

Detección del nivel de estrés hídrico en plantas de lechuga romana a través de CNN Detection of water stress level in romaine lettuce plants through CNN

J. G. Bermúdez-Rojas ^a, J. E. Luna-Taylor ^{a,*}, F. D. Von Borstel ^b, J. Sandoval ^a

^aDivisión de Estudios de Posgrado e Investigación, Tecnológico Nacional de México/I. T. de La Paz, 23080, La Paz, B. C. S., México.

^bPrograma de Agricultura de Zonas Áridas, Centro de Investigaciones Biológicas del Noroeste, S.C., 23096, La Paz, B. C. S., México.

Resumen

La agricultura en México enfrenta importantes desafíos en el manejo eficiente del agua. Una potencial solución para abordar estos desafíos es la implementación de técnicas agrícolas modernas que permitan métodos de agricultura de precisión en invernaderos que puedan producir durante todas las estaciones del año y con un uso más eficiente del agua. Para ello son necesarios sistemas inteligentes que permitan monitorear y controlar los recursos para el crecimiento de las plantas de acuerdo a las condiciones que presenten. Este artículo describe el diseño y entrenamiento de una red neuronal convolucional (CNN) para detectar el grado de deshidratación de plantas de lechuga romana a través de imágenes, esto con el fin de administrar adecuadamente el agua para riego y no desperdiciarla. Los experimentos muestran una precisión y sensibilidad del modelo del 83 % en la identificación del nivel de deshidratación y del 98,8 % en ambas métricas, considerando una tolerancia de más/menos un nivel de diferencia con respecto al real.

Palabras Clave: Redes Neuronales Convolucionales, Reconocimiento y Clasificación de Imágenes, Agricultura de Precisión.

Abstract

Agriculture in Mexico faces important challenges in the efficient management of water. A potential solution to address these challenges is the implementation of modern agricultural techniques that allow precision farming methods in greenhouses that can produce during all seasons of the year and with a more efficient use of water. For this, intelligent systems are necessary to monitor and control the resources for plant growth according to the conditions they present. This article describes the design and training of a convolutional neural network (CNN) to detect the degree of dehydration of romaine lettuce plants through images, in order to properly manage water for irrigation and not waste it. The experiments show a precision and sensitivity of the model of 83 % in the identification of the level of dehydration and 98.8 % in both metrics, considering a tolerance of plus/minus one level of difference with respect to the real one.

Keywords: Convolutional Neural Networks, Image Recognition and Classification, Precision Farming.

1. Introducción

La tecnificación de la agricultura ha evolucionado de manera acelerada en las últimas dos décadas. Nuevas tecnologías emergentes en la automatización, la robótica y la inteligencia artificial, se han combinado para optimizar la producción agrícola. En la actualidad, vehículos autónomos terrestres y aéreos dirigidos a través del sistema de posicionamiento global (GPS) se ofrecen de manera comercial y experimental, para realizar tareas de fumigación, fertilización, monitoreo, deshierbe y cosecha de cultivos (FAO e ITO, 2018), (Fernandes *et al.*, 2020), (Gonzalez-de Santos *et al.*, 2020), (OECD, 2021), (Mammare-

lla *et al.*, 2021). Asimismo, diversos sistemas inteligentes y sensores que permiten la administración estratégica de los recursos aplicados en las cosechas agrícolas, se han propuesto para realizar una agricultura de precisión (Bechtis *et al.*, 2017), (Naji, 2020), (FAO e ITO, 2021). La agricultura de precisión tiene como objetivo optimizar la producción, haciéndola sostenible y rentable mediante el control de las entradas a los procesos agrícolas (Idris y Sani, 2012).

Uno de los principales recursos de entrada para las actividades agrícolas, es el agua para riego. En México, la agricultura utiliza el 76 % del agua consumida (Ochoa-Noriega *et al.*,

* Autor para correspondencia: jorge.lt@lapaz.tecnm.mx (Jorge Enrique Luna Taylor)

Correo electrónico: m22310001@lapaz.tecnm.mx (Jesús Guillermo Bermúdez Rojas), jorge.lt@lapaz.tecnm.mx (Jorge Enrique Luna Taylor), fborstel@cibnor.mx (Fernando D. Von Borstel), jesus.sg@lapaz.tecnm.mx (Jesús Alberto Sandoval Galarza).

2020). Asimismo, se considera que existen aproximadamente 6.5 millones de hectáreas de uso agrícola donde se utiliza el riego (Conagua, 2022). La productividad de las superficies bajo riego es entre 2 y 3 veces mayor que las aproximadamente 15.5 millones de hectáreas donde se realizan actividades de agricultura de temporal en México; sin embargo, en la agricultura de riego, persisten pérdidas de agua del orden del 50 %, dado que se utilizan volúmenes excesivos de agua y existen problemas para la operación y mantenimiento de la infraestructura de riego (Conagua, 2020). De manera general, el sobreuso de los recursos hídricos de México es de 19.5 %, lo que es un porcentaje bajo, no obstante, el norte, el centro y el noreste, casi dos tercios de su territorio, son zonas áridas a semiáridas, por lo que en esas regiones existe un alto nivel de sobreuso de entre 40 % a 100 % (Ochoa-Noriega *et al.*, 2020). En este contexto, la agricultura en México está lidiando con desafíos importantes en el rubro del agua, para continuar con una producción agrícola que permita alimentar una población creciente, la cual tuvo un incremento de 14 millones de habitantes en el periodo de 2010 al 2020 (Inegi, 2020).

