Tecnológico de Tuxtla Gutiérrez. Es miembro del Claustro Doctoral "Doctorado en Ciencias de la Ingeniería" perteneciente al Programa Nacional de Posgrados de Calidad, I.T. de Tuxtla Gutiérrez desde 2016. Miembro del Sistema Nacional de Investigadores, nivel II.



Aída Guillermina Cossío Martínez es Maestra en Ciencias en Administración por el Instituto Tecnológico de Tuxtla Gutiérrez en 2002. Es profesora de tiempo completo del área de Ingeniería en Sistemas Computacionales del Instituto Tecnológico de Tuxtla Gutiérrez, desde 1994. Se especializa en la formulación y evaluación de proyectos, así como el emprendimiento y desarrollo de planes de negocio, actualmente es perfil deseable y trabaja en la línea de investigación Tecnología de Información y Base de Datos.



Galdino Belizario Nango Solís es Ingeniero en Sistemas Computacionales por el Instituto Tecnológico de Tuxtla Gutiérrez, Chiapas, en 1996. Es Maestro en Ciencias de la Computación por el Centro de Investigación en Computación del Instituto Politécnico Nacional, en 2001. Es Doctor en Desarrollo Tecnológico por la Universidad de Ciencia y Tecnología Descartes, en 2016. Es profesor en el área de Ingeniería en Sistemas Computacionales del Instituto Tecnológico de Tuxtla Gutiérrez, donde imparte clases en las materias de Programación Lógica y Funcional; y Lenguajes y Autómatas. Es profesor con perfil deseable PRODEP y miembro del Cuerpo Académico Tecnologías de la Información para el Desarrollo de Ventajas Competitivas en la LGAC Sistemas de Información desde 2022.