



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
"Análisis comparativo de imágenes normales versus
IRF, para detectar deshidratación en plantas usando
redes neuronales"

POR

ING. Noel Rodríguez Martínez


T E S I S

PRESENTADO COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE MAESTRO
EN CIENCIAS EN INGENIERÍA ELÉCTRICA

DIRECTOR DE TESIS

M.C. Martín Gerardo Vázquez Rueda

ISSN: 0188-9060



RIITEC: (20)-TMCIE-2019

Torreón, Coahuila. México

Noviembre 2019

Instituto Tecnológico de La Laguna

RESUMEN

En este trabajo se realizó un análisis comparativo entre dos sistemas de detección de deshidratación en plantas, uno basado en segmentación K-means y el otro basado en el índice de vegetación diferencial normalizado o mejor conocido por sus siglas en inglés NDVI, usando redes neuronales para correlacionarlos y darle validez a los datos que se obtienen del primer método.

Para el desarrollo del experimento se llevaron a cabo 5 periodos de prueba con diferentes metodologías, los cuales duraron de 10 a 14 días en un lapso de los 8 meses, se muestran los resultados de la última prueba. En los periodos de prueba se tomaron fotos 3 veces al día a 3 plantas de albahaca (*Ocimum Basilicum*) las cuales fueron regadas con 60, 30 y 10 ml de agua diarios.

Las tomas se realizaron con una cámara web RGB Microsoft LifeCam HD-6000 para notebook para el método de segmentación de imágenes K-means y una cámara RGB-NIR See3CAM_CU40 para la determinación del índice NDVI.

Se concluye en base al experimento realizado que se pueden correlacionar las respuestas del método de k-means y NDVI si se usa una de las operaciones con mejor promedio de desempeño entre las correlaciones procesadas con la red neuronal backpropagation con 10 neuronas en su capa intermedia y una en la salida. La mejor tuvo un buen promedio de desempeño de $1.86E-04$ con lo que se valida la correlación entre los índices con cámaras RGB y el índice NDVI.

ABSTRACT

In this work, a comparative analysis was carried out between two dehydration detection systems in plants, one based on K-means segmentation and the other based on the Normalized Differential Vegetation Index or better known by its acronym NDVI, using neural networks to correlate them and validate the data obtained from the first method.

For the development of the experiment, 5 test periods were carried out with different methodologies, which lasted from 10 to 14 days over a period of 8 months, the results of the latest test are shown. During the test periods, photos were taken 3 times a day at 3 basil plants (*Ocimum Basilicum*), which were watered with 60, 30 and 10 ml of water daily.

The shots were taken with a Microsoft LifeCam HD-6000 RGB webcam for the K-means image segmentation method and a See3CAM_CU40 RGB-NIR camera for NDVI index determination.

It is concluded based on the experiment carried out that the responses of the k-means and NDVI methods can be correlated if one of the operations with the best average performance among the correlations processed with the backpropagation neural network with 10 neurons in its intermediate layer and one in the exit is used. The best had a good performance average of $1.86E-04$, which validates the correlation between the indexes with RGB cameras and the NDVI index.

Índice general

1	Introducción	1
1.1	Planteamiento del problema	3
1.2	Objetivos.....	3
1.2.1	Objetivo general.....	3
1.2.2	Objetivos específicos.....	3
1.2.3	Justificación.....	4
1.3	Estructura de la tesis.....	5
2	Estrés por déficit hídrico	6
2.1	Comportamiento espectral de las plantas ante el estrés por déficit hídrico	7
2.2	Albahaca	8
3	Estación de trabajo	12
3.1	Sensibilidad espectral de las cámaras de visión artificial	13
3.2	Procesamiento de imágenes	15
3.3	Desarrollo experimental	16
4	Segmentación K-means	21
5	Índice de Vegetación Diferencial Normalizado (NDVI)	36
5.1	Espectro Infrarrojo cercano	36
5.2	Índices de vegetación espectrales.....	36
5.3	Índice de vegetación diferencial normalizado.....	36
6	Neurona Artificial	49
6.1	Perceptrón	49
6.2	Retro propagación	50
7	Resultados	56
	Discusión de resultados y conclusiones	69
	Trabajo a futuro	70
	Bibliografía	71

Índice de figuras

Figura 2.1 Comportamiento de la luz reflejada en diferentes estados de una hoja.....	8
Figura 2.2 Ocimum basilicum var. thyrsoiflora.....	9
Figura 2.3 Ocimum basilicum.	10
Figura 2.4 Ocimum tenuiflorum.	10
Figura 2.5 Ocimum minimum.	11
Figura 3.1 Vista frontal de la estación de trabajo.....	13
Figura 3.2 Vista superior de la estación de trabajo.	13
Figura 3.3 Diagrama normalizado de respuesta espectral de distintas cámaras y del ojo humano.....	14
Figura 3.4 Imagen delantera de la cámara See3CAM_CU40.....	17
Figura 3.5 Imagen posterior de la cámara See3CAM_CU40.	18
Figura 3.6 Componentes rojo, verde y azul de las 3 plantas.	19
Figura 3.7 Foto de la planta 1 y sus componentes rojo, verde y azul.	20
Figura 3.8 Imagen con luz fluorescente encendida.	21
Figura 3.9 Imagen con luz fluorescente apagada.	21
Figura 4.1 Objetos en el agrupamiento 1.....	25
Figura 4.2 Objetos en el agrupamiento 2.....	25
Figura 4.3 Objetos en el agrupamiento 3.....	26
Figura 4.4 Núcleos azules.	26
Figura 4.5 Diagrama de bloques para el procesamiento de imágenes.....	27
Figura 4.6 Imágenes de muestra de las hojas infectadas.....	27
Figura 4.7 Diagrama de flujo del algoritmo de umbralización.	28
Figura 4.8 Diagrama de flujo del algoritmo de agrupación K-means.....	29
Figura 4.9 Resultados del algoritmo de umbralización.....	30
Figura 4.10 Resultados de los pasos del algoritmo de agrupación K-means.....	31
Figura 4.11 Una hoja de la planta que ha sido infectada con la enfermedad.....	33
Figura 4.12 Imagen RGB a $L^*a^*b^*$	33
Figura 4.13 Máscara verde.....	33
Figura 4.14 Agrupamiento 1.....	33
Figura 4.15 Imagen HSI.....	33
Figura 4.16 Foto de la planta 1 tomada con la cámara Microsoft LifeCam HD-6000.....	35
Figura 4.17 Imagen procesada por segmentación K-Means.	35
Figura 5.1 Relaciones entre la biomasa sobre el suelo y los índices normalizados de vegetación derivados del sensor GreenSeeker y el sensor Circle ACS-430 en las 3 etapas de crecimiento.....	39
Figura 5.2 RGB (izquierda), Cercano infrarrojo (centro), NDVI (derecha).....	42
Figura 5.3 Resultados de los datos de NDVI.....	43
Figura 5.4 Foto RGB tomada de la planta 1.....	46
Figura 5.5 Foto NIR tomada de la planta 1.....	46
Figura 5.6 Resultado NDVI de la planta 1.....	46
Figura 5.7 Foto RGB tomada de la planta 2.....	47

Figura 5.8 Foto NIR tomada de la planta 2.....	47
Figura 5.9 Resultado NDVI de la planta 2.....	47
Figura 5.10 Foto RGB tomada de la planta 3.....	48
Figura 5.11 Foto NIR tomada de la planta 3.....	48
Figura 5.12 Resultado NDVI de la planta 3.....	48
Figura 6.1 Gráfica de los grupos de datos.....	53
Figura 6.2 Visualización a bloques de la red neuronal.....	53
Figura 6.3 Comparación entre respuesta real y respuesta esperada.....	54
Figura 6.4 Clasificación de grupos por región.....	54
Figura 6.5 Red neuronal con 1 entrada, una salida y 2 capas intermedias de 10 neuronas y 1 neurona respectivamente.....	55
Figura 7.1 Gráfica Ec. 5.1 vs Ec. 4.4 vs red neuronal de la planta 1.....	64
Figura 7.2 Gráfica Ec. 5.1 vs Ec. 4.4 vs red neuronal de la planta 2.....	64
Figura 7.3 Gráfica Ec. 5.1 vs Ec. 4.4 vs red neuronal de la planta 3.....	64
Figura 7.4 Gráfica Ec. 5.1 vs Ec. 4.3 vs red neuronal de la planta 1.....	65
Figura 7.5 Gráfica Ec. 5.1 vs Ec. 4.3 vs red neuronal de la planta 2.....	65
Figura 7.6 Gráfica Ec. 5.1 vs Ec. 4.3 vs red neuronal de la planta 3.....	65
Figura 7.7 Gráfica Ec. 5.1 vs Ec. 4.5 vs red neuronal de la planta 1.....	66
Figura 7.8 Gráfica Ec. 5.1 vs Ec. 4.5 vs red neuronal de la planta 2.....	66
Figura 7.9 Gráfica Ec. 5.1 vs Ec. 4.5 vs red neuronal de la planta 3.....	66
Figura 7.10 Gráfica Ec. 5.1 vs Ec. 4.6 vs red neuronal de la planta 1.....	67
Figura 7.11 Gráfica Ec. 5.1 vs Ec. 4.6 vs red neuronal de la planta 2.....	67
Figura 7.12 Gráfica Ec. 5.1 vs Ec. 4.6 vs red neuronal de la planta 3.....	67

Índice de tablas

Tabla 3.1 Mediciones en la estación de trabajo con luxómetro.....	20
Tabla 4.1 Muestras del proceso de segmentación de K-means.	23
Tabla 5.1 Índices espectrales de vegetación	38
Tabla 5.2 Coeficientes de determinación (R^2) para las relaciones entre índices de vegetación (derivados del sensor GreenSeeker y calculados del sensor Circle ACS-430) y la biomasa sobre el suelo en diferentes etapas de crecimiento.	39
Tabla 5.3 Resultados de validación de evaluación con índices de vegetación (derivados por GreenSeeker y calculados de Crop Circle ACS-430) para estimar los datos de biomasa sobre el suelo del experimento de validación a diferentes etapas de crecimiento.	40
Tabla 5.4 División de objetos vasados en NDVI.....	41
Tabla 5.5 Muestras de valores de NDVI	44
Tabla 7.1 Datos obtenidos con el proceso de segmentación K-means.....	56
Tabla 7.2 Datos obtenidos con el proceso de cálculo Ec 5.1.....	57
Tabla 7.3 Datos calculados con la operación Ec.4.4.	57
Tabla 7.4 Datos calculados con la operación Ec. 4.3.....	57
Tabla 7.5 Datos calculados con la operación Ec. 4.5.....	57
Tabla 7.6 Datos calculados con la operación Ec. 4.6.....	57
Tabla 7.7 Proceso NDVI del día 1 (2019/10/04).	59
Tabla 7.8 Proceso NDVI del día 7 (2019/10/10).	60
Tabla 7.9 Proceso K-means del día 1 (2019/10/04).....	60
Tabla 7.10 Proceso K-means del día 7 (2019/10/10).....	62
Tabla 7.11 Características del entrenamiento de las redes neuronales.	68
Tabla 7.12 Tabla de promedios de desempeño por operación derivada de k-means.....	68
Tabla 7.13 Tabla de promedios de desempeño por planta.....	69

Índice de ecuaciones

Ecuación 4.1	22
Ecuación 4.2	23
Ecuación 4.3	34
Ecuación 4.4	34
Ecuación 4.5	34
Ecuación 4.6	34
Ecuación 5.1	37
Ecuación 6.1	50
Ecuación 6.2	51
Ecuación 6.3	51
Ecuación 6.4	51
Ecuación 6.5	51
Ecuación 6.6	51
Ecuación 6.7	52

1 Introducción

La mayoría de las especies vegetales son sensibles al estrés hídrico y cuando este es muy alto ya sea por exceso o por falta de riego, hay consecuencias que varían desde pequeños cambios bioquímicos y disminución de la productividad hasta la muerte del espécimen.

El promedio mundial de la temperatura ambiental se ha incrementado gradualmente en los últimos 150 años, como consecuencia de la actividad humana y la emisión de gases con efecto invernadero como CO₂, metano, clorofluorocarbonos y óxido nitroso. La tasa de calentamiento global de 1901 al año 2000 se ha estimado en 0.07 °C cada década, y en los últimos cien años, a nivel mundial, se produjo un incremento de las temperaturas mínimas y máximas de 1.86 y 0.88 °C, respectivamente. Se estima que para el año 2025 la temperatura promedio global se incrementará 1 °C, y en 3 °C para el 2100. Se proyecta que los efectos del cambio climático incluirán modificaciones de los ámbitos ecológicos y geográficos donde se distribuyen las plantas, la zonificación agrícola y las épocas de siembra; irregularidades que representan amenazas potenciales para la producción agrícola y que cambiarán las prioridades actuales del mejoramiento genético, en especial en las regiones tropicales cálidas, donde la temperatura es un factor determinante en el rendimiento de los cultivos. Por estas razones, la respuesta de las plantas al incremento en la temperatura ambiental y a la sequía ha alcanzado las agendas sociales y políticas del mundo, porque el suministro sostenible de alimentos es crucial para la seguridad alimentaria de las sociedades. [1]

El sector agropecuario es la principal actividad económica de la región lagunera, existen alrededor de 38000 productores tanto del sector privado como ejidal. Este sector es el mayor consumidor de agua y productor de insumos para la industrialización de lácteos y otros productos agropecuarios, además de forrajes para mantener el ganado, producción de algodón, hortalizas y frutas.

Además de la actividad agropecuaria, existen el sector agroindustrial y el textil, que también han aumentado la demanda de agua en la zona urbana. A esto se añade que la región de la Comarca es una zona árida con clima muy seco y escasa precipitación.

De acuerdo con la Conagua en el documento “Disponibilidad de Acuíferos” publicado en 2015, la recarga anual del acuífero principal es de 518.9 millones de metros cúbicos al año y la extracción total es de 1,221.8 millones de metros cúbicos al año, de los cuales 1,045.2 corresponden a uso agrícola, 127.8 a uso urbano y 23.1 a uso industrial.

Existe un déficit muy considerable y ya no hay volumen de agua disponible para una mayor extracción. Todo esto ha ocasionado una tendencia hacia el abatimiento del nivel del agua subterránea, con el riesgo de que se incremente cada vez su deterioro. [2]

La pérdida de eficiencia en los cultivos debido al cambio del promedio mundial de la temperatura ambiental y el estrés hídrico sumado a la necesidad de alimentos para mantener a la creciente población mundial ha hecho que la gente busque maneras de tener control sobre estos problemas. [3]

Para mejorar la eficiencia de producción de los cultivos y agua consumida se han ideado muchos métodos para detectar deshidratación entre los cuales destacan los que usan imágenes y sus componentes o espectros visuales para calcular índices y con ellos saber el estado de la planta.

Los métodos que se compararán y aproximarán en este estudio son los siguientes:

El primero es la detección de deshidratación en plantas usando el espectro cercano infrarrojo (NIR) es preciso debido a la respuesta de las plantas a dicho espectro, sin embargo, las cámaras que captan esta región del espectro de la luz tienen un precio elevado.

El segundo método a La detección de deshidratación en plantas con imágenes tomadas con cámaras fotográficas digitales se basa en algoritmos para procesamiento de imagen por medio de segmentación por K-means en el formato RGB, su precisión está por debajo de los otros métodos, pero el costo y disponibilidad de una cámara fotográfica digital son más accesibles para el público en general.

Los métodos mencionados anteriormente tienen sus ventajas y desventajas, pero su accesibilidad a los agricultores se ve reducida cuanto más preciso sea el equipo de medición. Por lo tanto, se requiere de un sistema que use cámaras fotográficas digitales que compita con la precisión de los métodos más efectivos como el cercano infrarrojo.

El proyecto se desarrolló en el departamento de Posgrado de Ingeniería Eléctrica del Instituto Nacional de México, Instituto Tecnológico de La Laguna, ubicado en el Blvd. Revolución y Calzada Instituto Tecnológico de la Laguna s/n, en la ciudad de Torreón, Coahuila. Este proyecto inició en enero del 2018 y concluyó en noviembre del 2019.

