

Algoritmo detector de nivel de clorofila tipo A y B en las hojas a partir de una red neuronal convolucional

Algorithm to detect the level of chlorophyll type A and B in the leaves from a convolutional neural network

Rafael Núñez-Rodríguez¹, Daniel Velazco-Capacho²

Resumen: En este trabajo se presenta el desarrollo de un algoritmo detector de los niveles de clorofila tipo A y tipo B presente en algunas plantas, mediante el procesamiento digital de imágenes a partir de una red neuronal convolucional. Durante el desarrollo del algoritmo se construyó un módulo de adquisición de imagen de material vegetal sometido a longitudes de onda entre 430 nm y 650 nm. Este módulo permitió la construcción de un banco de imágenes para el preprocesamiento, entrenamiento y validación del desempeño de la red neuronal. Los resultados obtenidos durante el proceso de validación de las diferentes arquitecturas de la red neuronal convolucional, muestran que el modelo de red R1000A presentó la mayor precisión a la hora de etiquetar las muestras de material vegetal parametrizado, con un valor del 98,22% de precisión. Estos resultados indican que para la clasificación de niveles de clorofila que no requieran gran exactitud, una red neuronal convolucional puede realizar esta labor de manera adecuada si se entrena con una cantidad de muestras superior a 1000 imágenes, un *batch size* de 100 y una tasa de aprendizaje de 0.0001.

¹ Ingeniero Electrónico, Unidades Tecnológicas de Santander, Colombia. Magíster en Ingeniería Electrónica. E-mail: rrodriguez@correo.uts.edu.co ORCID: <https://orcid.org/0000-0001-6775-776X>

² Ingeniero Electrónico, Unidades Tecnológicas de Santander, Colombia. Doctor el Proyectos, E-mail: dvelazco@correo.uts.edu.co ORCID: <https://orcid.org/0000-0003-3297-6318>

Palabras clave: Clorofila, Material vegetal, Procesamiento digital de imágenes, Red neuronal convolucional.

Abstract: In this work, it is presented the development of a detector algorithm of chlorophyll type A and type B levels present in some plants, by means of digital image processing from a convolutional neuronal network. During the development of the algorithm, an image acquisition module of plant material subjected to wavelengths between 430 nm and 650 nm was built. This module allowed the construction of an image bank for pre-processing, training and validation of the performance of the neural network. The results obtained during the validation process of the different architectures of the convolutional neuronal network, show that the R1000A network model presented the highest precision when labeling the samples of parameterized vegetable material, with a value of 98.22% of precision. These results indicate that for the classification of chlorophyll levels that do not require high accuracy, a convolutional neuronal network can perform this task adequately if trained with a number of samples higher than 1000 images, a batch size of 100 and a learning rate of 0.0001.

Keywords: Chlorophyll, Plant material, Digital image processing, Convolutional neural network.

1. Introducción

Actualmente, el uso de la tecnología se ha extendido a muchos campos de la actividad humana [1]. Uno de estos campos es la agricultura, donde modernos equipos han facilitado en gran manera a la proliferación de cultivos en todo el mundo, y no sólo eso, también han dado paso a la creación de nuevas especies de vegetales con mejores valores alimenticios. Un ejemplo del uso de las nuevas tecnologías en el campo agrícola es la detección de enfermedades en las plantas mediante procesamiento digital de imágenes y redes neuronales convolucionales [2]. Dichas redes neuronales se han convertido en algoritmos muy empleados para el diseño de programas de aprendizaje automático, en el que un sistema aprende a realizar tareas de clasificación directamente a partir de imágenes, vídeos, textos o sonidos [3]. Estas redes son útiles para detectar patrones en imágenes que permitan reconocer objetos, rostros o