Mediante la adopción de técnicas agrícolas modernas se busca prevenir la pérdida de cultivos por sequías, cambios climáticos repentinos, enfermedades y pestes, entre otras causas. Estas técnicas permiten implementar métodos de agricultura de precisión en invernaderos y granjas agrícolas, las cuales pueden mantener continua su producción durante todas las temporadas del año. En estos términos, la aeroponía es una técnica moderna que permite cultivar plantas sin suelo o sustrato, donde las raíces de las plantas están en el aire y estas son asperjadas a intervalos predefinidos con una solución nutritiva. Esta técnica ha probado sus beneficios para prevenir enfermedades e infecciones, además de conseguir una mayor productividad con un uso más eficiente de los recursos naturales de entrada a los procesos agrícolas, como es la reducción en el consumo de agua en hasta un 98 % (NASA, 2006). Incluso, se han propuesto sistemas aeropónicos que ajustan y controlan de manera precisa los recursos necesarios para que las plantas crezcan, tales como la dosificación del riego y nutrientes, temperatura, luz, CO₂, humedad, flujo de aire, entre otros (Lakhari *et al.*, 2018).

A pesar de todos los beneficios mencionados, la aeroponía presenta desventajas y problemas, por lo que sigue aún en desarrollo. Por ejemplo, al ser un cultivo sin suelo, en caso de una falla eléctrica del sistema o de las bombas o la ocurrencia de obstrucciones en los aspersores para irrigación, cuando el operador no está presente; al no existir un sustrato que permita mantener el agua y los nutrientes en las raíces, se pueden producir daños severos o la muerte de las plantas (Montoya *et al.*, 2017). Lo cual hace necesario que los sistemas automatizados que controlan los recursos para el crecimiento de las plantas, sean lo suficientemente inteligentes para realizar un monitoreo en tiempo real y presentar diagnósticos que permitan al operador detectar fallas y prevenir daños a los cultivos.

Dado lo anterior, en este artículo se describe la implementación de un modelo de red neuronal convolucional (CNN, por sus siglas en inglés), para detectar determinados periodos de deshidratación en las plantas a través de imágenes tomadas en tiempo real. El objetivo final del modelo, es implementar un sistema inteligente para diagnosticar la falta de irrigación, debido a fallas en el sistema a través de un monitoreo directo de las

plantas. Esto le permitirá al operador conocer el nivel de deshidratación de las plantas y tomar las medidas necesarias para salvaguardar el cultivo aeropónico.

Considerando lo anterior, se propuso diseñar una nueva estructura de CNN ligera, en lugar de aplicar una CNN del estado del arte, dado que el objetivo a futuro es implementar el modelo sobre un dispositivo de bajo costo y rendimiento. Se observó que esto es factible generando un modelo de red específico para un tipo de planta, manteniendo así una arquitectura que requiere poco espacio de almacenamiento y que se procesa de manera más eficiente. Esto, finalmente, permite trabajar en tiempo real con dispositivos más económicos y reducir el consumo energético.

La primera sección de este documento presenta una introducción a la tecnificación y problemas actuales en la agricultura tradicional con el recurso del agua. En la segunda sección se presentan los trabajos de investigación relacionados. En la tercera sección se describe la propuesta del modelo con redes neuronales convolucionales. La cuarta sección presenta la implementación del modelo y los resultados experimentales obtenidos. En la quinta sección se presentan las conclusiones del trabajo de investigación.

2. Trabajos Relacionados

Múltiples trabajos de investigación basados en sistemas computacionales, que utilizan imágenes como entrada, se han propuesto para realizar la detección temprana de problemas en los cultivos agrícolas y así llevar a cabo acciones correctivas, reduciendo las pérdidas económicas. Las enfermedades y pestes en los cultivos, pueden producir graves daños que resultan en grandes pérdidas para la productividad agrícola, esto ha provocado que exista una larga lista de trabajos desarrollados enfocados a resolver esa problemática. Por ejemplo, en (Sharif *et al.*, 2018) se aplicó un método híbrido de visión computacional y procesamiento de imágenes para la detección y clasificación de enfermedades en los frutos y hojas de plantas de cítricos. En (Kai *et al.*, 2019) se propuso un sistema de identificación de enfermedades en las hojas de plantas de tomates, mediante la segmentación de imágenes utilizando un algoritmo K-means adaptativo. Asimismo, se han presentado diversas propuestas motivadas por los recientes desarrollos en aprendizaje profundo, que utilizan las CNNs para realizar una clasificación precisa de enfermedades y pestes mediante imágenes. Por ejemplo, en (Baranwal *et al.*, 2019) se propone un modelo de CNN para detectar enfermedades en los árboles de manzana, a través del análisis de imágenes de sus hojas. Con este modelo de red se obtuvo una precisión del 98.54 %. En (Arsenovic *et al.*, 2019) se presentan las limitaciones y deficiencias de los recientes modelos propuestos para la detección de enfermedades en plantas, además de presentar una gran base de datos con imágenes de hojas con diferentes características realizada con métodos tradicionales y de vanguardia, para aumentar el número de imágenes. Un método de entrenamiento de dos fases para una pequeña CNN diseñada para dispositivos móviles, fue propuesto en (Rahman *et al.*, 2020), para realizar la identificación de enfermedades y pestes en plantas de arroz, con una precisión del 93.3 %. Finalmente, una reciente revisión del estado del arte en

cuanto a trabajos de investigación que utilizan técnicas de procesamiento de imágenes y aprendizaje máquina, para la detección automática de enfermedades y plagas en cultivos agrícolas, es descrito en (Ngugi *et al.*, 2020).