1.1 Planteamiento del problema

Debido al cambio climático se predice una reducción total del 10% en la producción del maíz en el año 2055 en América Latina, equivalente a pérdidas de \$2 mil millones por año, afectando principalmente a 40 millones de agricultores en diferentes zonas de América Latina. Estas pérdidas de la producción se intensificarán de acuerdo al incremento en las temperaturas y las diferencias en la precipitación lo cual conducirá a una menor producción. Se predice que los efectos sobre el bienestar de las familias de agricultores de subsistencia serán muy severos, especialmente si el componente de la productividad de subsistencia se reduce. Estos cambios en la calidad y la cantidad de producción pueden afectar la productividad del trabajo de los agricultores e incluso afectar negativamente la salud de sus familias. [4]

Para tratar de reducir el impacto del estrés hídrico se requieren métodos que puedan dar más control sobre este fenómeno e incrementar la eficiencia en la cantidad de producto de los cultivos sin ser intrusivos.

Existe una gran variedad de métodos para detectar el impacto del estrés hídrico en los cultivos entre los cuales se tienen los que utilizan procesamiento de imágenes para calcular índices. El índice NDVI es el más conocido entre estos y su efectividad para detectar vegetación es ampliamente reconocida, existen varios sistemas comerciales que utilizan este índice llamados sistemas de agricultura de precisión.

El problema a resolver es comparar y obtener una correlación usando redes neuronales entre el índice NDVI y los datos obtenidos con la segmentación K-means y así validarlo.

1.2 Objetivos

1.2.1 Objetivo general

Realizar un análisis comparativo del método de segmentación de imágenes RGB con k-means contra el método de detección de deshidratación por medio del índice NDVI y aproximar sus comportamientos usando redes neuronales para validar la segmentación k-means como método de detección de deshidratación en plantas.

1.2.2 Objetivos específicos

- Aplicar procesamiento digital de imágenes RGB por medio de la segmentación K-means.

- Aplicar procesamiento digital de imágenes IRF para obtener el índice de vegetación diferencial normalizada
- Aplicar redes neuronales para aproximar los métodos mencionados.
- Lograr una mejora tecnológica, a bajo costo, que ayude a tomar medidas contra el estrés hídrico en los cultivos.
- Lograr una titulación de Maestría en Ciencias de Ingeniería Eléctrica.

1.2.3 Justificación

Las condiciones en que se desarrolla la agricultura en México, tanto de temporal como de riego, determinan también su vulnerabilidad ante eventos climáticos extremos. En particular, las prácticas agrícolas de temporal son sensibles a cualquier alteración en la precipitación estacional. Desde la época de la colonia, el fenómeno de El Niño es un evento climático extremo que ha tenido presencia constante, y al que se le atribuyen la mayoría de las sequías de verano causantes de cuantiosas pérdidas en la producción agrícola. Durante El Niño de 1997 y 1998, la precipitación se redujo al 50%, lo que ocasionó una pérdida del 14% a la producción, estimada en cerca de 2,000 millones de dólares. [5]

Para reducir las pérdidas de producción por estrés hídrico se han ideado métodos entre los cuales destacan los que hacen uso de índices de vegetación basados en imágenes con cámaras especializadas que captan diferentes espectros de luz, para detectar el estado de la planta y por medio de un rango saber cuándo proporcionar agua a las plantas, el más conocido es el índice de vegetación diferencial normalizada (NDVI) el cual utiliza el espectro rojo e infrarrojo de las imágenes debido a la respuesta de la vegetación a estos espectros.

En contraste, los pocos sistemas que usan imágenes RGB con cámaras comunes y más específicamente los que usan un sistema de segmentación por medio de k-means dan área total de la planta además de porcentajes de vegetación saludable y no saludable sin embargo no indican directamente la deshidratación, además se encuentran muy poco estandarizados por lo que se pretende desarrollar un método en el cual se correlacionen y aproximen los métodos mencionados.

1.3 Estructura de la tesis

El capítulo 2 muestra la definición general del estrés hídrico y cómo reaccionan las plantas a los rangos espectrales. También se presenta la planta que se usa como objeto de estudio y sus características.

El capítulo 3 trata sobre la estación de trabajo, las cámaras que se utiliza en la comparación de métodos, sus características espectrales además se explica el programa utilizado para la obtención de imágenes y su preprocesamiento.

El capítulo 4 trata sobre el proceso de segmentación por k-means, se define y se explica su algoritmo base. También muestra antecedentes del proceso aplicado en la agricultura y se mencionan consideraciones previas al proceso de toma de imágenes.

El capítulo 5 contiene definiciones sobre los índices de vegetación espectrales y en específico el índice de vegetación diferencial normalizado además de su fórmula y la programación necesaria para realizar el procesamiento de la imagen. También muestra antecedentes del proceso.

El capítulo 6 trata sobre las redes neuronales, su definición y la estructura de aprendizaje que se usa en este estudio, incluye un ejemplo aplicado a agrupación en Matlab.

El capítulo 7 muestra las imágenes antes y después de los procesamientos a los que fueron sometidas, los resultados de los índices obtenidos de los 2 métodos de detección de deshidratación en plantas y se realiza una aproximación de las respuestas por medio de una red neuronal.

Por último, se discuten los resultados y se presentan las conclusiones, además se hace mención de posibles trabajos a futuro.

2 Estrés por déficit hídrico

La sequía, escasez de agua disponible o estrés por déficit hídrico en el medio es uno de los principales inconvenientes a los que pueden tener que enfrentarse los seres vivos. Conocer el efecto fisiológico que la sequía produce en la planta es esencial para un buen desarrollo del césped o cultivo. En climas áridos o semiáridos la falta de agua es el principal factor limitante del crecimiento tanto en plantas C3 como C4. Las plantas C3 se llaman así porque el bióxido de carbono primero se incorpora en un compuesto de 3 carbonos y mantiene las estomas abiertas durante el día. Aquí la fotosíntesis se lleva a cabo a través de la hoja. Las plantas C4 se llaman así porque el CO₂ primero es incorporado a un compuesto de carbono- 4; se lleva a cabo en las células internas y mantiene las estomas abiertas durante el día, requiere de una anatomía especializada llamada "Anatomía de Kranz". Es más rápida que la C3 bajo altas condiciones de luz y temperatura ya que el CO₂ es transportado directamente a la enzima RuBisCo impidiendo que tome oxígeno y por lo tanto que pase por la foto respiración.

La cantidad de agua que contiene la planta es el resultado del balance interno entre el agua absorbida por las raíces y el agua que se pierde por transpiración. La mayor parte del agua absorbida es transportada a las hojas y se pierde por transpiración, tan sólo entre un 1-3% pasa al metabolismo de las plantas.

El estrés hídrico afecta a la mayor parte de las funciones vitales de la planta, de modo que prácticamente no hay ningún proceso fisiológico que no esté afectado por el mismo. Los cambios fisiológicos más significativos son:

- Reducción del crecimiento. Este efecto aparece mucho antes que los promovidos a través de mecanismos bioquímicos, fisiológicos y genéticos. La disminución del crecimiento se debe a una pérdida de turgencia (proceso físico). A medida que va disminuyendo el contenido hídrico de la planta lo hace también el de las propias células, de modo que disminuye el volumen celular y la turgencia de la célula. La pared celular se vuelve inflexible, limitando así el crecimiento y desarrollo.
- Cierre de las estomas de las hojas para evitar la pérdida de agua. Esta respuesta está desencadenada por el ácido abscísico (ABA), una hormona vegetal que se

produce principalmente en los tejidos vasculares. Cuando el tejido vascular deja de recibir agua de las raíces activa el ABA de su citoplasma, que viajará hasta las hojas estimulando el cierre estomático.

- La actividad fotosintética disminuye o se detiene. Debido al cierre de las estomas, el intercambio gaseoso en las hojas disminuye y la captación de CO₂ se ve imposibilitada. Al detenerse la fotosíntesis la planta deja de generar energía, la producción de azúcares queda en pausa y como consecuencia la planta detiene su metabolismo.
- Los nutrientes y minerales son absorbidos por la planta, disueltos en el agua y translocados a las hojas. Al cerrarse las estomas la absorción de agua se ralentiza, pudiendo llegar a detenerse. La falta de minerales en las hojas puede causar clorosis debido entre otras cosas a la degradación de clorofila en las hojas. [6]

2.1 Comportamiento espectral de las plantas ante el estrés por déficit hídrico

En el espectro visible (400–700 nm), la reflectancia de la hoja es baja debido a la absorción por los pigmentos fotosintéticos (principalmente clorofilas y carotenoides). Cuando la planta se encuentra sana absorbe el componente rojo y azul de la luz, pero el verde es reflejado y por eso es que vemos la hoja de color verde. Cuando la planta esta estresada o enferma empieza a bajar la reflectancia del componente verde. En el dominio del infrarrojo cercano (700–1300 nm), donde no hay características de absorción fuertes, la magnitud de la reflectancia se rige por las discontinuidades estructurales encontradas en la hoja. El componente infrarrojo cercano es más sensible al estrés de las hojas como se muestra en la figura 2.1. [7]




Figura 2.1 Comportamiento de la luz reflejada en diferentes estados de una hoja

Recuperado de: Genik W. 2016 What is NDVI? <https://www.greenaerotech.com/what-is-ndvi/> [33]

2.2 Albahaca

Ocimum basilicum denominada popularmente como albahaca o alhábega, es una hierba aromática anual de la familia de las lamiáceas nativa de Irán, India, Pakistán y otras regiones tropicales de Asia.[8]

Es una hierba de crecimiento bajo, de entre los 30 y 60 cm de alto con hojas ovales, dentadas, de textura sedosa y con un verde lustroso que miden de 3 a 11 cm de largo por 1 a 6 cm de ancho. Emite espigas florales tubulares de color blanco y se eliminan comúnmente al desarrollarse la planta.

La albahaca es muy sensible a las heladas y por lo tanto deben ser protegidas de temperaturas cercanas a las de congelación. Se cultivan únicamente por semillas, que se pueden sembrar en semilleros o en macetas en un invernadero. La albahaca prefiere climas de primavera o verano, preferentemente a sol directo, aunque en climas de veranos muy calurosos se recomienda algo de sombra. Para evitar enfermedades de marchitamiento fúngico o “damping off” no se debe sobrepasar en la cantidad de agua suministrada a la albahaca. Los suelos deben ser fértiles, permeables y húmedos. En inviernos la albahaca debe ser cultivada en ambientes cerrados y controlados. [9]

Dentro de la especie más común se encuentran multitud de variedades, cultivares e híbridos, con algunas características que los diferencian entre ellos y muchas comunes con la albahaca dulce.

A continuación, se describe brevemente algunos tipos de albahacas.

- **Albahaca tailandesa:** Conocida también como albahaca Reina de Siam, su nombre científico es *Ocimum basilicum* var. *thyrsoiflora*, es decir, se trata de una variedad de la albahaca dulce que no suele sobrepasar los 45 cm de altura. Es originaria del sudeste asiático y tiene fundamentalmente un uso culinario, formando parte de muchos platos de gastronomía local. Su sabor recuerda al del anís, con un toque del regaliz, sus hojas son verdes y delgadas, y su tallo de color morado. En la figura 2.1 se muestra una foto de este tipo de albahaca.



Figura 2.2 *Ocimum basilicum* var. *thyrsoiflora*.

Recuperado de: Amigo A., 2015, Tipos de albahaca, <https://www.mundohuerto.com/cultivos/albahaca/tipos>

- **Albahaca común:** Se trata de la especie *Ocimum basilicum*, y es conocida también como albahaca dulce o simplemente albahaca, y se cultiva en todo el mundo. Es originaria del sur de Asia y muy empleada desde antiguo en alimentación, rituales y como hierba medicinal. Existen diferentes variedades dentro de esta misma especie, algunas de las cuáles veremos más abajo. En la figura 2.2 se muestra una foto de la albahaca común.



Figura 2.3 *Ocimum basilicum*.

Recuperado de: Amigo A., 2015, *Tipos de albahaca*, <https://www.mundohuerto.com/cultivos/albahaca/tipos>

- Albahaca morada: Es la especie *Ocimum tenuiflorum*, expresada también como *Ocimum sanctum*, y que además recibe los nombres de albahaca cimarrona, albahaca sagrada y albahaca morada criolla. Su origen parece localizarse también en el sur del continente asiático, pero hoy en día se puede encontrar en casi todo el mundo como planta cultivada. Puede alcanzar hasta 1 metro de altura y sus hojas son de color morado siempre que se desarrolle a pleno sol, sino tenderán a ser verdes. En la misma planta se pueden encontrar hojas de ambos colores. Se empleó desde la antigüedad —y hasta el presente— en aplicaciones culinarias, medicinales y religiosas. Tiene un sabor picante y se usa mucho en la cocina tailandesa. En la figura 2.3 se puede apreciar una planta de albahaca morada.



Figura 2.4 *Ocimum tenuiflorum*.

Recuperado de: Amigo A., 2015, *Tipos de albahaca*, <https://www.mundohuerto.com/cultivos/albahaca/tipos>

- Albahaca fina: Se trata de *Ocimum minimum* —expresada también como *Ocimum basilicum* '*Minimum*'— y es una albahaca reducido tamaño y hoja pequeña. Al igual que la mayoría de las especies y variedades de albahaca, su origen se sitúa en el sur de Asia, y se utiliza por sus propiedades aromáticas y medicinales.



Figura 2.5 *Ocimum minimum*.

Recuperado de: Amigo A., 2015, Tipos de albahaca, <https://www.mundohuerto.com/cultivos/albahaca/tipos>

Este tipo de albahaca es muy apropiado para cultivar en maceta, ya que es de tamaño pequeño y forma una copa redondeada y compacta muy decorativa, es por esta razón que fue elegida como el objeto de estudio. [10]

Algunos de los estudios eco fisiológicos de la albahaca relacionados al estrés hídrico publicados se muestran a continuación.

Khalid (2006) realizó un trabajo cuyo objetivo fue establecer la influencia del estrés hídrico sobre el crecimiento vegetativo, la producción de aceites esenciales, prolina, carbohidratos totales y contenidos de N, P, K y proteínas en las especies *Ocimum basilicum* L. y *Ocimum americanum* L. El experimento fue realizado durante los años 2004 y 2005 en una granja experimental del National Research Center (NRC), en la ciudad de Giza - Egipto.

Los tratamientos empleados fueron: T1: 50%; T2: 75%; T3: 100% y T4: 125% de la capacidad de campo del suelo empleado. Se estableció que para ambas especies se presentaron diferencias significativas bajo condiciones de estrés hídrico para las variables evaluadas, siendo mayores los contenidos de prolina, carbohidratos y porcentaje de aceites esenciales, y menores los contenidos de N, P, K y proteína. El tratamiento de 75% de la capacidad de campo del sustrato produjo los mejores resultados en producción de materia fresca y aceites esenciales para ambas especies. [11]

Barrozo y Jerez (2002) realizaron un trabajo cuyo objetivo fue conocer que fase del desarrollo de la albahaca resulta más afectada por una deficiencia hídrica y las alteraciones que se producen en el crecimiento y las relaciones hídricas de las plantas en estas condiciones. Los tratamientos consistieron en variar las cantidades de agua aplicada durante el ciclo de cultivo en las siguientes fases: 0-30 días, 30-50 días y 50-75 días (cosecha). Se determinaron los consumos de agua por fase y en total y se realizaron

evaluaciones de crecimiento en altura, biomasa y estado hídrico de las plantas. Las respuestas en cada una de las fases permitieron definir que la primera fase fue la más susceptible para la planta, provocando reducciones importantes en la altura, la producción de masa seca, el potencial hídrico foliar y la conductancia estomática. Durante esta fase se presentaron los menores consumos de agua mientras que los más altos se presentaron durante la segunda fase (30-50 días después de siembra). [12]

3 Estación de trabajo

Para llevar a cabo la comparación se implementó una estación de trabajo consta de una base móvil la cual mantiene a las cámaras que se usaran en los dos métodos de detección de deshidratación a comparar con una vista en la parte superior en dirección al suelo. Se marcaron seis posiciones teniendo en cuenta la posición y las dimensiones de las plantas para que se obtenga una vista optima de la copa de las mismas con ambas cámaras. Para iluminar la estación de trabajo se utilizaron 2 lámparas fluorescentes compactas de 26 watts. En las Figuras 3.1 y 3.2 se puede apreciar la vista frontal y superior de la estacion de trabajo.