escenas [4]. Gracias a estas características se elige las redes neuronales convolucionales como una buena opción para el diseño de un algoritmo que sea capaz de detectar enfermedades de forma temprana en las hojas, mediante la detección del nivel de clorofila presente. La clorofila A y B absorbe en gran medida la longitud de onda entre 460 nm y 645 nm [5]. En [6] se evalúa el efecto que causa la emisión de luz por parte de LED en plantaciones de chile serrano. Las semillas se expusieron a luz blanca, azul y roja, siendo controladas por luz fluorescente, con un fotoperiodo de 11 a 13 horas. Se pudo demostrar que la longitud de la hoja y el ancho de tallo se vieron favorecidos por la luz roja, en cambio, la luz led azul aumento la cantidad de follaje. Aquellas plantas irradiadas con luz azul presentaron mayor cantidad de pigmentos fotosintéticos (Carotenoides= 0.12 mg g⁻¹, Clorofila= 0.84 mg g⁻¹). En este sentido, es válido afirmar que las longitudes de onda azul y roja afectan de manera significativa la producción de clorofila por parte de las plantas. Por tanto, estos resultados se pueden aprovechar para plantear estrategias que permitan determinar con cierto grado de precisión, el estado de salud de una planta y detección temprana de enfermedades en función de la concentración de clorofila con base a la cantidad de luz roja y azul que una hoja puede absorber. Es por ello que se plantea el desarrollo de un algoritmo capaz de clasificar el nivel de clorofila “A” y “B” presente en las hojas en tres niveles posibles: alto, medio y bajo; en donde principalmente, se elabora una base de datos a partir de imágenes tomadas por medio un dispositivo que irradia luz con longitud de onda entre 460 nm y 645 nm. Seguido, estas imágenes son utilizadas para proceso de entrenamiento y validación de la red neuronal convolucional con el fin de elaborar un algoritmo capaz de clasificar la concentración de clorofila.

2. Materiales y Métodos


Para el desarrollo del algoritmo se plantea inicialmente la construcción del módulo de adquisición de imágenes, el cual está compuesto por fuentes de emisión de luz con longitud onda entre 460 nm y 645 nm, circuito driver para gestión de los LED y un dispositivo de captura de imagines con interfaz USB. Este módulo permite generar las imágenes de las muestras del material vegetal con diferentes longitudes

de onda para su posterior procesamiento. A partir de este banco de imágenes, se construye la arquitectura de la red neuronal convolucional con sus respectivas etiquetas de salida y demás parámetros de entrenamiento para su posterior entrenamiento y validación.

2.1. Banco de imágenes

Se ensambló un dispositivo de captura a partir de una caja en la cual se aloja fuentes de emisión de luz alineadas en contraposición con una cámara USB, driver de control de fuentes luminosas, esquema de captura y envío de información al host y, soporte de vidrio donde se ajusta el material vegetal. En la Figura 1, se observa la estructura del módulo de captura.

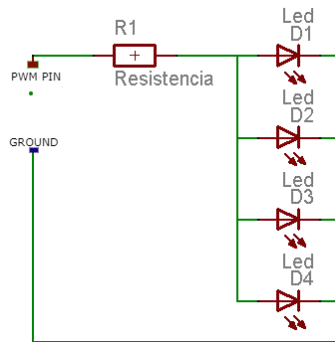
Figura 1. Prototipo del módulo de adquisición de imágenes de muestra de material vegetal



Fuente: elaboración propia.

Teniendo en cuenta que las muestras de material vegetal deben ser irradiadas por luz con longitud onda entre 460 nm y 645 nm a fin de estimar el nivel de la concentración de clorofila (Bajo, Medio, Alto), el sistema de iluminación se diseñó de manera que, cada muestra de material vegetal fuese irradiado por 4 LED de alta intensidad y diámetro de 5 mm. La distribución de las fuentes de emisión de luz se realizó a partir de una conexión en paralelo, esto para garantizar una máxima intensidad de cada LED y así aprovechar su máxima potencia. El circuito de conexión se presenta en la Figura 2. A fin de modular diferentes longitudes de onda, la potencia aplicada los LED se modula a partir de una señal PWM (Pulse Width Modulation).

Figura 2. Circuito driver de fuentes de iluminación LED.



Fuente: elaboración propia.