Como se puede observar, la mayoría de los trabajos relacionados que utilizan CNNs para la identificación de problemas en las plantas, se han desarrollado enfocados hacia la detección de enfermedades y plagas. Existen otros pocos trabajos relacionados con el estrés de las plantas por la falta de agua. Por ejemplo, en (Concepcion II *et al.*, 2020) se realizó un estudio que integró visión computacional y aprendizaje máquina utilizando una red neuronal recurrente optimizada, para detectar el contenido de humedad y el espesor de agua equivalente, como medidas del estrés por falta de agua en hojas de plantas de lechuga cultivadas en un sistema acuapónico. En (Kamarudin e Ismail, 2022) se propone un modelo ligero adecuado para dispositivos móviles, pudiendo ser aplicado en el campo para detectar las plantas estresadas por la falta de agua debido a la sequía, llegando hasta una precisión de 88.12 % y 88.97 % en imágenes con luz visible y cercano al infrarrojo, respectivamente. Asimismo, en (Aversano *et al.*, 2022) se describe un modelo para la clasificación de plantas de tomate con estrés por agua, utilizando imágenes térmicas y ópticas capturadas por un vehículo aéreo autónomo. Cabe comentar, que estos dos últimos trabajos utilizan imágenes con diferentes espectros de luz, y que son obtenidas de bases de datos reconocidas o que fueron capturadas de manera aérea en campos de cultivo agrícolas tradicionales.

Por otro lado, se han propuesto sistemas automatizados aeropónicos basados en tarjetas de desarrollo embebidas de bajo costo y software libre, como es la plataforma Arduino (Montoya *et al.*, 2017), (Lucero *et al.*, 2020), y la plataforma Raspberry Pi (Mithunesh *et al.*, 2015), (Kerns y Lee, 2017), que al proporcionar acceso a Internet, permiten desarrollar sistemas combinados con dispositivos actuadores y sensores con tecnología basada en Internet de las Cosas (IoT, por su abreviatura en inglés). Sin embargo, ambas plataformas ofrecen recursos limitados de cómputo y memoria. Al ser la plataforma Raspberry Pi un ordenador monoplaca con un sistema operativo basado en GNU/Linux, en conjunto con su cámara para la captura de imágenes, permite la implementación de CNNs ligeras que se pueden aplicar en tareas de clasificación de imágenes en tiempo real.

Este trabajo describe la creación de una base de datos de imágenes de plantas, capturadas con luz visible, y la generación de un modelo de CNN que será aplicado de manera embebida en tarjetas de cómputo de bajo rendimiento y potencia, como es la Raspberry Pi 3 B+, y que será parte de un sistema automatizado con control difuso para cultivos aeropónicos, para detectar la deshidratación de las plantas debido a la falta de riego por fallas en el sistema automatizado de irrigación.

3. Modelo de Red Neuronal Convolutiva

Con el objetivo de medir el nivel de deshidratación de las plantas a través de imágenes, se diseñó y entrenó un modelo de red neuronal basado en una combinación de capas convolucionales, *pooling* y capas densas. Para esto, se tomó como caso de estudio la Lechuga Romana (*Lactuca sativa L. var. longifolia*), y se entrenó a la red con la capacidad de distinguir entre

cinco niveles progresivos de deshidratación de esta planta. Para entrenar la red se requirió contar con un conjunto de imágenes digitales de la lechuga romana, etiquetadas bajo los cinco niveles de deshidratación. Dado que no se encontró información en la literatura sobre alguna base de datos de imágenes con las características requeridas en este proyecto, fue necesario crear una base de datos propia.

3.1. Creación de la base de datos de imágenes

Para crear la base de datos de imágenes se cultivaron 100 plantas de lechuga romana, para después someterlas a diferentes niveles de deshidratación y realizar la captura y etiquetado de las imágenes. El sembrado de las semillas se llevó a cabo en una charola germinadora de plástico rígido (ver Figura 1), expuesta directamente a la luz solar, con temperatura ambiente entre los 15° y 25°. Después de 48 horas de sembradas, y una vez germinadas las semillas, se colocó la charola bajo una malla sombra de plástico con 90 % de protección solar.

A partir del sembrado y durante el tiempo de desarrollo de las plantas se regaron en intervalos de 24 horas, utilizando en cada riego aproximadamente litro y medio de agua potable para toda la charola. En cada riego se aplicaron 5 gramos de fertilizante triple 19 por litro de agua. Esta mezcla de fertilizante está compuesta por un 19 % de Nitrógeno, 19 % de Fósforo y 19 % de Potasio, y el restante se divide entre Manganeso, Boro, Cobre y Zinc.

Se decidió iniciar el proceso de adquisición de imágenes digitales después de la cuarta semana de crecimiento. En esta etapa han brotado al menos las primeras cuatro hojas verdaderas y, aunque aún cuentan con algunas hojas de *leche*, dejan de considerarse plántulas y se reconocen como plantas. Se eligió esta etapa de desarrollo para el reconocimiento del nivel de deshidratación, ya que es una etapa en la que las plantas suelen ser transplantadas a otro medio para su crecimiento, en el cual la frecuencia y cantidad de riego se trata de controlar de forma más precisa.