Figura 3.1 Vista frontal de la estación de trabajo.



Figura 3.2 Vista superior de la estación de trabajo.

En este capítulo se dará a conocer los componentes usados en la estación de trabajo y los algoritmos utilizados para el pre-procesamiento de las imágenes obtenidas empezando por la teoría básica, seguido del desarrollo experimental.

3.1 Sensibilidad espectral de las cámaras de visión artificial

Las funciones de sensibilidad espectral de las cámaras de visión artificial relacionan la luminosidad de la escena con los tripletes RGB capturados. Son importantes para muchas tareas de visión por computadora que usan información de color, como imágenes multiespectrales, reproducción de color y constancia de color. [13]

El ojo humano tiene un rango de respuesta de aproximadamente 400 a 700 nm. La mayoría de las aplicaciones de visión artificial usan este mismo rango, pero cuando se requiere detectar más del espectro de luz se usan cámaras especiales o modificadas.

Muchas de las cámaras usadas para detectar el rango de cercano infrarrojo tienen un sensor tipo CCD o tipo CMOS y detectan desde los 700 y 1000 nm. Si bien las cámaras comerciales comunes pueden detectar el cercano infrarrojo si se les extrae el filtro infrarrojo, no son tan sensibles como una cámara específica para el trabajo. En la figura 3.3 se puede observar la respuesta de distintas cámaras.

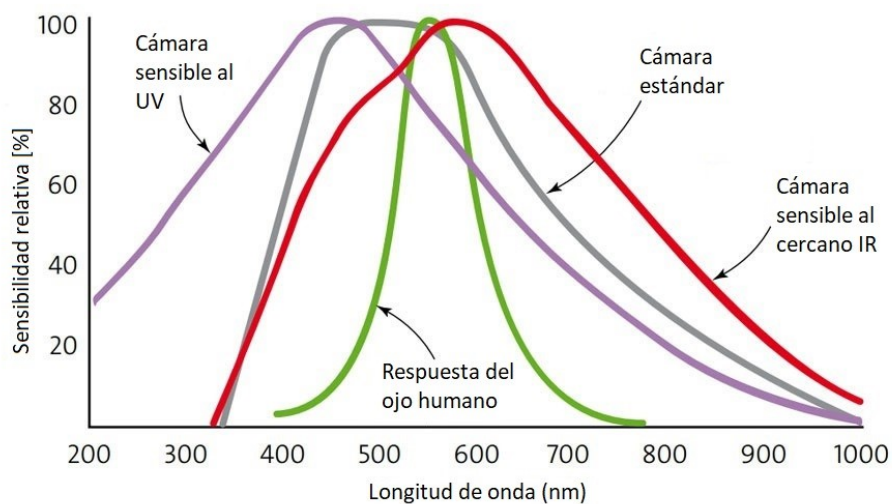


Figura 3.3 Diagrama normalizado de respuesta espectral de distintas cámaras y del ojo humano. Modificado de: J. Jiang et al., 2013, "What is the space of spectral sensitivity functions for digital color cameras?"

Una webcam es una videocámara digital que capta imágenes o video en tiempo real y puede enviar los datos a través de una computadora al internet. En este caso los datos serán transmitidos a la computadora en la cual se realizará el procesamiento de imágenes por medio del programa MATLAB. [14]

Las cámaras web normalmente están formadas por una lente, un sensor de imagen y la circuitería necesaria para manejarlos. Existen distintos tipos de lentes, siendo las lentes plásticas las más comunes. Los sensores de imagen pueden ser CCD (charge coupled device) o CMOS (complementary metal oxide semiconductor). Este último suele ser el habitual en cámaras de bajo coste, aunque eso no signifique necesariamente que cualquier cámara CCD sea mejor que cualquiera CMOS.

Las cámaras web para usuarios medios suelen ofrecer una resolución VGA (640x480) con una tasa de unos 30 fotogramas por segundo, si bien en la actualidad están ofreciendo resoluciones medias de 1 a 1.3 MP, actualmente las cámaras de gama alta cuentan con 3, 5, 8, 10 y hasta 15 megapíxeles y son de alta definición.

La circuitería electrónica es la encargada de leer la imagen del sensor y transmitirla a la computadora. [15]

Los fotodetectores en CCD y CMOS tiene un amplio rango de sensibilidad espectral, desde UV hasta NIR. Para el sensor con matriz de filtros de color rojo, verde y azul (CFA) convencional, la luz NIR a menudo degrada la calidad de la imagen, por lo tanto, una ventana con revestimiento de paso bajo a menudo se usa para bloquear la luz NIR. Incluso la ventana del sensor no bloquea la información NIR, es imposible extraer información NIR del sensor convencional con RGB CFA.

La cámara RGB-NIR se puede usar en muchas aplicaciones que requieren solo algunas bandas espectrales en lo visible y NIR, como visión por computadora, vigilancia digital, diagnóstico médico, mejora de retratos, eliminación de sombras, y mejora de visibilidad de las venas entre otras. [16]

3.2 Procesamiento de imágenes

El procesamiento de imágenes es un método para realizar algunas operaciones en una imagen, con el fin de obtener una imagen mejorada o extraer algo de información útil de ella. Es un tipo de procesamiento de señal en el cual la entrada es una imagen y la salida puede ser una imagen o características / características asociadas con esa imagen. Hoy en día, el procesamiento de imágenes se encuentra entre las tecnologías de rápido crecimiento. Forma el área central de investigación dentro de las disciplinas de ingeniería e informática.

El procesamiento de imágenes básicamente incluye los siguientes tres pasos:

- Importación de la imagen a través de herramientas de adquisición de imágenes;
- Se analiza y manipula la imagen;
- Salida en la que el resultado puede ser una imagen alterada o un informe que se basa en el análisis de imagen.

Hay dos tipos de métodos utilizados para el procesamiento de imágenes, el procesamiento de imágenes analógicas y digitales. El procesamiento de imágenes analógicas se puede usar para las copias impresas, como impresiones y fotografías. Los

analistas de imágenes usan varios fundamentos de interpretación mientras usan estas técnicas visuales. Las técnicas de procesamiento digital de imágenes ayudan en la manipulación de las imágenes digitales mediante el uso de computadoras. Las tres fases generales a las que deben someterse todos los tipos de datos durante el uso de la técnica digital son preprocesamiento, mejora y visualización, extracción de información. [17]

3.3 Desarrollo experimental

Para el desarrollo del experimento se llevaron a cabo 5 periodos de prueba con diferentes metodologías, los cuales duraron de 10 a 14 días en un lapso de los 8 meses, se muestran los resultados de la última prueba. En los periodos de prueba se tomaron fotos con ambas cámaras 3 veces al día a 3 plantas de albahaca (*Ocimum Basilicum*) las cuales fueron regadas con 10, 30 y 60 ml de agua diarios.

La cámara que se utilizará en este proyecto para obtener las imágenes a procesar con el método de K-means es una cámara web para notebook Microsoft LifeCam HD-6000. La LifeCam HD-6000 toma fotos en 720p HD a velocidades de hasta 30 cuadros por segundo. Tiene una función de enfoque automático y tiene tecnología de optimización de imagen incorporada además de que puede capturar imágenes fijas en alta definición. [18]

La programación en Matlab usada para tomar las imágenes de la webcam consta de una instrucción “`videoinput`” en la cual se especifica el nombre del adaptador actual de Matlab, en este caso “`winvideo`”, el número del dispositivo y el formato de imagen y resolución que se desea utilizar. Los últimos dos parámetros se pueden ver si se utiliza la instrucción “`imaqtool`” la cual lista los dispositivos conectados a la computadora, sus formatos y resoluciones disponibles. Se utilizó un formato YUY2_640x480 el cual se transforma a RGB con la línea “`set(vid,'ReturnedColorSpace','RGB');`” y finalmente se usa la instrucción “`getsnapshot`” para tomar la imagen.

Las imágenes NIR a procesar necesarias para obtener el índice NDVI fueron tomadas con una cámara See3CAM_CU40 la cual en conjunción con el programa e-CAMView puede hacer transmisión de video y toma de imágenes con resoluciones de 672x380, 1280x720, 1920x1080 y 2688x1520 y los formatos IR data(8bit BMP), RGB data(24bit BMP) y RGB-IR raw data.

Es compatible con todas las funciones de USB actual y retro compatible con 2.0. Sin embargo, en USB 3.0 transmite video sin comprimir de resolución 672 x 380 a 64 fps, 720p17, 1080p9 y 2688x1520 a 4 fps en formato RGB-IR de 10 bits sin procesar. En la figura 3.4 y 3.5 se muestra la parte delantera y trasera de la cámara respectivamente.

La placa de la cámara See3CAM_CU40 tiene un encabezado GPIO de 10 pines que contiene señales que pueden ser utilizadas para requisitos de personalización. También tiene señales serie I2C de reloj y datos además de una luz estroboscópica del sensor.

Esta funcionalidad está integrada en el firmware UVC que se ejecuta en el controlador y en la aplicación de PC de muestra. La descripción de estas señales se muestra a continuación junto con su funcionalidad.

- Pin No: 1, 2 y 3 Fuente de alimentación para circuitos flash externos (a desarrollar por el usuario).
- Pin No: 4,5 Tierra.
- Pin No: 6 I2C Reloj serial.
- Pin No: 7 datos seriales I2C (tanto el reloj como los datos extraídos hasta 1.8V).
- Pin No: 8 Tierra.
- Pin No: 9 Señal para aplicaciones de flash LED.
- Pin No: 10 Sin conexión.



Figura 3.4 Imagen delantera de la cámara See3CAM_CU40.
Recuperado de: e-con Systems, 2019, <https://www.e-consystems.com/OV4682-RGB-IR-USB3-camera.asp>




Figura 3.5 Imagen posterior de la cámara See3CAM_CU40.

Recuperado de: e-con Systems, 2019, <https://www.e-consystems.com/OV4682-RGB-IR-USB3-camera.asp>

Se decidió utilizar la resolución 1280x720 para tener los mejores detalles sin que fuera muy pesada la imagen y los formatos RGB (24bit BMP) e IR (8bit BMP) ya que el archivo RGB-IR de formato raw no fue reconocido en el software de MATLAB. [19]

El pre-procesamiento de imágenes es necesario en el proyecto ya que para la comparación de los dos métodos de detección de deshidratación se requiere una preparación previa de las fotos que se le tomarán a los especímenes utilizados en el experimento.

Para separar los espectros de la imagen RGB se usó la línea de código "imRa1=im2single(x1(:,:,1));" donde "imRa1" es la variable donde se guardará el espectro rojo, im2single convierte a tipo single los datos y x1(:,:,1) separa el espectro rojo. Si se necesitara separar los demás espectros la instrucción sería x1(:,:,2) y x1(:,:,3) para el componente verde y azul respectivamente. En figura 3.6 se muestran los componentes rojo, verde y azul simultáneamente de las 3 plantas en el cuarto día del experimento. A continuación se muestra la sección del programa encargada de separar los espectros:

```
x1 = imread('20191005232830234_1.bmp');  
x2 = imread('20191005232958914_1.bmp');  
x3 = imread('20191005233055584_1.bmp');
```

```
imRa1=im2single(x1(:,:,1));  
imRa2=im2single(x2(:,:,1));  
imRa3=im2single(x3(:,:,1));
```

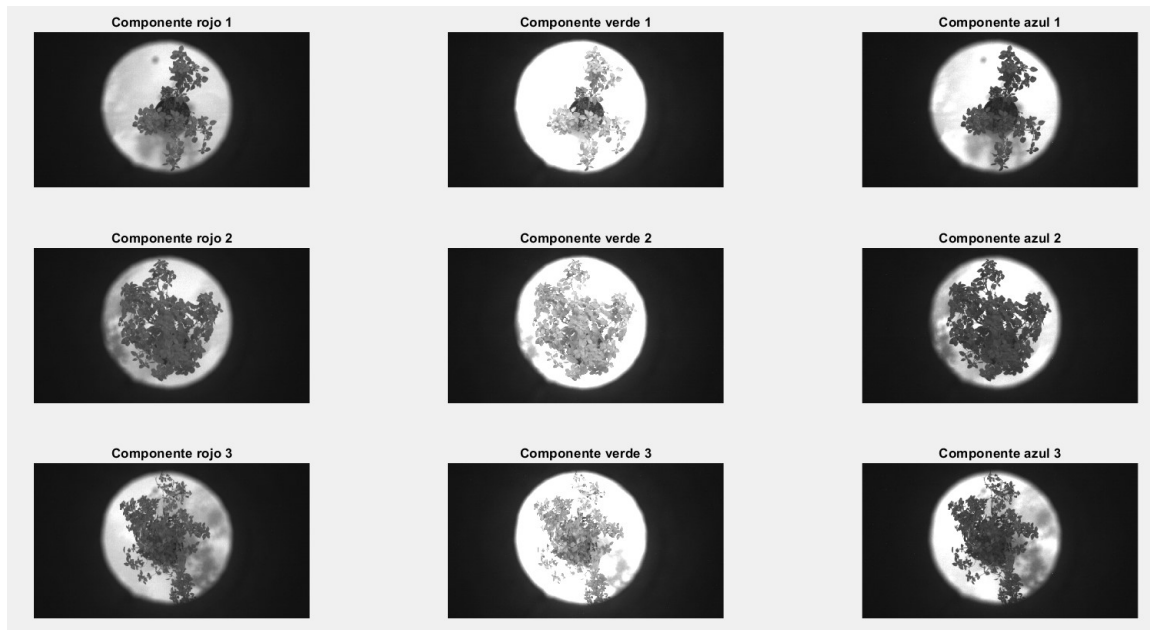


Figura 3.6 Componentes rojo, verde y azul de las 3 plantas.

Para separar los componentes RGB de las imágenes de la cámara Microsoft LifeCam HD-6000 para la segmentación K-Means se utiliza un proceso similar. En figura 3.7 se muestra la foto de la planta 1 y sus componentes R, G y B en el cuarto día del experimento. A continuación, se muestra la sección del programa encargada de separar los espectros:

```
lrgb=getsnapshot(vid);  
lrgb1=imadjust(lrgb,[],[]);  
R=lrgb1(:,:,1);  
G=lrgb1(:,:,2);  
B=lrgb1(:,:,3);
```

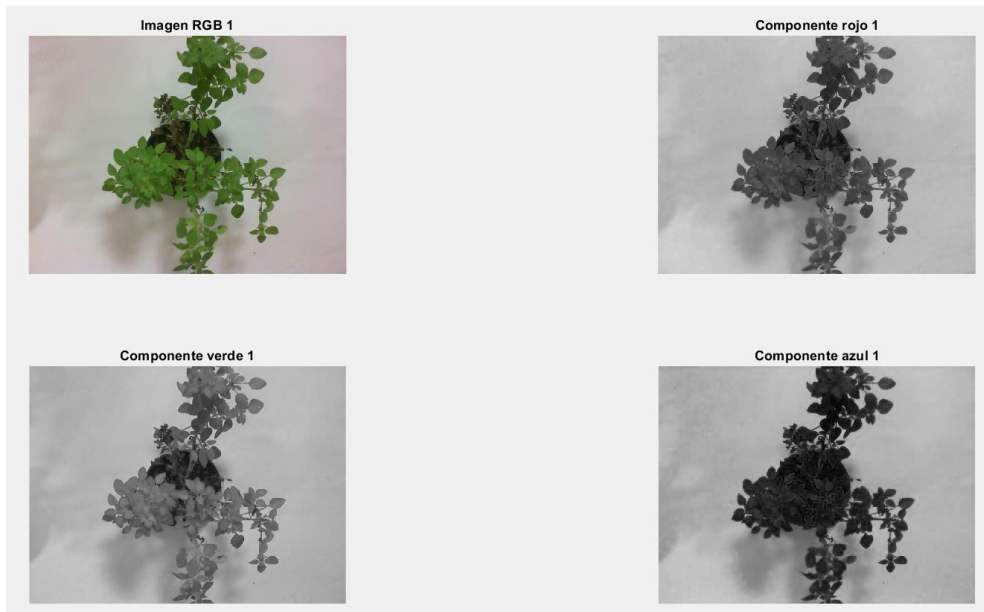


Figura 3.7 Foto de la planta 1 y sus componentes rojo, verde y azul.