De acuerdo con el adecuado funcionamiento del módulo de adquisición, se construye la base de datos referente a las imágenes de material vegetal. Dado que la estrategia se basa en la detección del nivel de clorofila tipo A y tipo B en el material vegetal, se hace necesario establecer al menos tres niveles posibles de concentración de clorofila; para ello, se definen las siguientes etiquetas: material vegetal verde corresponde a un nivel alto, material vegetal amarillo corresponde a nivel medio y material vegetal marrón a nivel bajo de clorofila. En la Figura 3 se observa el aspecto de cada material vegetal y su respectiva etiqueta.

Figura 3. Etiquetas para los niveles de concentración de clorofila.



Fuente: elaboración propia.

Para la construcción del banco de imágenes se capturan 250 imágenes de material vegetal por cada nivel de clorofila establecido. Las hojas que se usan para el banco de imágenes pertenecen a una gran cantidad de plantas de diferentes tipos, entre ellas se encuentran: almendrón (*Terminalia catappa*), acacia amarilla

(Cassia siamea), el ficus (Ficus benjamina), caucho común (Ficus elástica), pata de vaca (Bauhinia purpúrea), lluvia de oro (Cassia fistula), pomarroja brasileña (Syzygium malaccense), las cuales se presentan en la Figura 4, entre otras especies más [7].

Figura 4. Muestra de especies de material vegetal utilizado.



Fuente: elaboración propia.

Para cada muestra de material vegetal seleccionado, se captura una imagen al hacer incidir irradiancia cercana a la longitud de onda del color azul y rojo. Cada imagen se le asigna una etiqueta respecto a la intensidad de color verde relacionado con la concentración de clorofila. En la Figura 5 se observan imágenes de muestra de cada etiqueta relacionada con la reflexión de longitudes de onda roja y azul.

Figura 5. Imágenes de muestra con etiqueta relacionada.



Fuente: elaboración propia.

2.2. Entrenamiento Red Neuronal Convolutacional

2.2.1. Preprocesamiento banco de imágenes

El algoritmo de detección está basado en la red neuronal convolutacional AlexNet [8], la cual tiene como entrada una imagen de 227 x 227 píxeles como máximo. Las imágenes obtenidas por la cámara *Genius Facecam* usadas en el módulo captura, tienen una resolución de 640 x 480 píxeles, siendo esta mucho más grande que la máxima soportada por la CNN. Para adaptar las imágenes a la resolución necesaria, se hace uso de la herramienta Matlab®, la cual permite reajustar la resolución original de la imagen de entrada a una de 227 x 227 píxeles, dando como resultado una nueva muestra con el tamaño requerido para la CNN AlexNet. En la Tabla 1 se presenta el pseudocódigo para el reescalado del banco de imágenes.


Tabla 1. Pseudocódigo para el reescalado de banco de imágenes.

# Línea	Acción
1	Inicio Algoritmo para reescalado de imagen
2	Guardar muestras en variable test
3	Inicio ciclo for para reescalado de muestras
4	Incremento de la variable i (muestras)
5	Reescalado de muestras
6	Fin del ciclo For
7	Fin Algoritmo para reescalado de imagen

Fuente: elaboración propia.

Una etapa de preprocesamiento adicional se realiza para seleccionar la región en la imagen donde se presenta mayor densidad de luz roja o azul reflejada de acuerdo a la concentración de clorofila. En la Figura 6 se aprecia el resultado del método implementado.

Figura 6. Región de 227x227 px con mayor densidad de luz reflejada.



Fuente: elaboración propia.

Con un número de 250 imágenes por etiqueta se implementa un algoritmo para rotar y reflejar las muestras con el fin de obtener 4 veces el número de imágenes por nivel y aumentar la capacidad de aprendizaje de la CNN, dando como resultado 1000 imágenes por cada nivel establecido (Alto, Medio, Bajo).

2.2.2. Entrenamiento de Algoritmo de detección

En esta etapa se procede a entrenar las redes neuronales por medio de la herramienta del software de programación Matlab® llamada *Deep Learning Toolbox*. Esta *Toolbox* trae incorporada un esquema para el entrenamiento de la CNN AlexNet. Con base en esto, se reajusta los parámetros para que se adapten a la problemática del proyecto y se procede a entrenar cada una de las redes. A continuación, en la Tabla 2 se puede evidenciar el pseudocódigo utilizado para el entrenamiento de manera jerárquica. Durante esta etapa, se procede a entrenar múltiples redes con el fin de encontrar la que mejor precisión ofrezca. A partir de esto se entrenan 10 redes diferentes, cada una de estas, con características únicas, variando

entre ellas la cantidad de imágenes que se encuentran en el banco de muestras, el batch size y el tipo de imagen.