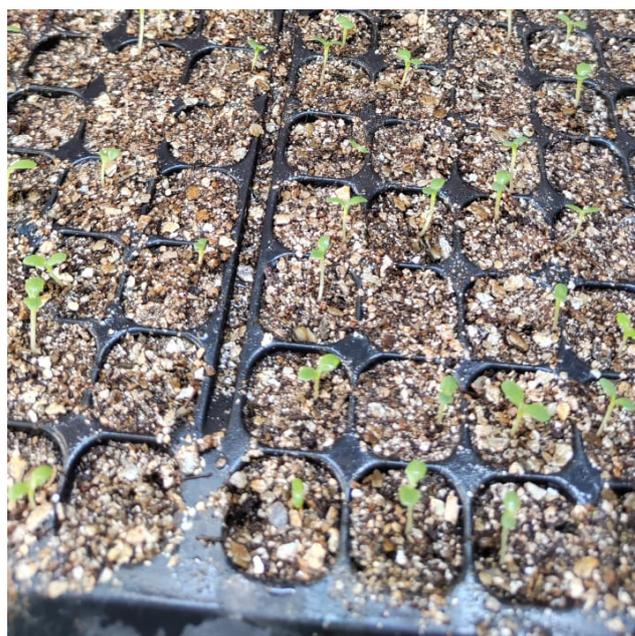


Figura 1: Charola con plántulas de lechuga romana.

Para la adquisición de imágenes se montó un escenario dentro de una habitación cerrada con fondo negro, utilizando una base para colocar las plantas, iluminada con tres focos ubicados frente a estas. Las imágenes se capturaron con una cámara para Raspberry Pi 3, con la tarjeta conectada a una pantalla LCD. Las imágenes se tomaron a una distancia de 15 cm entre la cámara y las plantas (ver Figura 2). La captura de imágenes se realizó con 20 plantas elegidas al azar. La primera sesión de captura fue justo después de regar por última vez las plantas, a partir de ese momento se suspendió el riego y se continuó capturando imágenes de cada planta en intervalos de dos horas, durante las 102 horas siguientes.

En total se obtuvieron 860 imágenes, divididas en 172 imágenes por cada uno de los cinco niveles de deshidratación. El nivel de cada imagen se asignó de acuerdo a la hora en que se tomó la fotografía. Por ejemplo, se etiquetó como nivel "0" a las imágenes tomadas entre las cero y las primeras 16 horas después de que se dejó de regar. Estas plantas se encuentran en buen estado y tienen un alto nivel de humedad. Se asignó nivel "4" a las imágenes tomadas entre 80 y 102 horas después de la última irrigación, estas plantas están en peor estado y con muy bajo nivel de humedad (ver Tabla 1). En la Figura 3 se muestra un ejemplo de plantas en los cinco niveles de deshidratación.

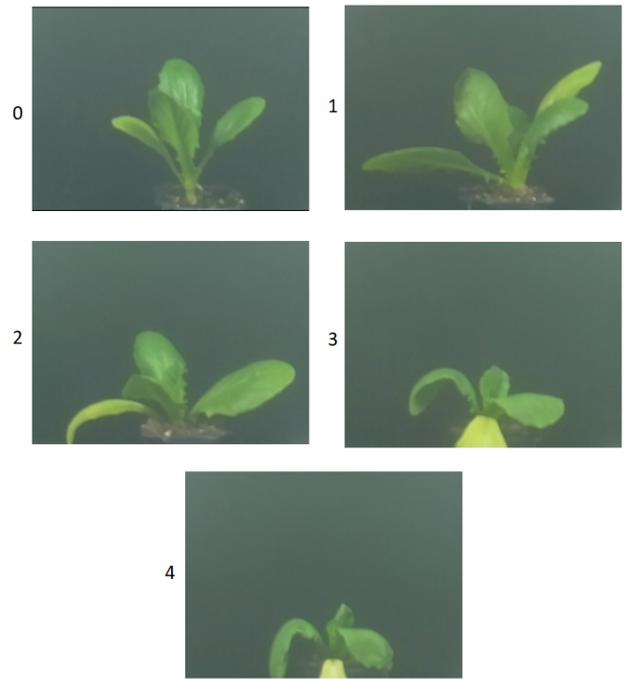


Figura 3: Imágenes de plantas en diferentes niveles de deshidratación.

Tabla 1: Intervalo de horas por nivel de deshidratación.

Nivel de deshidratación	Horas desde el último riego
0	0 a 16
1	16 a 38
2	38 a 62
3	62 a 80
4	80 a 102



Figura 2: Toma de muestras de imágenes.

3.2. Arquitectura y entrenamiento de la red neuronal

Una vez generado el conjunto de imágenes se realizó el entrenamiento de la red neuronal. En la Figura 4 se muestra la arquitectura de red utilizada. La primera capa de la red recibe las imágenes con dimensiones de 320 x 240 píxeles con 3 canales de color. Posteriormente se define una capa de convolución con *kernel* de 5x5, seguida de una capa de *Pooling* de 4x4, generando 20 mapas de características. En ambas capas se aplica la función de activación ReLU. A continuación se repite la secuencia de capa de convolución seguida de capa de *Pooling*, generando en este caso 30 mapas de características. Los mapas de características que resultan después de aplicar estas dos secuencias son de 18x13 neuronas. Finalmente, se definen dos capas lineales totalmente conectadas, la primera de 100 neuronas y la segunda de 5 neuronas que corresponden a los 5 niveles de deshidratación en que se clasifican las plantas. La función de activación de la primera capa lineal es ReLU y la función de la última capa es *Softmax* logarítmica.