Se hicieron mediciones con un luxómetro marca STEREN modelo HER-410 colocado en el lugar de una de las plantas para diseñar las pruebas y verificar que la luz infrarroja no afectaba en gran medida a la toma con la webcam. Los resultados se pueden observar en la tabla 3.1 y se concluye que la luz infrarroja influye de manera despreciable en la toma de las imágenes con la webcam.

Tabla 3.1 Mediciones en la estación de trabajo con luxómetro.

	Luz infrarroja encendida	Luz infrarroja apagada
Luz fluorescente encendida	340	333
Luz fluorescente apagada	91	87

Tal y como se comprobó que la luz infrarroja no influía significativamente en la toma de las imágenes con la webcam, también se realizó una prueba para determinar si la luz fluorescente afectaba significativamente en la toma de las imágenes de infrarrojo cercano. A continuación, se muestran los resultados de la resta entre los promedios calculados con la instrucción `mean2()` de MATLAB de las imágenes 3.8 y 3.9.

Promedio de la figura 3.8 = 50.8047

Promedio de la figura 3.9= 49.3318

Resultado de la resta= 1.4729

Con base a los resultados obtenidos se concluye que hay una diferencia despreciable al usar o no la luz fluorescente en la toma de las imágenes de infrarrojo cercano.




Figura 3.8 Imagen con luz fluorescente encendida.



Figura 3.9 Imagen con luz fluorescente apagada.

4 Segmentación K-means

El primer paso para el proceso de análisis de las imágenes RGB es la segmentación donde se divide la imagen en las partes que la forman.

La segmentación es importante ya que si hay una mala segmentación todo el proceso posterior tendrá problemas.

Se utilizará un formato RGB de imagen en el cual se puede tener hasta 16 millones de colores, por esta razón se necesita un método de segmentación por agrupamiento para detectar más fácilmente las tonalidades que nos interesan en las plantas.

K-means fue desarrollado por James Macqueen en 1967 y es uno de los métodos más sencillos y populares de usar para la segmentación de imágenes. El procedimiento tiene una forma sencilla para clasificar conjuntos de datos, en este caso las intensidades de los píxeles, a través de cierto número de grupos (k grupos) fijados de forma aleatoria.

Se define k centroides, uno para cada grupo (diferente ubicación causa resultados diferentes), la mejor opción es colocarlos lo más separados que se pueda uno del otro. El siguiente paso consiste en tomar cada punto que pertenece a un conjunto y asociarlo al centroide más cercano. Al término del proceso no habrá puntos pendientes y el agrupamiento estará completo. Se repite el proceso, pero esta vez se calcularán nuevos k centroides como baricentros de las agrupaciones resultantes del paso anterior. Los k centroides van cambiando en cada repetición hasta que no se realicen más cambios. [20]

Los objetos se representan con vectores reales de d dimensiones (x_1, x_2, \dots, x_n) y el algoritmo k-means construye k grupos donde se minimiza la suma de distancias de los objetos, dentro de cada grupo $S = \{S_1, S_2, \dots, S_k\}$, a su centroide. En la ecuación 4.1 se formula.

$$\min_S E(\mu_i) = \min_S \sum_{i=1}^k \sum_{\mathbf{x}_j \in S_i} \|\mathbf{x}_j - \mu_i\|^2 \quad \text{Ecuación 4.1}$$


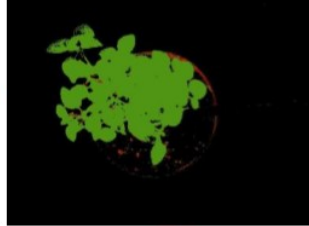



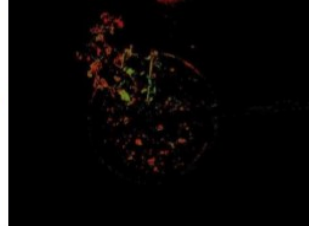

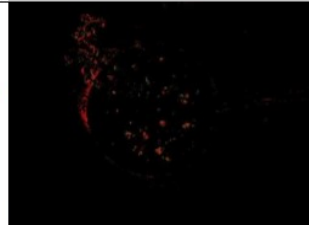
Donde S es el conjunto de datos cuyos elementos son los objetos x_j representados por vectores, donde cada uno de sus elementos representa una característica o atributo. Tendremos k grupos o clusters con su correspondiente centroide μ_i .

En cada actualización de los centroides, desde el punto de vista matemático, imponemos la condición necesaria de extremo a la función $E(\mu_i)$ como se muestra en la ecuación 4.2 y se toma el promedio de los elementos de cada grupo como un nuevo centroide.

$$\frac{\partial E}{\partial \mu_i} = 0 \implies \mu_i^{(t+1)} = \frac{1}{|S_i^{(t)}|} \sum_{\mathbf{x}_j \in S_i^{(t)}} \mathbf{x}_j \quad \text{Ecuación 4.2}$$

Después de que termina el proceso se obtienen imágenes como las que se muestran en la tabla 4.1.

Tabla 4.1 Muestras del proceso de segmentación de K-means.
Modificado de: Galicia J. I., 2015, "Aplicación para control vía remota, integración de sensores y sistema de riego a invernadero de pruebas automático para el monitoreo de plantas"

Fecha	Imagen no procesada	Imagen procesada
Semana 1 17/03/2015		
Semana 2 23/03/2015		
Semana 3 31/03/2015		
Semana 6 16/04/2015		

A partir del procesamiento de k-means se obtienen los porcentajes en mal y buen estado además de la cantidad de píxeles de la planta completa dejando de lado todo lo que no

sea la planta en cuestión. El análisis y procesamiento se realiza a las imágenes tomadas por la cámara Microsoft LifeCam HD-6000. Para el correcto funcionamiento del procesamiento de las imágenes se tienen que tomar en cuenta las siguientes consideraciones:

- El color de fondo en el piso debe ser blanco, para facilitar la discriminación del mismo.
- Tiene que estar iluminado correctamente, si es muy brillante el procesamiento no detectará las hojas y si hay sombras podría interferir en la detección de color marcándolo como porcentaje malo.
- El algoritmo del procesamiento de imagen por k-means se centra en la detección de zonas amarillas en la planta ya que esto significa que hay un déficit de clorofila (clorosis) el cual puede ser causado por varios motivos como lo son: plaga, falta de nutrientes o minerales, falta de luz solar o estrés hídrico.
- Hay que tener cuidado de que contenga la totalidad de la planta y solo de esa planta a analizar en las tomas.
- Realizar las tomas 2 o más veces al día ayudaría a incrementar la precisión para detección de deshidratación. [21]

Matlab tiene un ejemplo de segmentación automática basado en colores usando agrupamiento de k-means. Se utiliza el espacio de color $L^*a^*b^*$ y la agrupación de K-means.

La imagen usada es un tejido manchado con hematoxilina y eosina (H&E). Esta imagen se convirtió de RGB a $L^*a^*b^*$ usando la instrucción "rgb2lab". El espacio $L^*a^*b^*$ permite cuantificar las diferencias visuales de color sin importar el brillo. El espacio $L^*a^*b^*$ consiste en una capa de luminosidad " L^* ", una capa de cromaticidad " a^* " que indica donde el color cae a lo largo del eje rojo-verde y la capa de cromaticidad " b^* " para el eje azul-amarillo. Toda la información de color está en las capas " a^* " y " b^* ". se puede medir la diferencia entre 2 colores utilizando la métrica de distancia euclidiana.

Después se clasificó los colores en el espacio " a^*b^* " usando el agrupamiento K-means. Se requiere que se especifique el número de agrupamientos que se van a particionar y una métrica de distancia para cuantificar el cierre de 2 objetos entre sí. Se convierten los datos a tipo single con la instrucción "im2single" y los objetos se agrupan en 3 con la instrucción "imsegkmeans".

Para cada objeto de la entrada, devolvió un índice, o una etiqueta, correspondiente a un grupo. A continuación, se etiquetó cada pixel de la imagen con su etiqueta de pixel.

Para la creación de las imágenes segmentadas por color se aplicó a la imagen una máscara fabricada con las etiquetas de los píxeles 1 para cada color. En las figuras 4.1, 4.2 y 4.3 se muestran las imágenes segmentadas por color.

Para separar el azul oscuro y el azul claro se segmentaron los núcleos. Se extrajeron los valores del brillo y se aplicó un umbral con la instrucción imbinarize.

Después se copió la máscara de los objetos azules y, a continuación, se eliminaron los píxeles de color azul claro de la máscara 3. Luego se aplicó la nueva máscara a la imagen del tejido manchado. El resultado se muestra en la Figura 4.4.




Figura 4.1 Objetos en el agrupamiento 1.




Figura 4.2 Objetos en el agrupamiento 2.




Figura 4.3 Objetos en el agrupamiento 3.




Figura 4.4 Núcleos azules.

T. N. Tete y S. Kamlu (2017) realizaron un proyecto el cual tiene como objetivo ahorrar tiempo, dinero y ser más preciso en la detección de enfermedades en contraste con el método de la observación humana hecha por expertos. Discuten diferentes procesos de segmentación que se pueden aplicar para el objetivo. Mencionan algunos tipos de enfermedades que podrían ser detectadas como el punto negro o cancrósis cítrica y menciona que el procesamiento de imágenes se puede usar para medir el área de influencia de la enfermedad.

Proponen 2 diferentes técnicas de segmentación las cuales son: umbralización y el algoritmo de agrupación K-means. En la figura 4.5 se muestra el diagrama básico del procesamiento de imágenes.




Figura 4.5 Diagrama de bloques para el procesamiento de imágenes.
Modificado de: T. N. Tete y S. Kamlu, 2017, "Detection of plant disease using threshold, k-mean cluster and ann algorithm"

En la figura 4.6 se muestran las 4 imágenes seleccionadas para ser procesadas. Se puede notar a simple vista la enfermedad que tienen, en este caso (a) chamuscado temprano en la hoja de crisantemo (guldaudi), (b) el chancro de los cítricos en la hoja de limón, (c) la mancha negra en la hoja de rosa y (d) el chamuscado tardío en la hoja de calabaza amarga.




Figura 4.6 Imágenes de muestra de las hojas infectadas.

Modificado de: T. N. Tete y S. Kamlu, 2017, "Detection of plant disease using threshold, k-mean cluster and ann algorithm"

En las figuras 4.7 y 4.8 se muestran los diagramas de flujo de los procesos que utilizaron. El primero es una umbralización simple que clasifica los píxeles en 2 colores, negro si es menor al umbral y blanco si es mayor. El segundo es el agrupamiento K-means después de convertir el archivo al formato L*a*b*.

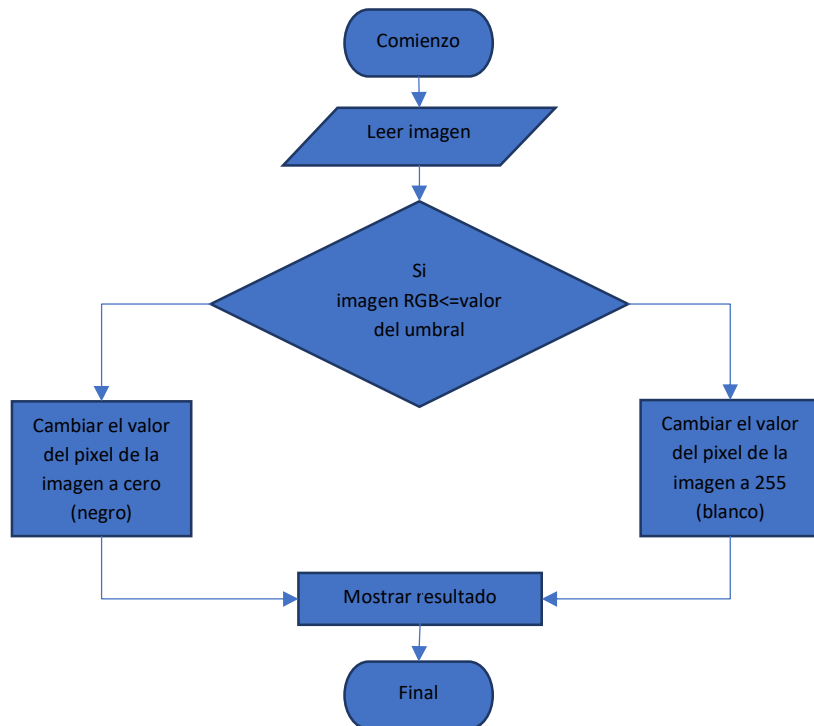


Figura 4.7 Diagrama de flujo del algoritmo de umbralización.

Modificado de: T. N. Tete y S. Kamlu, 2017, "Detection of plant disease using threshold, k-mean cluster and ann algorithm"

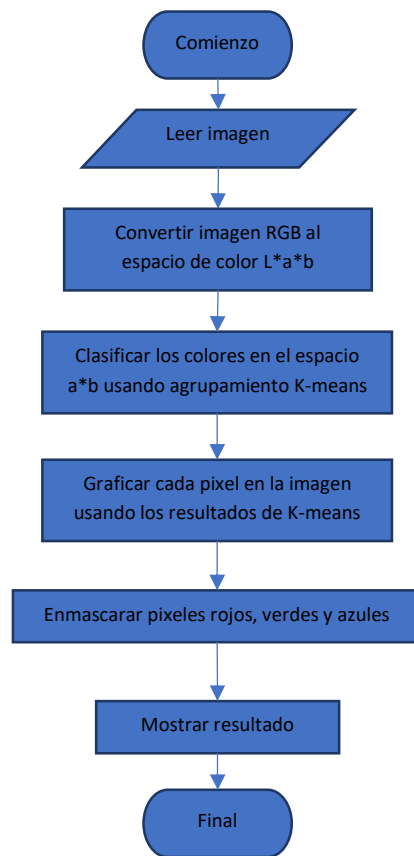


Figura 4.8 Diagrama de flujo del algoritmo de agrupación K-means.
Modificado de: T. N. Tete y S. Kamlu, 2017, "Detection of plant disease using threshold, k-mean cluster and ann algorithm"

En la figura 4.9 se muestran los resultados del algoritmo de umbralización. (a) A la izquierda se presenta la imagen del chamuscado temprano en la hoja de crisantemo y a la derecha el resultado con un valor de umbralización de 95, (b) a la izquierda se presenta la imagen del chancro de los cítricos en la hoja de limón y a la derecha el resultado con un valor de umbralización de 100, (c) a la izquierda se presenta la imagen de la mancha negra en la hoja de rosa y a la derecha el resultado con un valor de umbralización de 140 y (c) a la izquierda se presenta la imagen del chamuscado tardío en la hoja de calabaza amarga y a la derecha el resultado con un valor de umbralización de 50.

En la figura 4.10 se muestran los resultados de los pasos del algoritmo de agrupación K-means. (a) La primera columna de imágenes tiene la imagen RGB de cada muestra, (b) la segunda columna es el resultado del primer agrupamiento, (c) la tercera columna tiene el

resultado del segundo agrupamiento, (c) la cuarta columna tiene el resultado del tercer agrupamiento y (c) la quinta columna tiene el resultado de la máscara azul.