Tabla 2. Pseudocódigo para entrenamiento de las CNN.

# Línea	Acción
1	Inicio Algoritmo para entrenamiento de la CNN
2	Leer las carpetas con las imágenes de muestra.
3	Leer las etiquetas de cada nivel de clorofila
4	Separación banco de muestras (Entrenamiento, Validación)
5	Inicio de asignación de ajustes preliminares
6	Declarar tipo de CNN
7	Declarar capas de la CNN a usar.
8	Ingresar número de clases y capas a usar
9	Asignar valor del tamaño del lote
10	Establecer método para corrección de error
11	Asignar número de iteraciones por época
12	Asignar número de épocas
13	Fin de la asignación de ajustes preliminares
12	Iniciar entrenamiento de la CNN
13	Clasificar etiquetas con la red entrenada
14	Evaluar exactitud de la red entrenada
15	Fin Algoritmo para entrenamiento de la CNN

Fuente: elaboración propia.

Cada una de las redes entrenada a partir del algoritmo de la Tabla 2, se comporta de manera diferente durante su entrenamiento. En la Tabla 3 se observa cada uno de los ajustes de entrenamiento de las redes.

Tabla 3. Pseudocódigo para entrenamiento de las CNN.


Modelo de red	Ajustes de Red				
	Batch Size	Épocas	Aprendizaje	Cantidad de imágenes por nivel	Tipo de imagen
R50	10	4	0,0001	50	Reducida
R100	10	4	0,0001	100	Reducida
R150	10	4	0,0001	150	Reducida
R200	10	4	0,0001	200	Reducida
R250	50	4	0,0001	250	Reducida
R500	100	4	0,0001	500	Reducida
R750	100	4	0,0001	750	Reducida
R1000A	10	4	0,0001	1000	Reducida
R1000B	10	4	0,0001	1000	Recortada
R1000C	100	4	0.0001	1000	Reducida

Fuente: elaboración propia.

En la Figura 7, se puede visualizar la gráfica de entrenamiento que arroja la función *Transfer Learning Using AlexNet*. Esta se divide en dos, la primera de ella está formada por tres tipos de línea, siendo la más clara y de color azul el comportamiento de aprendizaje de la red en cada iteración, la línea azul oscuro representa el comportamiento de la red, pero de manera suavizada, prediciendo el posible

comportamiento de la red para evitar cambios bruscos. Y por último la línea segmentada negra representa el porcentaje de validación alcanzado por la red durante esa época.

Figura 7. Gráfica de transferencia de aprendizaje para la CNN R50.



Fuente: elaboración propia.

Logrando el uso adecuado del algoritmo, se diseñó una interfaz gráfica, en la cual se puede evaluar de manera directa una muestra de material vegetal capturada por el módulo de adquisición, permitiendo ver la imagen en vivo iluminada por la luz roja y azul, así como también la imagen iluminada por luz blanca. La interfaz le permite al usuario interactuar con ella a través de múltiples pulsadores que van desde la captura de imágenes, hasta el apagado de la cámara. Esta interfaz gráfica se desarrolló a partir de la herramienta GUIDE de Matlab®, la cual ofrece múltiples alternativas y plantillas para el diseño. La apariencia de la interfaz se observa en la Figura 8.

Figura 8. Interfaz gráfica del algoritmo detector de clorofila.