La arquitectura de la CNN se diseñó bajo el criterio de generar un modelo-solución ligero que pueda ser implementado de forma eficiente en una tarjeta embebida con limitaciones de procesamiento y memoria (ej. Raspberry pi 3 B+), pero que a la vez mantenga un nivel de precisión competitivo respecto al estado del arte. Para esto, se buscó limitar el número de capas convolucionales para la extracción de características de las imágenes, así como el número de capas totalmente conectadas para la clasificación final. De esta forma, a partir de una experimentación incremental en cuanto al número de capas, mapas de características y neuronas, se obtuvo una arquitectura con un número relativamente pequeño de parámetros y un buen nivel de predicción.

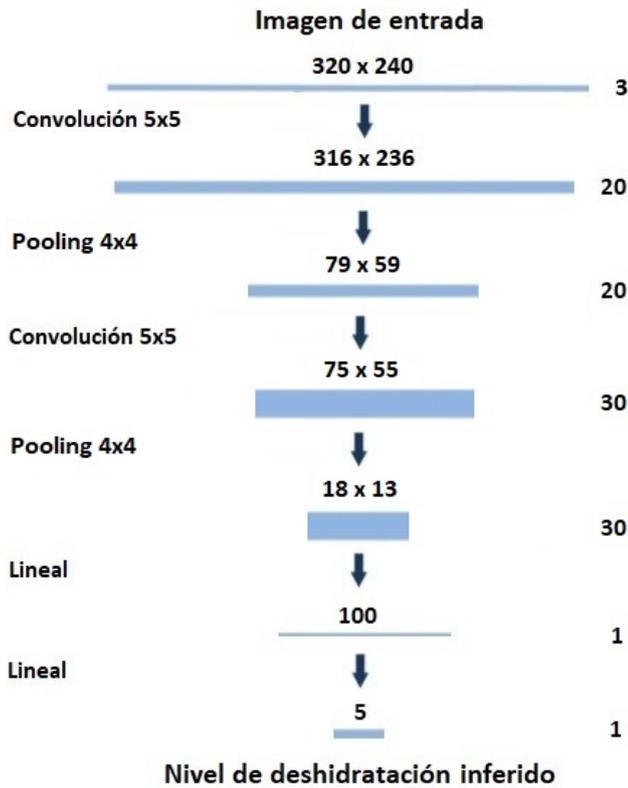


Figura 4: Arquitectura de la red neuronal utilizada.

El Algoritmo 1 corresponde al proceso de entrenamiento de la red neuronal. Para este proceso se utilizaron 688 imágenes, distribuidas en los cinco niveles de deshidratación de acuerdo a como se muestra la Tabla 2. Las imágenes se agruparon de forma aleatoria en lotes de 10 para aplicar el modelo actual y ajustar los pesos de la red. La parte principal del algoritmo consiste en un bloque de cuatro funciones dentro del segundo ciclo for: 1) se aplica el modelo actual (pesos y bias) de la red sobre cada lote de imágenes, obteniendo como salida la inferencia del nivel de deshidratación de las plantas que corresponden al lote de imágenes. 2) se aplica la función de pérdida para obtener el error logarítmico de la inferencia del modelo, respecto a los niveles reales recibidos como etiquetas. 3) se aplica la retropropagación del error calculado de la última capa hacia las capas previas de la red. 4) Dado el error asociado a cada peso y bias calculado en la retropropagación, se aplica el ajuste atenuado con el factor o tasa de aprendizaje.

Tabla 2: Distribución de imágenes de entrenamiento por nivel de deshidratación.

Imágenes de entrenamiento					
Nivel de deshidratación	0	1	2	3	4
Cantidad de imágenes	141	136	140	136	135

Algoritmo 1: Entrenamiento de la Red Neuronal

```

entrada: parámetros de entrenamiento
salida : modelo de red neuronal entrenada
modelo_red ← genera modelo de red neuronal inicial
optimizador ← define función de optimización SGD
menor_perdida ← 0
for epoca in rango(1, total_epocas) do
  activa modo entrenamiento de modelo_red
  for imagenes, etiquetas in conjunto entrena do
    salida ← aplica modelo_red sobre imagenes
    perdida ← aplica función de pérdida NLL sobre salida vs etiquetas
    aplica retropropagación del error (perdida.backward())
    aplica actualización de pesos y bias (optimizador.step())
  end
  activa modo evaluación de modelo_red
  perdida_prueba ← 0
  for imagen, etiqueta in conjunto de prueba do
    salida ← aplica modelo_red sobre imagen
    perdida_prueba += aplica función de pérdida NLL sobre salida vs etiqueta
  end
  if perdida_prueba < menor_perdida then
    guarda modelo_red
    menor_perdida ← perdida_prueba
  end
end
  
```

En la Tabla 3 se muestran los parámetros de entrenamiento. Los valores de estos parámetros se obtuvieron a través de experimentación, buscando un equilibrio entre el porcentaje de correcta clasificación y el tiempo de ejecución. Esto es, se mantuvo la arquitectura de la red lo más sencilla posible, sin perder más de dos puntos porcentuales en la precisión de la inferencia del nivel de deshidratación. En la Tabla 4 se muestran las características del equipo de cómputo utilizado para el entrenamiento y pruebas de la red.

Tabla 3: Parámetros de entrenamiento.

Parámetro	Valor
Tamaño de lote	10
Número de épocas	150
Tasa de aprendizaje	0.01
Función de pérdida	Negative Log-Likelihood
Función de optimización	Stochastic Gradient Descent

Tabla 4: Equipo de cómputo de entrenamiento.