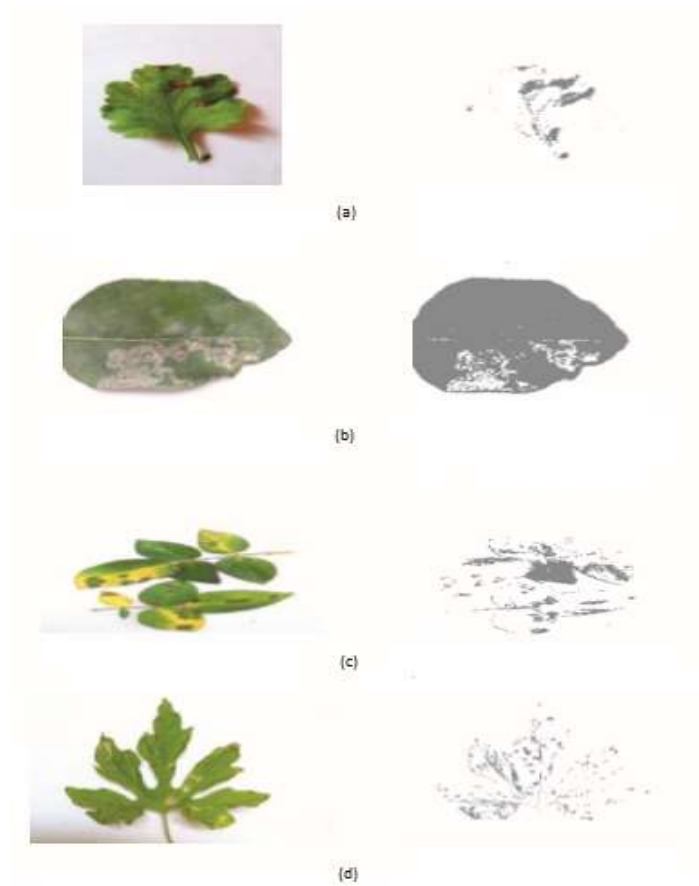


Figura 4.5 resultados del algoritmo de umbralización.

Modificado de: T. N. Tete y S. Kamlu, 2017, "Detection of plant disease using threshold, k-mean cluster and ann algorithm"



Figura 4.10 Resultados de los pasos del algoritmo de agrupación K-means.

Modificado de: T. N. Tete y S. Kamlu, 2017, "Detection of plant disease using threshold, k-mean cluster and an algorithm"

Concluyen que, aunque el algoritmo de K-means necesita que se defina el número de núcleos de agrupaciones con anterioridad, entrega los mejores resultados en comparación con la umbralización. [22].

R. Anand, et al. (2016) presentan un método para identificar la enfermedad de las hojas de las plantas y un enfoque para la detección cuidadosa de enfermedades. El objetivo del método que proponen es diagnosticar la enfermedad de la hoja brinjal utilizando procesamiento de imágenes y técnicas neuronales artificiales. Las enfermedades en esta planta son un problema crítico que hace una fuerte disminución en la producción de la misma. El estudio de interés es la hoja en lugar de la planta completa porque alrededor del 85-95% de las enfermedades ocurrieron en la hoja como, marchitez bacteriana, mancha de la hoja de Cercospora, virus del mosaico del tabaco (TMV). La metodología para detectar la enfermedad de la hoja brinjal incluye el algoritmo de agrupamiento de K-means para la segmentación y la red neuronal para la clasificación. El modelo de detección propuesto basado en redes neuronales artificiales es muy efectivo para reconocer enfermedades de las hojas.

Si bien los agricultores monitorean las hojas de sus cultivos y si ven que tiene alguna enfermedad aplican fertilizante y pesticida, pero si no saben con certeza que enfermedad es, la aplicación puede ser detrimental para las plantas. Las posibles enfermedades son marchitez bacteriana, *Pseudomonas solanacearum*, mancha de la hoja de *Cercospora* y mosaico del tabaco. La solución es automatizar el proceso de detección de la deficiencia de salud en la planta.

Los pasos del proceso propuesto son los siguientes:

- Lectura de la imagen RGB.
- Ecuilibración de histograma.
- Cambiar el tamaño de la imagen.
- Crear la estructura de transformación del color.
- Algoritmo de agrupamiento K-means.
- Aplicar enmascaramiento en una imagen.
- Convertir la hoja afectada (grupos) de RGB a HSI.
- Crear una matriz espacial de dependencias de nivel de gris (SGDM) para S y H.
- Calcule las características llamando a los parámetros de la matriz de co-ocurrencia de nivel de gris (GLCM).
- Reconocimiento utilizando la red neuronal artificial (ANN).

El algoritmo de agrupación K-means se desarrolla con los siguientes pasos:

- Clasifique las imágenes en p número de grupos donde se debe conocer p .
- Marque los puntos p al azar en el centroide del grupo.
- Asignación de objetos a su centroide de conglomerado más cercano.
- Calcule la media, centroide o perímetro de todas las imágenes en cada grupo.
- Repita los pasos 2, 3 y 4 hasta que los puntos iguales se asignen a cada grupo.

La extracción de características se realiza mediante el método de coincidencia de color (método CCM). Este método extrae tanto la textura como el color de una imagen, para finalmente llegar a características únicas que representan esa imagen. El CCM se desarrolló para matrices de dependencia de nivel de gris espacial (SGDM's).

Los resultados de los pasos del proceso se pueden ver en las Figuras 4.11 a 4.15.



Figura 4.11 Una hoja de la planta que ha sido infectada con la enfermedad.

Modificado de: R. Anand et al., 2016, "An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method"



Figura 4.12 Imagen RGB a L*a*b*

Modificado de: R. Anand et al., 2016, "An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method"



Figura 4.13 Máscara verde

Modificado de: R. Anand et al., 2016, "An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method"



Figura 4.14 Agrupamiento 1

Modificado de: R. Anand et al., 2016, "An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method"



Figura 4.15 Imagen HIS

Modificado de: R. Anand et al., 2016, "An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method"

Concluyen que con el trabajo realizado es posible identificar la enfermedad de la mancha foliar usando un algoritmo de K-means y ANN. Se tiene que extender para identificar todas las enfermedades posibles de la planta en cuestión. [23]

En el presente trabajo de investigación se analizaron 3 plantas de albahaca (*Ocimum basilicum* v. *mínimum*) las cuales se regaron con 10ml, 30 ml y 60 ml de agua diarios respectivamente.

Se realizaron tomas de imagen 3 veces al día para incrementar la precisión del proceso y se usó el algoritmo de procesamiento de imagen por segmentación K-means explicado anteriormente. Las figuras 4.16 y 4.17 corresponden al primer día del experimento. En la figura 4.17 El color verde corresponde a la vegetación sana, el color rojo corresponde a la vegetación deshidratada o enferma y el color negro corresponde a la tierra y fondo.

Adicionalmente se implementaron las ecuaciones 4.3 a la 4.6 para poder interpretar los datos obtenidos del proceso de segmentación K-means donde R_{actual} es el número de píxeles de la imagen RGB procesada por segmentación K-means en el día en cuestión, G_{actual} es el número de píxeles verdes en el día en cuestión, $Total_{actual}$ es el número de píxeles verdes y rojos en el día en cuestión y $Total_{original}$ es el número de píxeles verdes y rojos en el primer día.

$$\text{Índice RGB 1} = \frac{R_{actual}}{Total_{original}} \quad \text{Ecuación 4.3}$$

$$\text{Índice RGB 2} = \frac{G_{actual}}{Total_{original}} \quad \text{Ecuación 4.4}$$

$$\text{Índice RGB 3} = \frac{Total_{original} - Total_{actual} + R_{actual}}{Total_{original}} \quad \text{Ecuación 4.5}$$

$$\text{Índice RGB 4} = \frac{G_{actual} - R_{actual}}{G_{original} + R_{original}} \quad \text{Ecuación 4.6}$$



Figura 4.16 Foto de la planta 1 tomada con la cámara Microsoft LifeCam HD-6000.




Figura 4.17 Imagen procesada por segmentación K-Means.

5 Índice de Vegetación Diferencial Normalizado (NDVI)

5.1 Espectro Infrarrojo cercano

En esencia, la tecnología infrarrojo cercano (IRC) involucra luz interactuando con un material, donde una radiación electromagnética ocurre en forma de ondas. La longitud de onda es la distancia entre los dos picos o puntos altos, y se indica con el símbolo λ la longitud de onda en el espectro IRC se mide normalmente en nanómetros (nm) donde $1\text{nm} = 10^{-9}\text{ m}$ o $1000\text{nm} = .001\text{mm}$. Esa parte del espectro visible al ojo humano se extiende de alrededor de 400nm á 800nm, mientras que el espectro infrarrojo se extiende de aproximadamente 2,500nm á 25,000nm. El infrarrojo cercano es considerado esa parte del espectro situada entre la región visible y la región infrarroja. El rango de longitudes de onda que el IRC cubre, está entre 750nm á 2,600nm. [24]

5.2 Índices de vegetación espectrales

Los índices de vegetación (IV) espectrales han sido utilizados en el campo de los sensores remotos desde los inicios de esta tecnología como una forma indirecta de estimar variables biofísicas de la vegetación (índice de área foliar o IAF y cobertura de la vegetación o f_v , principalmente). Estos índices con base en datos captados por sensores remotos explotan el alto contraste entre la banda del rojo e IRC de la vegetación, para caracterizarla y diferenciarla de otros objetos terrestres; esto fundamentalmente con bases empíricas, pero con sustento biofísico genérico. Los valores de IV basados en datos espectrales son función de factores internos: propiedades ópticas de las hojas, arquitectura de los Fito elementos y suelo o sustrato (fondo) principalmente. Adicionalmente influyen factores externos, como la condición de la atmósfera y la geometría sol-sensor. [25]

5.3 Índice de vegetación diferencial normalizado

El Índice de Vegetación Diferencial Normalizado o por sus siglas en ingles NDVI, es el más conocido de todos, y es el más utilizado para todo tipo de aplicaciones. La razón fundamental su sencillez de cálculo y disponer de un rango de variación fijo (entre -1 y $+1$), lo que permite establecer umbrales y comparar imágenes.

- Valores muy bajos de NDVI, del orden de 0.1, corresponden a áreas rocosas, arenosas o nevadas.

- Valores de 0.2 a 0.3 pueden corresponder a áreas pobres con arbustos o pasturas naturales. A partir de estos valores tendremos los niveles correspondientes a praderas, cultivos, forestaciones etc. dependiendo el valor alcanzado.

Sin embargo, tiene el inconveniente de ser sensible a la reflectividad del suelo sobre el que se sitúa la planta, lo que limita su potencial de discriminación. Por ejemplo, en una zona con baja densidad de vegetación, la reflectividad de un pixel en la banda infrarroja y en la banda roja, vendrían determinados fundamentalmente por el suelo, con una pequeña variación debida a la presencia de vegetación. El resultado, es que un índice de vegetación de esa zona, daría resultados muy similares a los del suelo desnudo y sería imposible detectar la presencia de vegetación. De hecho, este problema es bastante grave cuando la cubierta vegetal es menor del 50%, lo que ocurre bastante a menudo, incluso en zonas cultivadas, siendo su uso poco aconsejable en esas condiciones. [26]

La fórmula que se usa para determinar este índice se muestra en la ecuación 5.1 donde “NIR” es la banda del infrarrojo cercano y “red” es la banda del rojo en la imagen a analizar.

$$NDVI = \frac{NIR - red}{NIR + red} \quad \text{Ecuación 5.1}$$

A continuación, se muestran antecedentes del uso del índice NDVI para estimar la salud de los cultivos.

Wang et al. (2018) Realizaron un estudio cuyo objetivo es evaluar el potencial del sensor Crop Circle ASC-430 para mejorar la estimación de la biomasa de la planta de maíz primaveral en diferentes etapas de crecimiento.

Se menciona además la importancia del maíz para comida, comida para animales y bio-combustible así que se busca mejorar su rendimiento y este se asocia con la cantidad de biomasa visible.

El experimento se realizó en 2015 en la estación de experimentos Lishu, en la Universidad de Agricultura de China, en la provincia Jilin. En esta área se cultiva maíz de primavera con agua de lluvia o temporal.

El experimento tuvo 5 tasas N (0, 60, 120, 180, 240 kg ha⁻¹) y 3 diferentes densidades de plantas (55000, 70000, 85000 plantas/ha). Se utilizó un diseño de bloques completos al azar con tres réplicas. Cada área de la parcela era de 100 m². Antes de la siembra se

aplicaron fertilizantes de fósforo (90 kg ha⁻¹ P₂O₅) y potasio (90 kg ha⁻¹ K₂O). Se aplicó un tercio del fertilizante N antes de la siembra, y el resto se aplicó en la etapa V8.

Se utilizaron los sensores GreenSeeker de mano 505 y el sensor Crop Circle ACS-430 para recolectar datos espectrales de las etapas V5 a la V13 del maíz. Los sensores se desplazaron a 0.7m sobre la copa de las plantas y dentro de los índices los índices seleccionados se muestran los índices NDVI y el RVI en la tabla 5.1.

Tabla 5.1 Índices espectrales de vegetación

Modificado de: Wang et al., 2018, "An Evaluation of Two Active Canopy Sensor Systems for Non-destructive Estimation of Spring Maize Biomass."

Índice	Formula	Referencia
Índice de vegetación diferencial normalizado	$(NIR-R)/(NIR+R)$	Rouse et al. (1973)
Índice de proporción de vegetación	NIR/R	Jordan. (1969)

La desviación estándar, media y coeficiente de variación (CV,%) se calcularon usando Microsoft Excel. El coeficiente de determinación (R^2) relacionando los índices de vegetación con la biomasa se calcularon usando SPSS18 (SPSS Inc., Chicago, Illinois, USA). El rendimiento general de las relaciones se estimó comparando R^2 , error cuadrático medio (RMSE), y error relativo (RE, %) de predicción.

Para el sensor GreenSeeker los índices NDVI y RVI tuvieron la misma R^2 a través de todas las etapas de crecimiento o en una específica. Pero en V5-V6 los índices fueron mayores que en V8-V9 y V12-V13 (ver tabla 2). El sensor Crop Circle se comportó similar al anterior pero la R^2 para las relaciones no mostró diferencias significativas entre las etapas.

Para comparar los diferentes índices de vegetación se tuvieron que normalizar basándose en el mayor valor. Esto demostró que RVI es más sensible y tiene más habilidad para distinguir biomasa de maíz en lugares más altos. (ver figura 5.1)

Con base en los resultados enumerados en la tabla 5.2, los modelos de regresión entre los índices de vegetación y la biomasa aérea se evaluaron adicionalmente con datos de experimentos de validación (ver tabla 5.3)

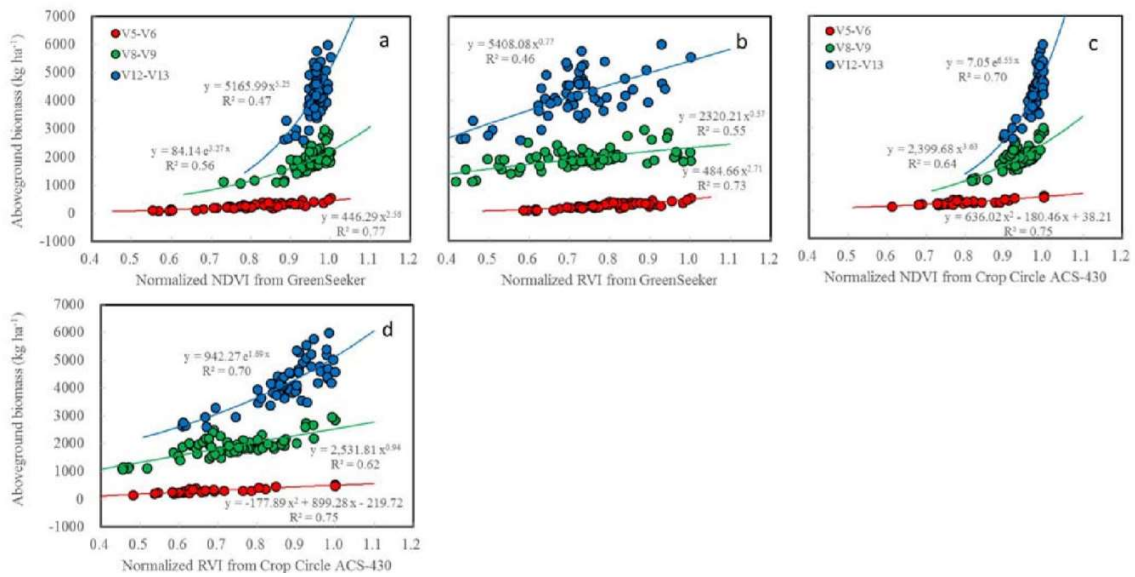


Figura 5.1 Relaciones entre la biomasa sobre el suelo y los índices normalizados de vegetación derivados del sensor GreenSeeker y el sensor Circle ACS-430 en las 3 etapas de crecimiento.