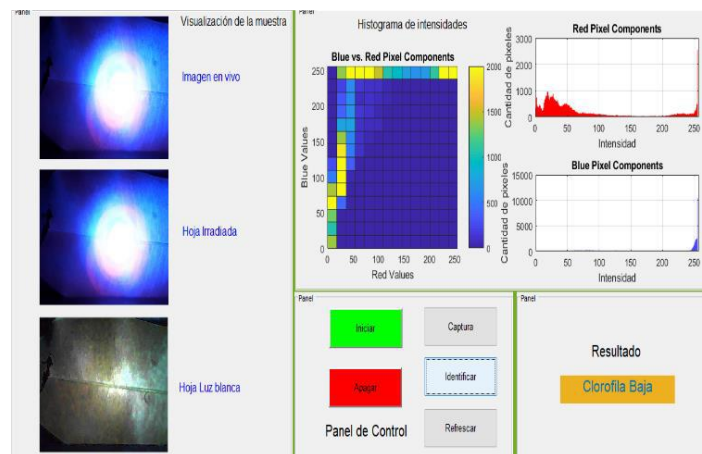


Fuente: elaboración propia.

2.2.3. Validación de algoritmo de detección

De acuerdo a los resultados del proceso de entrenamiento se realiza una etapa de validación, en el cual se ingresan imágenes de material vegetal capturadas por el módulo de adquisición con el fin de comprobar si el nivel de clorofila detectado corresponde al adecuado. Haciendo uso de la interfaz gráfica diseñada anteriormente, el usuario captura la imagen de una muestra aleatoria, de esta manera el algoritmo procede a ajustar la imagen para su próxima clasificación con la CNN y dar como resultado el nivel predicho. En la Figura 9 se observa una muestra procesada en la interfaz.

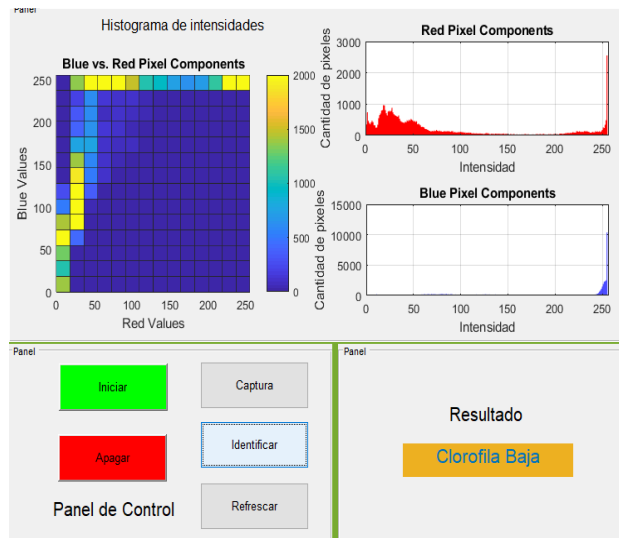
Figura 9. Muestra procesada en la interfaz gráfica.



Fuente: elaboración propia.

Como paso final, la interfaz indicará a través de un mensaje el nivel de clorofila estimado; este mensaje se visualizará al terminar de procesar la muestra. Por otra parte, el resultado del algoritmo también entrega como dato de salida un histograma de la imagen y la cantidad de pixeles asociados por nivel de intensidad, tal como se muestra en la Figura 10.

Figura 10. Resultados en la interfaz gráfica.



Fuente: elaboración propia.

3. Resultados

Los datos que arrojan cada uno de los clasificadores entrenados muestran el porcentaje de exactitud y perdida, permitiendo así, evaluar de mejor manera, cuál de estas desempeña un mejor comportamiento a la hora de clasificar el nivel de clorofila de las muestras. Estos valores se visualizan de manera más clara en la Tabla 4. Tales datos permiten indicar que a medida que sube el número de muestras, también disminuye la exactitud en la validación final, esto lleva a pensar que entre mayor sea la cantidad de imágenes mayor va a ser la dificultad de la red a la hora de predecir las etiquetas correctas. Teniendo claro lo anterior, se debe evidenciar que la cantidad de imágenes de entrenamiento va aumentando de manera considerable desde la red R500.

Los datos que arroja el entrenamiento se computan a través de la ecuación (1), que permite calcular el valor de exactitud de la red y la ecuación (2), utilizada para calcular el error cuadrático medio.

Tabla 4. Resultados de cada modelo de red.