Componente	Descripción
Procesador	Intel i5 7th Gen
Tarjeta gráfica	Nvidia GTX 1050
Memoria RAM	16 GB
Disco duro	1.5 TB
Sistema operativo	Windows 10

4. Resultados

La evaluación del modelo de red obtenido se realizó con 172 imágenes, distribuidas en los cinco niveles de deshidratación de las plantas, de acuerdo a como se muestra en la Tabla 5. Estas 172 imágenes no se utilizaron para el entrenamiento de la red, es decir, son imágenes desconocidas por el modelo. Las pruebas consistieron en procesar las imágenes con el modelo de red para inferir el nivel de deshidratación que presentan las plantas en cada imagen.

Tabla 5: Distribución de imágenes de prueba por nivel de deshidratación.

Imágenes de prueba					
Nivel de deshidratación	0	1	2	3	4
Cantidad de imágenes	31	36	30	36	39

La Figura 5 muestra el mapa de calor de los resultados de las pruebas. Las etiquetas de las filas del mapa corresponden a los niveles de deshidratación reales de las imágenes y las etiquetas de las columnas corresponden a los niveles inferidos por el modelo. Se puede observar en el mapa una tendencia clara de clasificación del nivel real de las imágenes, predominando la diagonal principal que representa los positivos verdaderos, seguida de las diagonales contiguas a esta, que representan la clasificación con un nivel de diferencia del real.

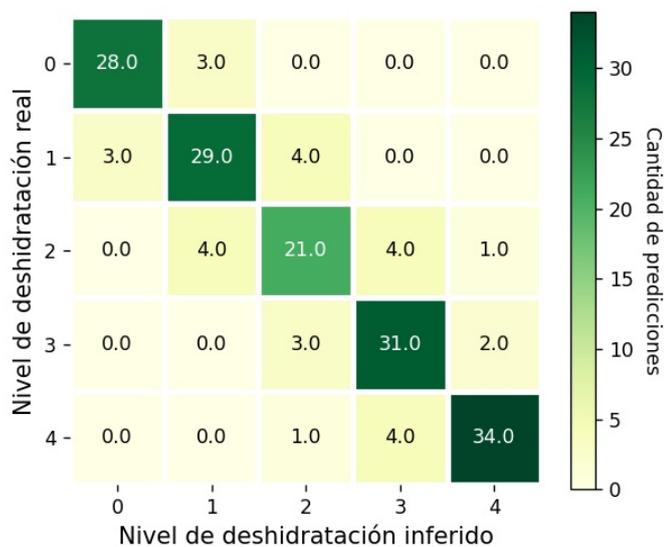


Figura 5: Mapa de calor de las pruebas de inferencia.

La Tabla 6 muestra la precisión (1) y la sensibilidad (2) del modelo. Se puede observar que el modelo obtuvo una menor precisión para el nivel "2" con el 72.4 %, para el cual de las 29 imágenes inferidas en este nivel, solo 21 son correctas. Así mismo, para el nivel "2" obtuvo la menor sensibilidad con 70.0 %, ya que de las 30 imágenes que corresponden a este nivel logró inferir 21. Por otro lado, para los niveles extremos el modelo obtuvo los mayores porcentajes de precisión y sensibilidad. Para el nivel "4" obtuvo la mayor precisión con el 91.9 %, resultando 34 clasificaciones correctas de las 37 inferidas. Para el nivel "0" logró la mayor sensibilidad con el 90.3 %, clasifican-

do correctamente 28 de las 31 imágenes con verdadero positivo de este nivel.

$$Precisión = \frac{TP}{TP + FP} \tag{1}$$

$$Sensibilidad = \frac{TP}{TP + FN} \tag{2}$$

Tabla 6: Estadística de clasificación por nivel de deshidratación

Nivel de deshidratación	0	1	2	3	4	Total
Positivos verdaderos (TP)	28	29	21	31	34	143
Falsos positivos (FP)	3	7	8	8	3	29
Falsos negativos (FN)	3	7	9	5	5	29
Precisión (%)	90.3	80.5	72.4	79.5	91.9	83.1
Sensibilidad (%)	90.3	80.5	70.0	86.1	87.2	83.1

Como se muestra en el mapa de calor, solo dos de las 172 imágenes de prueba se clasificaron en un nivel con más de una unidad de diferencia del nivel real. En un caso, la imagen se clasificó como nivel "4" siendo del nivel "2", y en el otro, la imagen se clasificó como nivel "2" siendo del nivel "4". Esto es, en ambos casos el modelo infirió un nivel con dos unidades de diferencia del real. La Tabla 7 muestra la precisión y sensibilidad del modelo considerando una tolerancia de más/menos un nivel de diferencia entre el valor inferido y el nivel real. Como se puede observar, tanto la precisión como la sensibilidad del conjunto completo de prueba resultan muy cercanas al 100 %.

Tabla 7: Estadística de clasificación con tolerancia de un nivel de diferencia

Nivel de deshidratación	0	1	2	3	4	Total
Positivos verdaderos (TP)	31	36	29	36	38	170
Falsos positivos (FP)	0	0	1	0	1	2
Falsos negativos (FN)	0	0	1	0	1	2
Precisión (%)	100	100	96.7	100	96.7	98.8
Sensibilidad (%)	100	100	96.7	100	96.7	98.8

En la Figura 6 se muestra el análisis o curva ROC (Receiver Operating Characteristic, o Característica Operativa del Receptor), y el área bajo la curva (AUC, por sus siglas en inglés). Este análisis permite evaluar la efectividad del modelo clasificador, relacionando la tasa de verdaderos positivos (Sensibilidad) contra la tasa de falsos positivos (1-Especificidad) a diferentes umbrales de probabilidad para la aceptación de una clase.