Modificado de: Wang et al., 2018, "An Evaluation of Two Active Canopy Sensor Systems for Non-destructive Estimation of Spring Maize Biomass."

Tabla 5.2 Coeficientes de determinación (R²) para las relaciones entre índices de vegetación (derivados del sensor GreenSeeker y calculados del sensor Circle ACS-430) y la biomasa sobre el suelo en diferentes etapas de crecimiento.

Modificado de: Wang et al., 2018, "An Evaluation of Two Active Canopy Sensor Systems for Non-destructive Estimation of Spring Maize Biomass."

Etapa	V5-V6		V8-V9		V12-V13		Todas las etapas	
	Ecuación	R ²	Ecuación	R ²	Ecuación	R ²	Ecuación	R ²
Greenseeker								
NDVI	P	0.77	E	0.56	P	0.47	E	0.92
RVI	P	0.73	P	0.55	P	0.46	P	0.89
Crop Circle ACS-430								
NDVI	Q	0.75	P	0.64	E	0.47	E	0.91
RVI	Q	0.75	P	0.55	E	0.46	P	0.92

Tabla 5.3 Resultados de validación de evaluación con índices de vegetación (derivados por GreenSeeker y calculados de Crop Circle ACS-430) para estimar los datos de biomasa sobre el suelo del experimento de validación a diferentes etapas de crecimiento.

Modificado de: Wang et al., 2018, "An Evaluation of Two Active Canopy Sensor Systems for Non-destructive Estimation of Spring Maize Biomass."

Etapa	V5-V6			V8-V9			V12-V13			Todas las etapas		
Índice	RMSE (kg ha ⁻¹)	RE(%)	R ²	RMSE (kg ha ⁻¹)	RE(%)	R ²	RMSE (kg ha ⁻¹)	RE(%)	R ²	RMSE (kg ha ⁻¹)	RE(%)	R ²
Greenseeker												
NDVI	59.54	22.25	0.75	327.44	16.69	0.54	698.42	16.31	0.36	984.80	45.07	0.68
RVI	58.4	21.83	0.76	327.41	16.68	0.51	710.58	16.59	0.34	972.35	44.5	0.67
Crop Circle ACS-430												
NDVI	54.77	19.15	0.84	312.72	15.94	0.57	558.66	13.04	0.6	893.01	37.24	0.73
RVI	56.19	19.65	0.83	310.18	15.81	0.57	536.21	12.52	0.63	800.85	33.39	0.76

Como conclusiones se tiene que en las primeras etapas de crecimiento (V5-V8) del maíz, el NDVI y el RVI de ambos sensores tuvieron un buen desempeño para la estimación de la biomasa del maíz. El sensor de copa activo de dos bandas Crop Circle ACS-430 es más adecuado para la estimación de la biomasa aérea de maíz después de V6. Se menciona que son necesarios más estudios para evaluar más a fondo el sensor Crop Circle ACS-430 para el diagnóstico del estado de N y el manejo preciso de N del maíz de primavera. [27]

Rizki Wahyu Pratama (2017) realizó un estudio sobre la salud de la planta de arroz y la relación que tiene con los índices de vegetación ya que es producido en el país de indonesia donde se realiza la investigación además de ser una importante parte de su economía.

Para ayudar proporcionando datos y estadísticas que ayudaran a los granjeros se propuso presentarles nuevos métodos para incrementar la productividad del arroz como un vehículo volador no tripulado (UAV) equipado con una cámara que pueda captar la luz cercana infrarroja (NIR) emparejada con datos georreferenciados. Estos datos permiten analizar el índice de vegetación diferencial normalizado (NDVI) el cual lleva a detectar la

eficiencia fotosintética y así el granjero puede optimizar el uso de fertilizantes, agua y pesticidas.

El principal método utilizado en el proceso se basa en el índice NDVI usando 2 cámaras de bolsillo Canon S100 y una de ellas fue modificada para aceptar la luz NIR usando un filtro roscolux 2007 y un cuadcoptero con un módulo integrado Ardupilor mega (APM) 2560.


El índice NDVI es un cálculo de las imágenes que puede mostrar los parámetros relacionados con el bienestar de la planta como la biomasa de las hojas y el área de follaje que es el valor que puede ser estimado para la división de vegetación. Investigaciones previas mostraron que el valor de NDVI se encuentra estrechamente relacionado con la fracción de radiación activa absorbida fotosintéticamente (FAPAR), fuertemente relacionado con el índice de área de la hoja (LAI), la biomasa, y es sensitivo al contenido de clorofila. En la tabla 5.4 se puede ver la clasificación de los objetos identificados según el valor de NDVI.

*Tabla 5.4 División de objetos vasados en NDVI.
Modificado de: Rizki Wahyu Pratama, et al. 4th International Conference on Electrical Engineering*

Índice	Valor de NDVI
No vegetación	<0
Vegetación poco saludable	0 a 0.1
Vegetación saludable	0.2 a 0.3
Vegetación muy saludable	0.4 a 0.8

Los rangos del índice NDVI varían desde -1.0 hasta 1.0.

El proceso de recolección de datos se realizó con las 2 cámaras antes descritas y a ambas se les dio un código para capturar imágenes basados en intervalo de tiempos. Después de que las imágenes fueron recolectadas, el resultado fue renderizado usando el software Agisoft Photoscan y los resultados se pueden ver en la figura 5.2.



*Figura 5.2 RGB (izquierda), Cercano infrarrojo (centro), NDVI (derecha).
Modificado de: Rizki Wahyu Pratama, et al. 4th International Conference on Electrical Engineering*

Las imágenes resultantes se analizaron usando el programa ArcGIS que usaba la fórmula de NDVI, luego se seleccionaron 6 muestras, los resultados se pueden ver en la figura 5.3 y en la tabla 5.5.

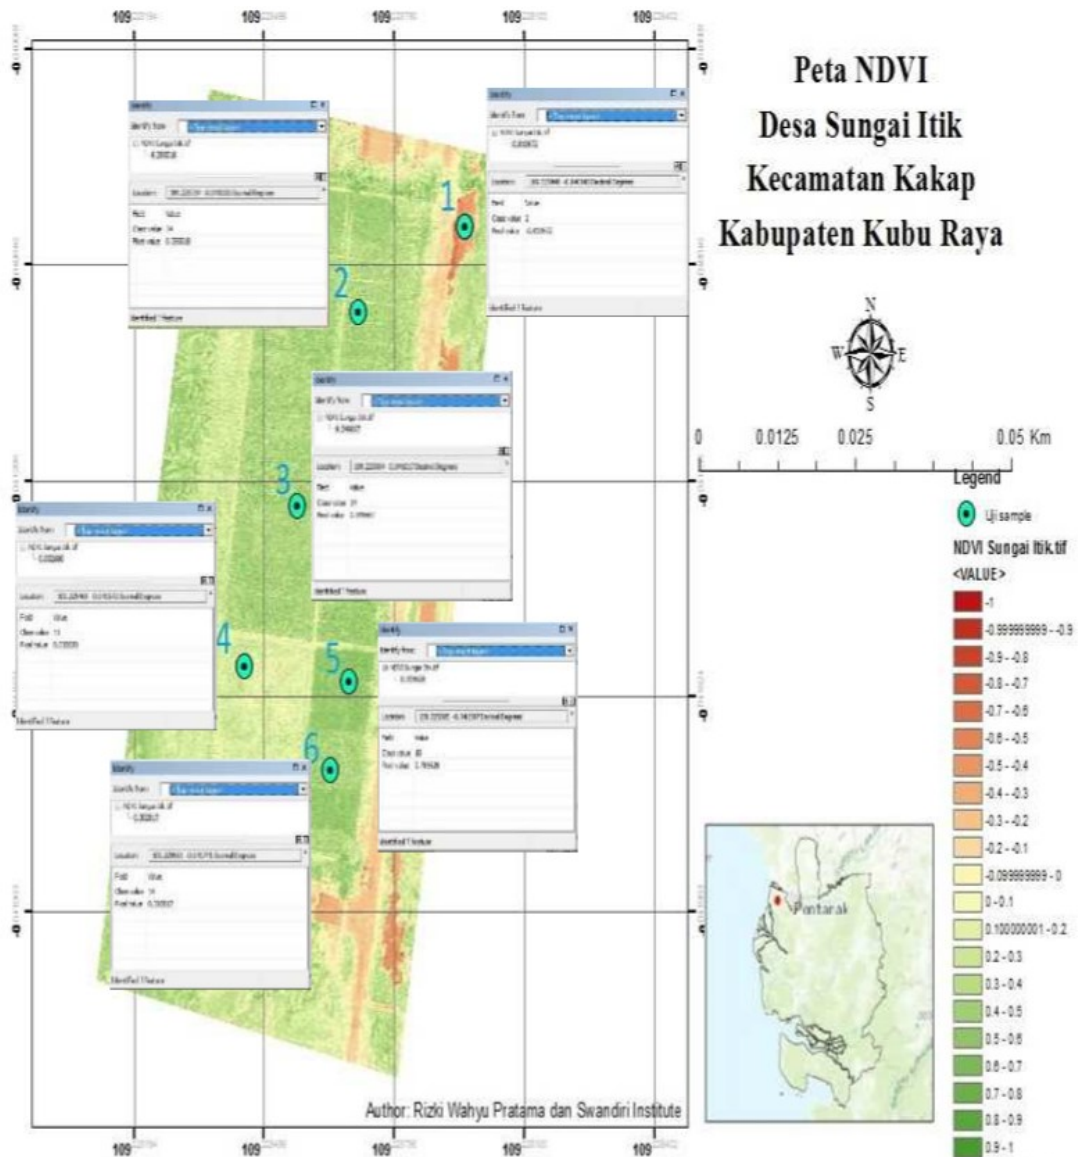


Figura 5.3 Resultados de los datos de NDVI.

Modificado de: Rizki Wahyu Pratama, et al. 4th International Conference on Electrical Engineering

Tabla 5.5 Muestras de valores de NDVI
Modificado de: Rizki Wahyu Pratama, et al. 4th International Conference on Electrical Engineering

Punto	Muestra de datos	Rango de valores de NDVI	Validación de resultados
1	-0.819672	-1 a 0	No vegetación
2	0.395018	0.2 a 0.6	Vegetación saludable
3	0.346667	0.2 a 0.6	Vegetación saludable
4	0.032680	0.2 a 0.6	Vegetación saludable
5	0.705628	0.6 a 1	Vegetación muy saludable
6	0.302817	0 a 0.2	Vegetación poco saludable

Los resultados de las pruebas fueron validados por granjeros en el sitio ya que las condiciones actuales de las plantas en el campo correspondían con el estado determinado por el índice NDVI. Entonces se concluye que los datos de NDVI se pueden usar por el granjero como referencia para observar el crecimiento y la salud de las plantas para que puedan dar el cuidado apropiado y optimizar la producción. [28]

El programa “Encontrar vegetación en una imagen multiespectral” de Matlab muestra cómo utilizar la aritmética de matrices de MATLAB para procesar una imagen con formato ERDAS LAN del mapeador temático de LANDSAT que cubre parte de París, Francia obtenida de Space Imaging, LLC. Esta imagen tiene siete canales espectrales y es de 512 por 512 píxeles.

Al hacer la diferencia y aplicando un umbral entre las bandas roja y NIR se puede apreciar las áreas de la imagen donde hay vegetación.

Por medio de la función “multibandread” se leyeron las bandas 4(NIR se le asigna rojo), 3(Rojo, se le asigna verde) y 2(Verde, se le asigna azul) del archivo LAN.

Después se creó un gráfico de dispersión que muestre un punto por píxel, X siendo el valor rojo y el valor NIR esto para interpretar las zonas en la gráfica que representan carreteras, tejados y suelos y las zonas que representan vegetación.

A continuación, se tomó la diferencia (NIR-red) y la normaliza para ayudar a equilibrar los efectos de la iluminación irregular con la ecuación 5.1.

El resultado NDVI fue una matriz 2-D con un rango de valores de -1 a 1.

Al final se aplicó un umbral para identificar los pixeles que tienen más probabilidad de contener la vegetación.

Para las tomas realizadas en este trabajo se usa una cámara La See3CAM_CU40, una cámara USB3 RGB-IR en color y RAW 4MP de alto rendimiento con soporte de lente con montura S (montura M12). Esta cámara RGB-IR está basada en el sensor de imagen CMOS OV4682, un popular sensor de imagen CMOS con formato de píxel RGB-IR de OmniVision.

La cámara junto con el programa de toma de imágenes proporcionado por la compañía donde se adquirió la cámara, e-con Systems, puede tomar una imagen de formato RAW con los componentes RGB además de un componente cercano infrarrojo, a falta de compatibilidad con el programa Matlab donde se realiza el procesamiento de imágenes se optó por tomar fotos separadas del componente RGB y del cercano infrarrojo.

El procedimiento para procesar las imágenes y obtener el índice NDVI en Matlab es simple, se extrae y se convierte a tipo de archivo "single" el componente rojo de la imagen RGB con la instrucción: `imRa1=im2single(x1(:, :, 1))`, además se convierte la imagen cercana infrarroja a archivo tipo single y se redimensiona el tamaño del componente rojo con la siguiente instrucción: `bir1 = imresize(ir1,[720 1280])`; para que sean compatibles. Después se usan las siguientes instrucciones para obtener el índice NDVI según la ecuación 5.1.

```
Minuendo1=bir1 - imRa1;  
sustraendo1=bir1 + imRa1;  
NDVI1 = minuendo1 ./sustraendo1;
```

Como resultado se obtiene una imagen en escala de grises en la cual cada pixel tiene una intensidad que varía desde -1 hasta 1. De -1 a 0 se considera que es el fondo y no hay follaje. En las figuras 5.4 a la 5.12 se pueden ver los componentes RGB, NIR y la imagen resultante NDVI de las 3 plantas de albahaca en el cuarto día después de iniciar las tomas del experimento.

Por último se calcula un promedio de las intensidades de los pixeles en la imagen resultante para poder compararlo con los índices obtenidos con las ecuaciones 4.3 a 4.6 del proceso de segmentación K-means.




Figura 5.4 Foto RGB tomada de la planta 1.




Figura 5.5 Foto NIR tomada de la planta 1.




Figura 5.6 Resultado NDVI de la planta 1.




Figura 5.7 Foto RGB tomada de la planta 2.




Figura 5.8 Foto NIR tomada de la planta 2.




Figura 5.9 Resultado NDVI de la planta 2.




Figura 5.10 Foto RGB tomada de la planta 3.




Figura 5.11 Foto NIR tomada de la planta 3.



Figura 5.12 Resultado NDVI de la planta 3.

6 Neurona Artificial

La neurona artificial es una unidad procesadora con cuatro elementos funcionales:

1. El elemento receptor, a donde llegan una o varias señales de entrada x_i , que generalmente provienen de otras neuronas y que son atenuadas o amplificadas cada una de ellas con arreglo a un factor de peso w_i que constituye la conectividad entre la neurona fuente de donde provienen y la neurona de destino en cuestión.
2. El elemento sumador, que efectúa la suma algebraica ponderada de las señales de entrada, ponderándolas de acuerdo con su peso.
3. El elemento de función activadora, que aplica una función no lineal de umbral (que frecuentemente es una función escalón o una curva logística) a la salida del sumador para decidir si la neurona se activa, disparando una salida o no.
4. El elemento de salida que es el que produce la señal, de acuerdo con el elemento anterior, que constituye la salida de la neurona.

Este modelo neuronal es el utilizado en casi todas las Redes Neuronales artificiales, variando únicamente el tipo de función activadora.