Modelo de Red	Porcentaje de Exactitud	Porcentaje de Perdida	Cantidad de muestras por nivel	Total de muestras
R50	97,78	0,05	50	150
R100	94,44	0,5	100	300
R150	97,04	0,07	150	450
R200	95	0,1	200	600
R250	93,78	0,2	250	750
R500	93,33	0,18	500	1500
R750	93,04	0,23	750	2250
R1000A	92,89	0,31	1000	3000
R1000B	91,89	0,33	1000	3000
R1000C	91.56	0.33	1000	3000

Fuente: elaboración propia.

$$\textit{Precisi3n} = \frac{\textit{Predicciones Correctas}}{\textit{Total de predicciones}} \quad (1)$$


$$\textit{Perdidas} = \frac{\sum_{i=1}^{\textit{Total de muestras}} (\textit{Predicciones}_i - \textit{Real}_i)^2}{\textit{Total de Muestras}} \quad (2)$$

Se puede establecer que entre más muestras tenga una CNN de clasificación, mayor será su robustez y a su vez, la red podrá extraer un número más alto de características que puede usar a la hora de predecir la etiqueta correcta. El número de muestras usado para validar aumenta según la red, siendo para la red R1000A, R1000B Y R1000C un número de imágenes de validación equivalente a 300 muestras por nivel, mucho más grande que las redes anteriores, haciendo más difícil para estas conseguir mayor exactitud a la hora de evaluar. En el diagrama de barras de la Figura 11 se observa de mejor manera como la cantidad de imágenes es inversamente proporcional a la exactitud de la red.

Al finalizar el entrenamiento de las diferentes CNN se establecen y analizan los valores que provocan variaciones en los distintos resultados arrojados por cada red. La cantidad de iteraciones que realiza la CNN durante su preparación, es afectada por la cantidad de imágenes de entrenamiento, el ancho de talla (*batch size*) y el número de épocas. Con un numero de épocas fijo igual a 4 en todas las redes, las variables que afectan esa cantidad de iteraciones decaen en el número de imágenes de entrenamiento y el ancho de talla. En la ecuación (3) se plantea el cálculo de este valor.

$$Iteraciones\ Totales = \frac{Imágenes\ de\ entrenamiento}{Ancho\ de\ talla} \cdot \times\ Numero\ de\ épocas \quad (3)$$

Figura 10. Resultados en la interfaz gráfica.



Fuente: elaboración propia.

En el entrenamiento de las distintas redes implementadas, el número de iteraciones totales presenta una fuerte variación. En la Tabla 5 se puede apreciar cómo cambia ese número dependiendo de las variables mencionadas anteriormente.

Tabla 5. Variación en la cantidad de iteraciones.

Modelo de Red	# de muestras	# de Épocas	Batch size	Iteraciones
R50	150	4	10	40
R100	300	4	10	84
R150	450	4	10	124
R200	600	4	10	168
R250	750	4	50	40
R500	1500	4	100	40
R750	2250	4	100	60
R1000A	3000	4	10	840
R1000B	3000	4	10	840
R1000C	3000	4	100	84

Fuente: elaboración propia.

La transferencia de la red con un batch size de 10 oscila de manera más brusca, a comparación de la red con un batch size de 100. Un reajuste de los pesos más frecuente, puede ocasionar que la red no logre estabilizarse durante su entrenamiento, pero esto no quiere decir que la CNN no alcanzará un valor alto

de exactitud, puesto que, en alguno de esos ajustes de pesos, la red puede encontrar un valor que se ajuste de manera eficaz, logrando así alcanzar un valor de exactitud alto y por lo tanto una estabilización final.

A partir de los resultados de entrenamiento se procede a evaluar cada una de las redes con nuevas muestras con el fin de validar su funcionamiento y observar qué porcentaje de exactitud arrojan ante nuevas imágenes. Para esto, se hace uso de un banco de imágenes de prueba, el cual consta de 250 muestras por cada nivel de clorofila, dando como total 750 imágenes de validación. Los resultados que muestran las 10 redes se pueden observar en la Tabla 6.

Tabla 6. Exactitud e las CNN en la asignación de etiquetas.

Modelo de Red	Imágenes de validación	Exactitud en asignación de etiquetas
R50	750	74,44
R100	750	94,84
R150	750	96,00
R200	750	95,56
R250	750	95,21
R500	750	95,11
R750	750	96,89
R1000A	750	98,22
R1000B	750	95,36
R1000C	750	96,52

Fuente: elaboración propia.