La línea discontinua de la figura corresponde a la curva ROC de un modelo hipotético sin capacidad discriminativa, esto es, un modelo que clasifica de manera aleatoria, con un AUC=0.50. A medida que el AUC de una curva se acerca a 1 (clasificación perfecta), es mayor la efectividad del modelo. El análisis ROC del modelo propuesto, se realizó por cada nivel de deshidratación de forma independiente. Como se puede observar, el AUC de las curvas ROC se encuentra entre 0.935 y 0.998.

Consistente con los resultados presentados en la Tabla 6, el análisis ROC muestra una mayor efectividad del modelo en

el reconocimiento correcto del nivel 0 de deshidratación, y una menor efectividad para el nivel 2. En contraste, muestra una efectividad similar en el reconocimiento del nivel 1 y 4, contrario a lo presentado en la Tabla 6, donde la precisión y sensibilidad de reconocimiento del nivel 4 es mayor.

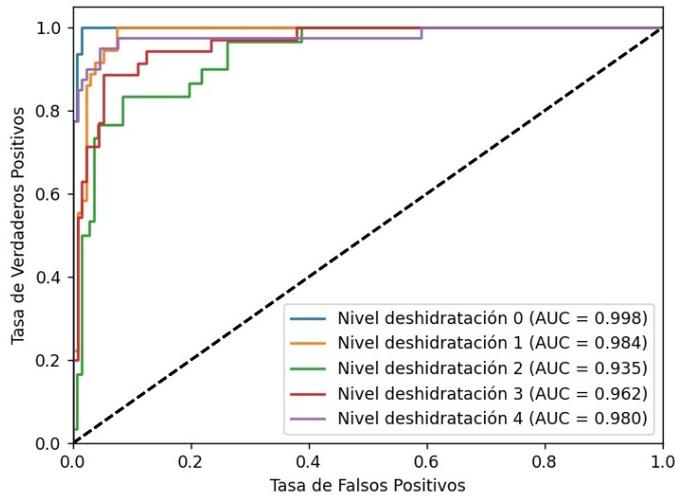


Figura 6: Curva ROC por nivel de deshidratación.

La Tabla 8 presenta el desempeño del modelo propuesto contra tres modelos ligeros evaluados en uno de los trabajos mencionados en el estado del arte (Kamarudin e Ismail, 2022), los cuales se entrenaron utilizando imágenes RGB con luz visible.

Tabla 8: Comparación del desempeño y tamaño del modelo propuesto contra otros modelos ligeros.

Modelo	Precisión	Tiempo de inferencia CPU (ms)	Tiempo de inferencia GPU (ms)	Tamaño (MB)	Parámetros
EfficientNet*	88.12 %	46.0	4.91	29	5,330,571
Propuesto**	83.1 %	9.7	0.60	3	719,155
NasNet mobile*	81.87 %	27.04	6.70	23	5,326,716
MobileNet-V2*	76.87 %	25.9	3.83	14	3,538,984

* Entrada: Imágenes de (Fahlgren et al., 2015), fueron pre-procesadas y escaladas para cada modelo. Clasifica 3 niveles de estrés por sequía: Sequía Severa, Sequía Leve, Sin Sequía, en un periodo de 17 días. Se inició con plantas de césped Setaria (*Setaria grass*) con 17 días de plantadas, con 4 tratamientos de riego durante 17 días más.

** Entrada: Imágenes con resolución de 320 x 240. Clasifica 5 niveles de estrés hídrico en un periodo entre 0 y 102 horas. Se inició con plantas de lechuga romana con 28 días de plantadas, con un tratamiento de 4.25 días más.

Es de notar que las imágenes de plantas utilizadas en el estudio de (Kamarudin e Ismail, 2022) tuvieron tratamientos de irrigación más prolongados (17 días) con diferentes porcentajes de capacidad completa de agua, y que las plantas utilizadas en este estudio, tuvieron un tratamiento (sin irrigación) realizado en un periodo de 4.25 días.

5. Conclusiones

Los experimentos realizados en este trabajo muestran que es factible estimar el nivel de deshidratación de las plantas, a tra-

vés de imágenes digitales capturadas con luz visible, utilizando CNNs. El modelo propuesto obtuvo una precisión y sensibilidad del 83.1 % en la predicción del nivel de deshidratación real de las plantas, y de un 98.8 % considerando una tolerancia de un nivel con respecto al real.

Como objetivo de este proyecto se propuso mantener la estructura del modelo lo más sencilla y ligera posible, con el fin de aplicarlo de manera embebida en un dispositivo de bajo costo y rendimiento, para ser utilizado en un futuro en el monitoreo de un sistema de cultivo aeropónico.

Durante el desarrollo de este trabajo observamos la dificultad de encontrar bases de datos útiles para este tipo de investigación. Por lo que se generó una base de datos de 860 imágenes de la lechuga romana etiquetadas en cinco niveles distintos de deshidratación, que consideramos puede ser útil para otros proyectos similares.

Agradecimientos

Agradecemos al CONACYT, TecNM y CIBNOR por su apoyo en el desarrollo de este proyecto. Así mismo, se agradece al técnico Miguel Díaz Ramírez, del Centro de Investigaciones Biológicas del Noroeste, S. C. por su apoyo y asesoría en el cultivo de las plantas.

Referencias

Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., y Stefanovic, D. (2019). Solving current limitations of deep learning based approaches for plant disease detection. *Symmetry*, 11(7).

Aversano, L., Bernardi, M. L., y Cimitile, M. (2022). Water stress classification using convolutional deep neural networks. *JUCS - Journal of Universal Computer Science*, 28(3):311–328.