6.1 Perceptrón

El Perceptrón, desarrollado por Rosenblatt (1958), consiste en una neurona procesadora, con sus elementos de entrada, sumador, activador y de salida a la cual llegan señales de entrada x_i , $i = 1, 2, \dots, n$ cada una con una w_i a través de una línea con conductividad o peso asociado w_i . El elemento sumador efectúa entonces una suma ponderada de las entradas, en tanto que el activador emplea una función escalón de umbral: si la suma ponderada es mayor o igual a un valor de umbral U , da una salida y de tal manera que:

$$y = 1 \text{ si } S > U$$

$$y = 0 \text{ si } S < U$$

La red neuronal más simple construida con perceptrones tiene dos capas: una capa receptora de entrada, en la que la salida de cada neurona reproduce simplemente su entrada y una capa de salida formada por perceptrones como los descritos, totalmente conectados con la capa de entrada, a través de líneas de comunicación con conductividades o pesos ajustables. [29]

6.2 Retro propagación

Para entrenar una red neuronal para realizar alguna tarea, se deben ajustar los pesos de cada unidad de tal manera que se reduce el error entre la salida deseada y la salida real. Este proceso requiere que la red neuronal calcule la derivada de error de los pesos. En otras palabras, debe calcular cómo cambia el error a medida que aumenta cada peso o disminuyó ligeramente. El algoritmo de retro propagación es el método más utilizado para determinar EW.

El algoritmo de retro propagación se introdujo originalmente en la década de 1970, pero su importancia no se apreció completamente hasta la publicación del artículo de David Rumelhart, Geoffrey Hinton y Ronald Williams en 1986. Ese documento describe varias redes neuronales en las que la retro propagación funciona mucho más rápido que los enfoques de aprendizaje anteriores, lo que hace posible utilizar redes neuronales para resolver problemas que antes eran insolubles.

En el corazón de la retro propagación hay una expresión para la derivada parcial $\partial C / \partial w$ de la función de costo C con respecto a cualquier peso w (o sesgo b) en la red. La expresión nos dice qué tan rápido cambia el costo, error entre la salida esperada y la salida verdadera, cuando cambiamos los pesos y los sesgos. Cada elemento tiene una interpretación natural e intuitiva. Y entonces la propagación hacia atrás no es solo un algoritmo rápido para el aprendizaje. En realidad, nos brinda información detallada sobre cómo cambiar los pesos y los sesgos cambia el comportamiento general de la red. [30]

Antes de explicar el algoritmo de la retro propagación se deben definir ciertos parámetros.

Se tiene una red neuronal prealimentada con $L > 2$ capas, w_{jk}^l represente el peso del enlace que conecta la neurona k -ésima en la capa $l-1$ con la neurona j -ésima en la capa l , b_j^l representa el sesgo de la neurona j -ésima en la capa l y a_j^l representa la salida de la neurona j -ésima en la capa l . La ecuación 6.1 relaciona la activación de una neurona en la capa l con las activaciones de las neuronas en la capa $l-1$.

$$a_j^l = \sigma\left(\sum_k w_{jk}^l a_k^{l-1} + b_j^l\right) \quad \text{Ecuación 6.1}$$

Donde σ representa la función de activación neuronal. En la ecuación 6.2 se describe de forma matricial la activación de neuronas en la capa l con respecto a las activaciones en la capa $l-1$.

$$a^l = \sigma(w^l a^{l-1} + b^l) \quad \text{Ecuación 6.2}$$

El objetivo del algoritmo de retro propagación es calcular las derivadas parciales $\frac{\partial C}{\partial w}$ y $\frac{\partial C}{\partial b}$ las cuales nos permitirán modificar los pesos y sesgos de cada neurona para reducir el coste C. La ecuación 6.3 representa la definición δ_j^l como el error en la neurona j-ésima en la capa l y a continuación hace una distinción entre el error de las neuronas de la capa de salida L y el error del resto de las capas de una forma matricial.

$$\delta^l = \nabla_a C \odot \sigma'(z^l) \quad \text{Ecuación 6.3}$$

Siendo $\nabla_a C$ el vector compuesto por las derivadas parciales de C con respecto a las diferentes activaciones de las neuronas en la capa de salida. La ecuación 6.4 representa el error en las neuronas de las capas interiores.

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l) \quad \text{Ecuación 6.4}$$

Donde $(w^{l+1})^T$ representa la traspuesta de la matriz de pesos de la capa l+1, necesaria para propagar hacia atrás los errores. Combinando las ecuaciones 6.3 y 6.4 podemos obtener el error δ_j^l en cualquier neurona de la red. Se utiliza la primera para calcular δ^L , a continuación, se utiliza la segunda para calcular δ^{L-1} en función de δ^L y sucesivamente utilizaremos la ecuación 6.4 para calcular δ^{l-1} en función de δ^l .

Las ecuaciones 6.5 y 6.6 indica cómo cambia el coste C con respecto a cualquier sesgo y cualquier peso en la red respetivamente.

$$\frac{\partial C}{\partial b} = \delta \quad \text{Ecuación 6.5}$$

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l \quad \text{Ecuación 6.6}$$

Las cuatro ecuaciones fundamentales 6.3, 6.4, 6.5 y 6.6 del algoritmo de retro propagación nos sirven para entender de manera más adecuada las modificaciones realizadas sobre los pesos y las implicaciones que conllevan.

El algoritmo de propagación sigue los siguientes pasos:

- 1- Entrada: Activar las neuronas de la primera capa a^1 con la entrada x .
- 2- Propagación: Para cada $l=2,3, \dots, L$ calcular $z^l = w^l a^{l-1} + b^l$ y $a^l = \sigma(z^l)$.
- 3- Cálculo de errores en la capa de salida: Calcular el vector $\delta^l = \nabla_a C \odot \sigma'(z^l)$.
- 4- Retro propagación del error: Para cada $l=L-1, L-2, \dots, 2$ calcular $\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l)$.
- 5- Salida: El gradiente de la función de coste C viene dado por la función 6.7.

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l, \frac{\partial C}{\partial b_j^l} = \delta_j^l \quad \text{Ecuación 6.7}$$

Después se puede combinar el algoritmo de retro propagación con algún algoritmo de aprendizaje como la regla delta o el método del descenso por el gradiente estocástico. [31]

Si los pares entrada-salida del patrón de entrenamiento de nuestra red neuronal fueran a ser el resultado de una función desconocida se usaría la aproximación de función la cual encuentra un estimado de dicha función desconocida.

Las redes neuronales artificiales (ANN) aplican el principio de aproximación de funciones con ejemplos, lo que significa que aprenden una función mirando ejemplos de esta función. Uno de los ejemplos más simples es una ANN aprendiendo la función XOR.

Si una ANN debe poder aprender un problema, debe definirse como una función con un conjunto de variables de entrada y salida compatibles con ejemplos de cómo debería funcionar esta función. Un problema como la función XOR ya está definido como una función con dos entradas binarias variables y una variable de salida binaria, y con los ejemplos que están definidos por los resultados de cuatro patrones de entrada diferentes. [32]

En nuestro caso los valores de entrada son los resultados de la función del sistema de detección de deshidratación RGB basado en k-means y nuestra salida esperada son los resultados de la función del sistema con cámara infrarroja basado en el índice NDVI y se busca realizar una aproximación entre estas 2 funciones usando una red neuronal.

Un ejemplo sobre aproximación lineal con redes neuronales existe en Matlab en el cual se tienen 4 grupos de datos (A, B, C y D) definidos en un espacio bidimensional. (A, C) y (B, D)

representan el problema de clasificación XOR. El programa define una red neuronal para resolver el problema XOR. En la figura 6.1 se muestra la gráfica de los grupos. En la figura 6.2 se muestra la red neuronal. En la figura 6.3 se muestra la respuesta de la red para observar la efectividad de su aprendizaje. En la figura 6.4 se muestra la gráfica resultante clasificando los grupos en regiones representadas de diferente color.




Figura 6.1 Gráfica de los grupos de datos.

```
P = [A B C D];  
T = [repmat(a,1,length(A)) repmat(b,1,length(B)) ...  
repmat(c,1,length(C)) repmat(d,1,length(D))];  
net = feedforwardnet([5 3]);
```




Figura 6.2 Visualización a bloques de la red neuronal.




Figura 6.3 Comparación entre respuesta real y respuesta esperada.




Figura 6.4 Clasificación de grupos por región.

La estructura básica que tendrá nuestra red neuronal consta de una entrada, una salida y dos capas intermedias de diez neuronas y una neurona respectivamente. Se muestra en la figura 6.5.




Figura 6.5 Red neuronal con 1 entrada, una salida y 2 capas intermedias de 10 neuronas y 1 neurona respectivamente.

7 Resultados

Para comparar los métodos de detección de deshidratación por medio de NDVI y por segmentación K-means se implementaron algunas operaciones adicionales con los datos obtenidos del método k-means. En la tabla 8.1 se muestran los datos obtenidos del proceso de k-means en el cual se tienen total de píxeles, porcentaje bueno y porcentaje malo de cada planta durante el periodo de prueba y en la tabla 8.2 se muestran los índices obtenidos del proceso NDVI. En la tabla 8.3 a 8.6 se muestran los índices calculados con la relación de la cantidad de píxeles buenos de la planta en el día actual sobre los píxeles totales del primer día, la relación de la cantidad de píxeles malos de la planta en el día actual sobre los píxeles totales del primer día, la relación de la suma de los píxeles perdidos y los píxeles malos sobre los píxeles totales del primer día y la relación de los píxeles buenos menos los píxeles malos sobre los píxeles totales del primer día respectivamente.

A continuación, se diseñó y entrenó una red neuronal en MATLAB para aproximar los índices de las operaciones de las tablas 8.3 a 8.6 a los índices NDVI de la tabla 8.2.

El proceso de entrenamiento se realizó planta por planta. En las figuras 8.1 a la 8.12 se muestran las gráficas de la comparación de comportamientos de cada planta entre el índice NDVI representado en verde, los índices calculados representados con color rojo y los resultados de las redes neuronales artificiales entrenadas representados con color azul.

Se sacaron muestras de las imágenes tomadas a las plantas del primer y séptimo día del proceso NDVI y segmentación K-means las cuales se pueden ver en las tablas 8.7 a 8.10.

Las tablas 8.11 a 8.13 muestran las Características del entrenamiento de las redes neuronales y los promedios de su desempeño.

Tabla 7.1 Datos obtenidos con el proceso de segmentación K-means.

		Día 1	Día 2	Día 3	Día 4	Día 5	Día 6	Día 7	Día 8	Día 9	Día 10
Planta 1	Total de píxeles	58633	53653	49356	31896	22333	16702	11252	9842	6825	2331
	% Malo	0,9786	0,9732	0,9364	0,9401	0,9279	0,8803	0,9239	0,9286	0,8575	0,6722
	% Bueno	0,00213	0,0267	0,0635	0,0598	0,072	0,1196	0,076	0,0713	0,1424	0,3277

Tabla 7.2 Datos obtenidos con el proceso de cálculo Ec 5.1.

	Día 1	Día 2	Día 3	Día 4	Día 5	Día 6	Día 7	Día 8	Día 9	Día 10
Planta 1	0,9764	0,86610	0,73478	0,47887	0,32600	0,21669	0,16271	0,14390	0,08323	0,01369

Tabla 7.3 Datos calculados con la operación Ec.4.4.

	Día 1	Día 2	Día 3	Día 4	Día 5	Día 6	Día 7	Día 8	Día 9	Día 10
Planta 1	0,9786	0,8905	0,7882	0,5114	0,3534	0,2507	0,1773	0,1558	0,0998	0,0267

Tabla 7.4 Datos calculados con la operación Ec. 4.3.

	Día 1	Día 2	Día 3	Día 4	Día 5	Día 6	Día 7	Día 8	Día 9	Día 10
Planta 1	0,0021	0,02443	0,05345	0,03253	0,02742	0,03406	0,01458	0,01196	0,01657	0,01302

Tabla 7.5 Datos calculados con la operación Ec. 4.5.

	Día 1	Día 2	Día 3	Día 4	Día 5	Día 6	Día 7	Día 8	Día 9	Día 10
Planta 1	0,00213	0,10936	0,21167	0,48853	0,64653	0,74921	0,82267	0,84411	0,90017	0,97327

Tabla 7.6 Datos calculados con la operación Ec. 4.6.

	Día 1	Día 2	Día 3	Día 4	Día 5	Día 6	Día 7	Día 8	Día 9	Día 10
Planta 1	0,97647	0,86610	0,73478	0,47887	0,32600	0,21669	0,162717	0,14390	0,08323	0,01369

Tabla 7.7 Proceso NDVI del día 1 (2019/10/04).

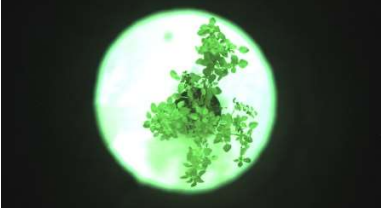
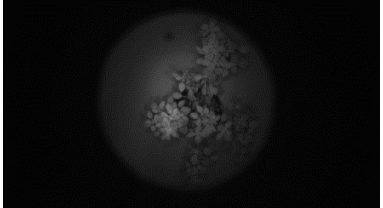
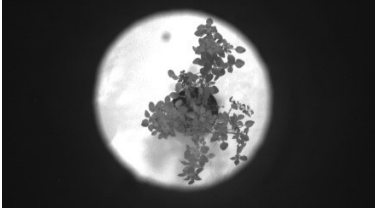

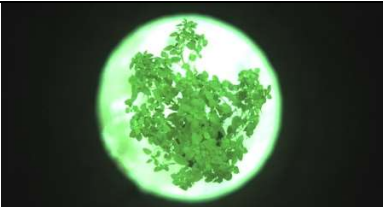
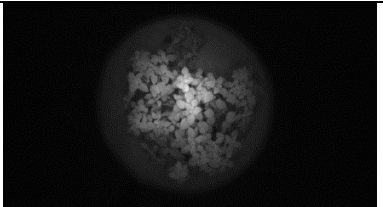
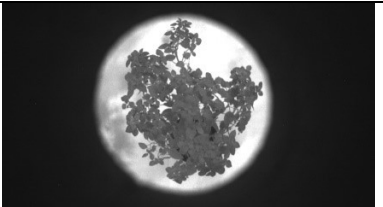
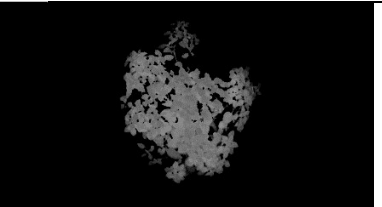
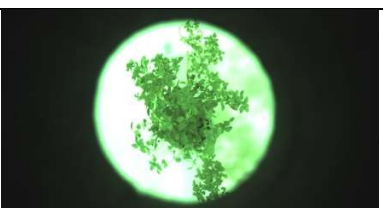
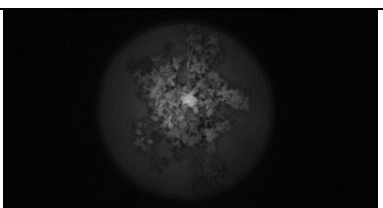
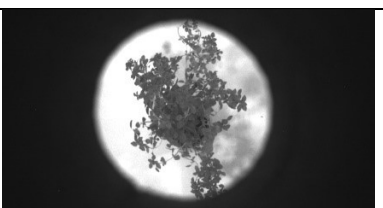
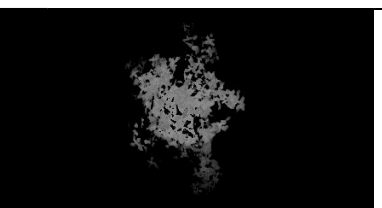
	Imagen RGB	Imagen IR	Componente rojo	NDVI
Planta 1 10 ml.				
Planta 2 30 ml.				
Planta 3 60 ml.				

Tabla 7.9 Proceso K-means del día 1 (2019/10/04).