De acuerdo a los datos de la Tabla 6, la red que mayor porcentaje de exactitud presentó es la R1000A, esto se debe a la cantidad de imágenes y el tipo de ajuste usado para su entrenamiento, dando una mayor certeza a la hora de asignar etiquetas a nuevas muestras. De otra forma, la red R50 presenta un bajo porcentaje de exactitud consecuencia de su bajo número de imágenes de entrenamiento. A partir de esto, se puede decir que la red R1000A es la que más se adecua a la problemática establecida, permitiendo al usuario establecer el nivel de clorofila (Alta, Media, Baja) tipo 'A' o 'B' que se encuentra en la muestra, con ayuda de la red seleccionada y el uso del dispositivo de adquisición de muestras, se obtiene un grado de exactitud de 98.22 %.

4. Conclusiones

La emisión de luz roja y azul sobre una muestra de material vegetal permite resaltar de mejor manera las características de las plantas que contienen clorofila 'A' o 'B', debido a la capacidad de este pigmento de absorber o reflejar estas longitudes de onda dependiendo de su nivel de clorofila. El uso de un módulo que aisle la luz exterior e ilumine la muestra con luz roja y azul se ajusta muy bien a la problemática, permitiendo resaltar de mejor manera las características de la muestra, invisibles al ojo humano.

A la hora de entrenar una CNN se obtienen mejores resultados, entre mayor sea el número de imágenes que se usen para su entrenamiento. Esto sucede, debido a que, entre más muestras se ingresen a la red esta podrá extraer más características y volverse de esta manera, más ajustada y exigente a la hora de clasificar una muestra. Es importante no exceder esa tasa de sobre ajuste, porque, esto puede llevar a que la exactitud final de la red decaiga en gran manera y el tiempo de entrenamiento aumente considerablemente.

Referencias

- [1] OCYT, "El papel de la ciencia y la tecnología en la sociedad de conocimiento", 2020. [En línea]. Disponible: <https://www.ocyt.org.co/el-papel-de-la-ciencia-y-la-tecnologia-en-la-sociedad-de-conocimiento/>

- [2] A. Kapoor, S. I. Bhat, S. Shidnal, and A. Mehra, “Implementation of IoT (Internet of Things) and Image processing in smart agriculture”, in 2016 International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS), Bengaluru, India, pp. 21–26, 2016. <https://doi.org/10.1109/CSITSS.2016.7779434>
- [3] J. Zhou, D. Xiao, and M. Zhang, “Feature Correlation Loss in Convolutional Neural Networks for Image Classification”, in 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), Chengdu, China, pp. 219–223, 2019. <https://doi.org/10.1109/ITNEC.2019.8729534>
- [4] T. Treebupachatsakul and S. Poomrittigul, “Bacteria Classification using Image Processing and Deep learning”, in 2019 34th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC), JeJu, Korea (South), pp. 1–3, 2019. <https://doi.org/10.1109/ITC-CSCC.2019.8793320>
- [5] S. Dutta Gupta and A. K. Pattanayak, “Intelligent image analysis (IIA) using artificial neural network (ANN) for non-invasive estimation of chlorophyll content in micropropagated plants of potato”, *Vitro Cell. Dev. Biol. - Plant*, vol. 53, no. 6, pp. 520–526, 2017. <https://doi.org/10.1007/s11627-017-9825-6>
- [6] A. M. Moreno-Jiménez, S. Loza-Cornejo, and M. Ortiz-Morales, “Efecto de luz LED sobre semillas de *Capsicum annuum* L. var. serrano”, vol. 17, no. 3, p. 7, 2017.
- [7] A. Rojas, “Flora Urbana Del Área Metropolitana De Bucaramanga”, *Innovaciencia Fac. Cienc. Exactas Físicas Nat.*, vol. 5, no. 1, 2017. <https://doi.org/10.15649/2346075X.454>
- [8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, in *Advances in Neural Information Processing Systems 25*, F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, Eds. Curran Associates, Inc., 2012, pp. 1097–1105.