Baranwal, S., Khandelwal, S., y Arora, A. (2019). Deep learning convolutional neural network for apple leaves disease detection. *SSRN Electronic Journal*.

Bechtis, D., Moisiadis, V., Tsolakis, N., Vlachos, D., y Bochtis, D. (2017). Scheduling and control of unmanned ground vehicles for precision farming: A real-time navigation tool. En *HAICTA*, pp. 180–187.

Conagua (2020). Programa Nacional Hídrico 2020-2024, Comisión Nacional del Agua, Secretaría de Medio Ambiente y Recursos Naturales Cd. de México, México.

Conagua (2022). Numeragua Edición 2022, Comisión Nacional del Agua, Secretaría de Medio Ambiente y Recursos Naturales, Cd. de México, México.

Concepcion II, R., Lauguico, S., Almero, V. J., Dadios, E., Bandala, A., y Sybingco, E. (2020). Lettuce leaf water stress estimation based on thermovisible signatures using recurrent neural network optimized by evolutionary strategy. En *2020 IEEE 8th R10 Humanitarian Technology Conference (R10-HTC)*, pp. 1–6.

Fahlgren, N., Feldman, M., Gehan, M. A., Wilson, M. S., Shyu, C., Bryant, D. W., Hill, S. T., McEntee, C. J., Warnasooriya, S. N., Kumar, I., Ficor, T., Turnipseed, S., Gilbert, K. B., Brutnell, T. P., Carrington, J. C., Mockler, T. C., y Baxter, I. (2015). A versatile phenotyping system and analytics platform reveals diverse temporal responses to water availability in setaria. *Molecular Plant*, 8(10):1520–1535.

FAO e ITO (2018). E-agriculture in action: drones for agriculture, Food and Agric. of the U. N. and Intl. Telecomm. Union, Bangkok.

FAO e ITO (2021). Digital agriculture in action: artificial intelligence for agriculture, Food and Agric. of the U. N. and Intl. Telecomm. Union, Bangkok.

Fernandes, H., Moriones, E., Garcia, A., Barrero Mendoza, O., y Albiero, D. (2020). Agricultural unmanned ground vehicles: A review from the stability point of view. *REVISTA CIENCIA AGRONOMICA*, 51.

Gonzalez-de Santos, P., Fernandez, R., Sepúlveda, D., Navas, E., y Armada, M. (2020). *Unmanned Ground Vehicles for Smart Farms*.

Idris, I. y Sani, M. (2012). Monitoring and control of aeroponic growing system for potato production. pp. 120–125.

Inegi (2020). Censo de población y vivienda 2020, Instituto Nacional de Estadística y Geografía, México.

- Kai, T., Li, J., Zeng, J., Asenso, E., y Zhang, L. (2019). Segmentation of tomato leaf images based on adaptive clustering number of k-means algorithm. *Computers and Electronics in Agriculture*, 165.
- Kamarudin, M. e Ismail, Z. (2022). Lightweight deep cnn models for identifying drought stressed plant. *IOP Conference Series: Earth and Environmental Science*, 1091:012043.
- Kerns, S. y Lee, J.-L. (2017). Automated aeroponics system using iot for smart farming. *European Scientific Journal*.
- Lakhiar, I., Jianmin, G., Syed, T., Chandio, F. A., Buttar, N., y Qureshi, W. (2018). Monitoring and control systems in agriculture using intelligent sensor techniques: A review of the aeroponic system. *Journal of Sensors*, 2018:18.
- Lucero, L., Lucero, D., Ormeno-Mejia, E., y Collaguazo, G. (2020). Automated aeroponics vegetable growing system. case study lettuce. En *2020 IEEE ANDESCON*, pp. 1–6.
- Mammarella, M., Comba, L., Biglia, A., Dabbene, F., y Gay, P. (2021). Cooperation of unmanned systems for agricultural applications: A theoretical framework. *Biosystems Engineering*, 223:61–80.
- Mithunesh, P., Gupta, K., Ghule, S., y Hule, S. (2015). Aeroponic based controlled environment based farming system. *IOSR Journal of Computer Engineering (IOSR-JCE)*, 17(6):55–58.
- Montoya, A., Obando, F., Morales, J., y Vargas, L. (2017). Automatic aeroponic irrigation system based on arduino's platform. *Journal of Physics: Conference Series*, 850:012003.
- Naji, I. (2020). The drones' impact on precision agriculture, Master thesis, University of Texas, El Paso, U.S.
- NASA (2006). Progressive plant growing has business blooming. *Environmental and Agricultural Resources. New York: NASA Spinoff*, pp. 64–77.
- Ngugi, L., Abelwahab, M., y Abo-Zahhad, M. (2020). Recent advances in image processing techniques for automated leaf pest and disease recognition - a review. *Information Processing in Agriculture*, 8.
- Ochoa-Noriega, C., Aznar-Sánchez, J. A., Velasco Muñoz, J., y Alvarez, A. (2020). The use of water in agriculture in mexico and its sustainable management: A bibliometric review. *Agronomy*, 10:1957.
- Rahman, R., Arko, P., Ali, M. E., Khan, M., Apon, S. H., Nowrin, F., y Wasif, A. (2020). Identification and recognition of rice diseases and pests using convolutional neural networks. *Biosystems Engineering*, 194:112–120.
- Sharif, M., Khan, M., Iqbal, Z., Azam, F., Lali, M. I., y Javed, M. (2018). Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection. *Computers and Electronics in Agriculture*, 150.