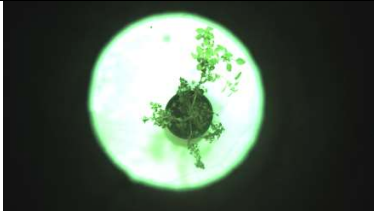
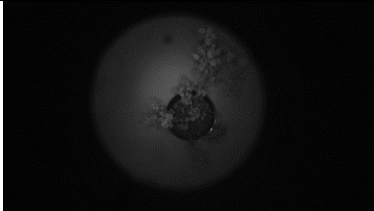
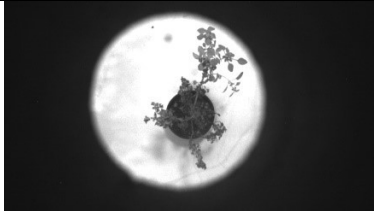

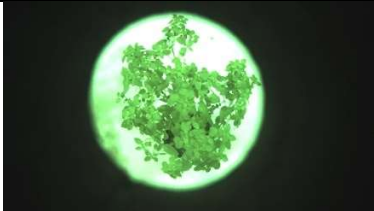
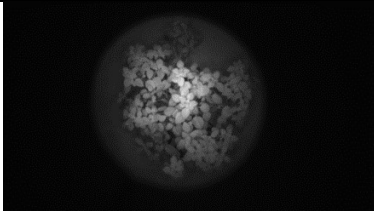
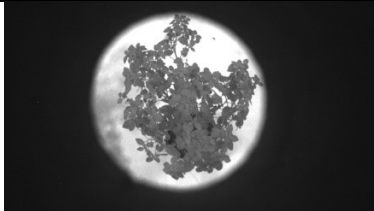
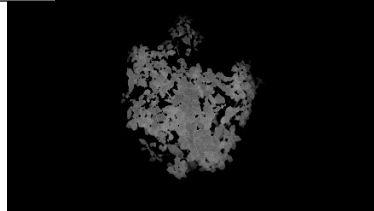

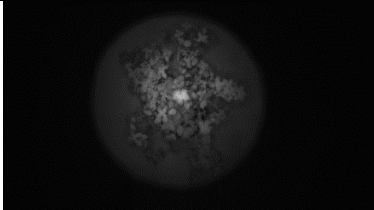


	Imagen RGB	Imagen IR	Componente rojo	NDVI
Planta 1 10 ml.				
Planta 2 30 ml.				
Planta 3 60 ml.				

Tabla 7.8 Proceso NDVI del día 7 (2019/10/10).


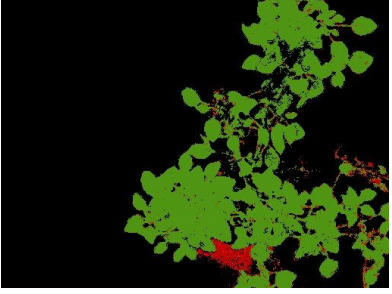


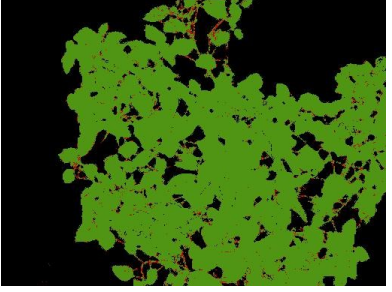


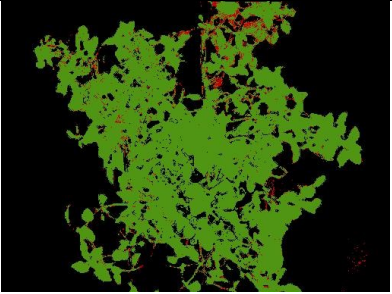
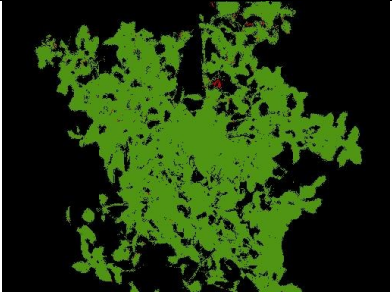




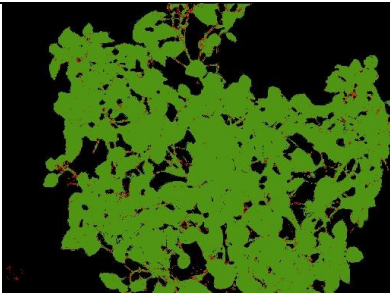


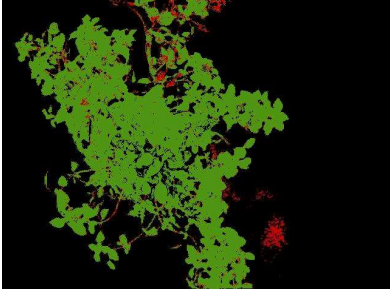
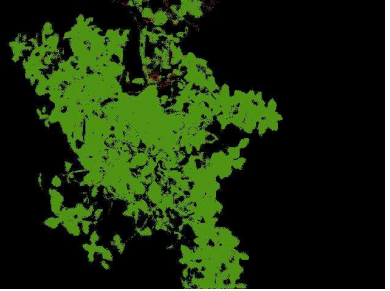
	Imagen RGB	Imagen procesada sin ajuste	%	Imagen procesada con ajuste	%
Planta 1 10 ml.			T=60869 B=94.27% M=5.72%		T=58633 B=97.86% M=2.13%
Planta 2 30 ml.			T=120144 B=96.61% M=3.38%		T=116892 B=99.30% M=0.69%
Planta 3 60 ml.			T=83713 B=96.01% M=3.98%		T=80873 B=99.38% M=0.61%

Tabla 7.10 Proceso K-means del día 7 (2019/10/10).

	Imagen RGB	Imagen procesada		Imagen procesada con ajuste	%
Planta 1 10 ml.			T=19475 B=53.38% M=46.61%		T=11252 B=92.39% M=7.60%
Planta 2 30 ml.			T=120334 B=97.11% M=2.88%		T=117438 B=99.50% M=0.49%

<p>Planta 3 60 ml.</p>			<p>T=87466 B=94.18% M=5.81%</p>		<p>T=83008 B=99.23% M=0.76%</p>
----------------------------	---	--	---	---	---

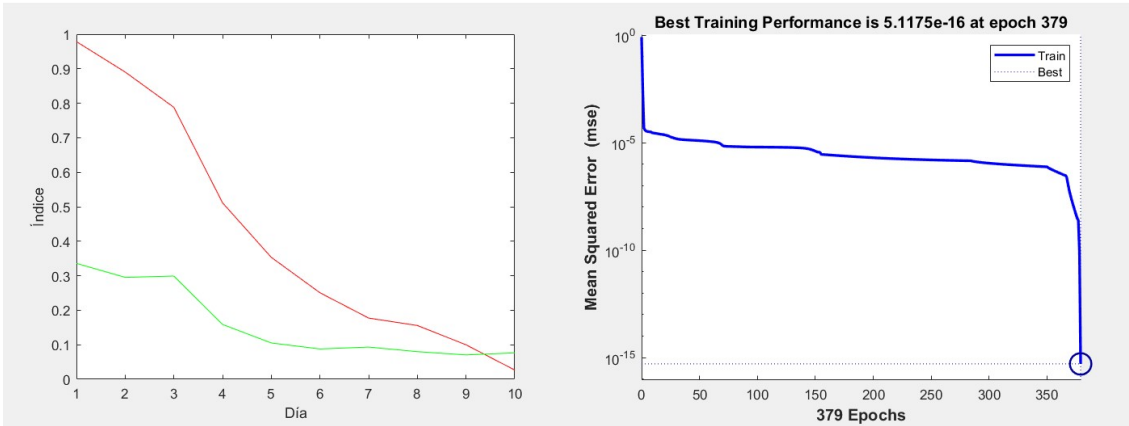


Figura 7.1 Gráfica Ec. 5.1 vs Ec. 4.4 vs red neuronal de la planta 1.

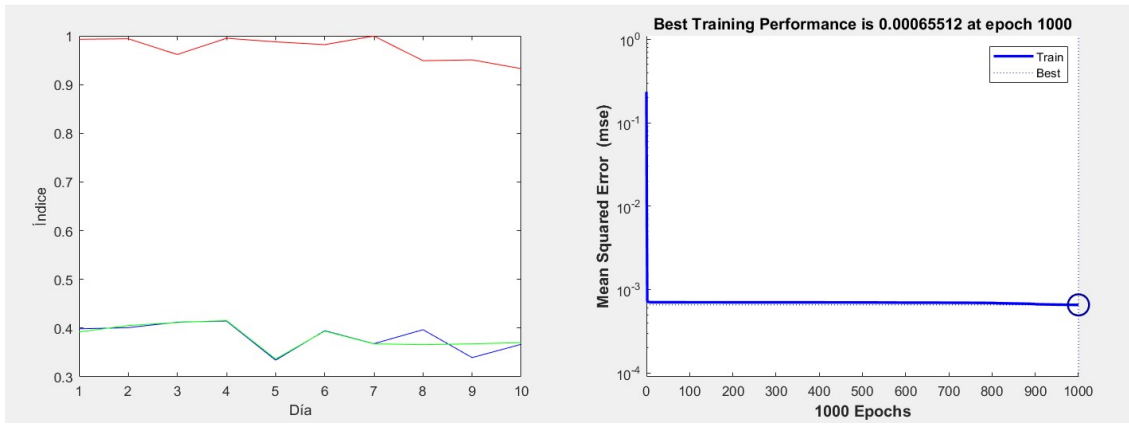


Figura 7.2 Gráfica Ec. 5.1 vs Ec. 4.4 vs red neuronal de la planta 2.




Figura 7.3 Gráfica Ec. 5.1 vs Ec. 4.4 vs red neuronal de la planta 3.




Figura 7.4 Gráfica Ec. 5.1 vs Ec. 4.3 vs red neuronal de la planta 1.




Figura 7.5 Gráfica Ec. 5.1 vs Ec. 4.3 vs red neuronal de la planta 2.




Figura 7.6 Gráfica Ec. 5.1 vs Ec. 4.3 vs red neuronal de la planta 3.

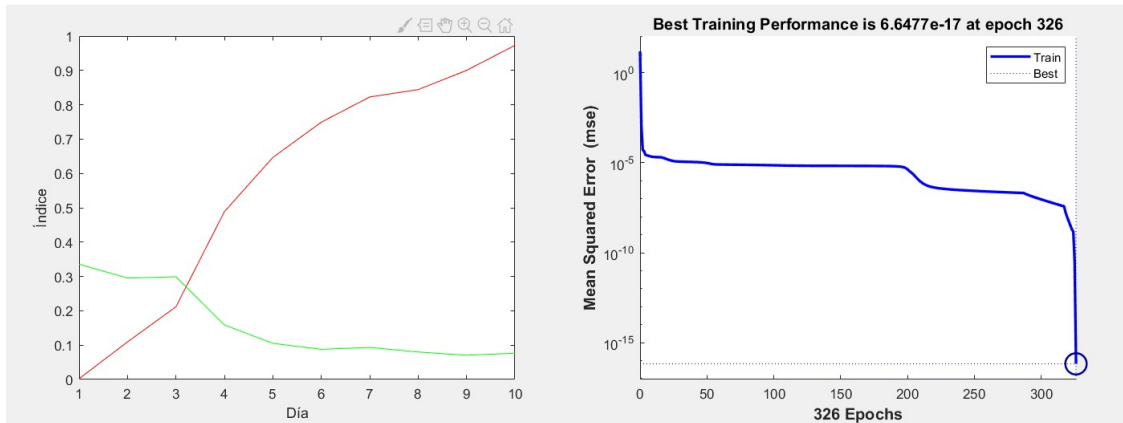


Figura 7.7 Gráfica Ec. 5.1 vs Ec. 4.5 vs red neuronal de la planta 1.




Figura 7.8 Gráfica Ec. 5.1 vs Ec. 4.5 vs red neuronal de la planta 2.




Figura 7.9 Gráfica Ec. 5.1 vs Ec. 4.5 vs red neuronal de la planta 3.

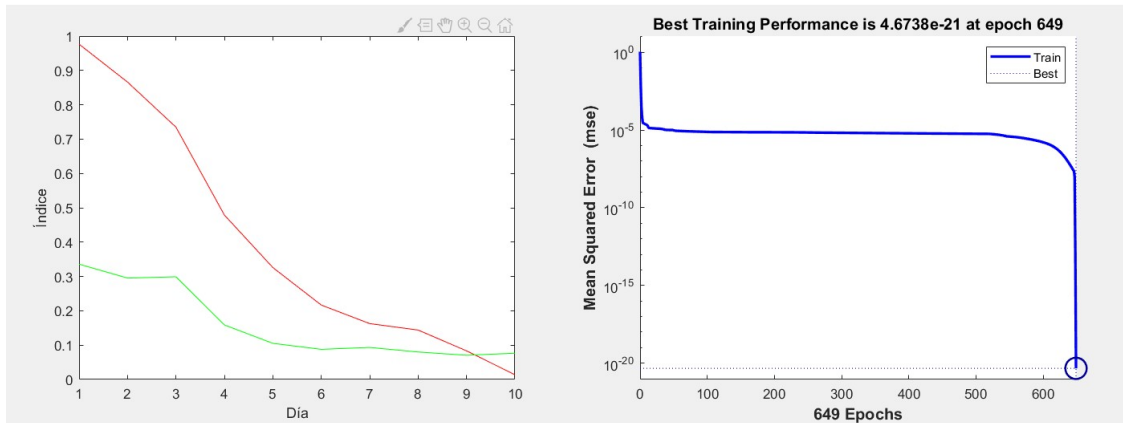


Figura 7.10 Gráfica Ec. 5.1 vs Ec. 4.6 vs red neuronal de la planta 1.




Figura 7.11 Gráfica Ec. 5.1 vs Ec. 4.6 vs red neuronal de la planta 2.

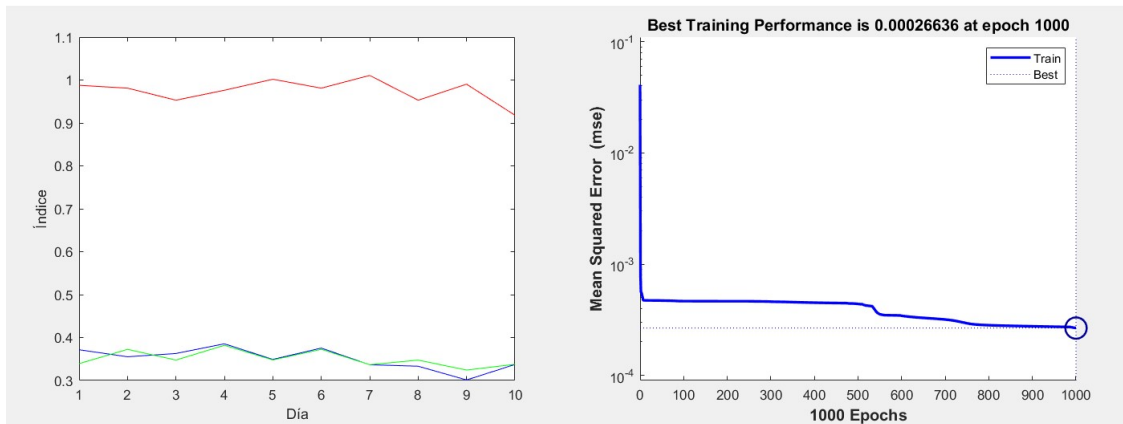


Figura 7.12 Gráfica Ec. 5.1 vs Ec. 4.6 vs red neuronal de la planta 3.

Tabla 7.11 Características del entrenamiento de las redes neuronales.

	Planta	Epoca	Tiempo	Desempeño	Gradiente	Mu
Ec.4.3	1	1000	0:00:01	8.17E-04	5.99E-04	1.00E-06
	2	1000	0:00:01	4.08E-04	3.43E-04	1.00E-07
	3	1000	0:00:01	9.05E-05	2.98E-03	1.00E-07
Ec.4.4	1	379	0:00:02	5.12E-16	4.47E-08	1.00E-11
	2	1000	0:00:01	6.55E-04	9.08E-07	1.00E-05
	3	1000	0:00:01	2.47E-04	8.72E-04	1.00E-06
Ec.4.5	1	326	0:00:00	6.65E-17	3.05E-08	1.00E-11
	2	1000	0:00:01	4.07E-04	8.72E-05	1.00E-06
	3	1000	0:00:01	1.52E-04	2.81E-03	1.00E-07
Ec.4.6	1	649	0:00:01	4.67E-21	7.26E-11	1.00E-10
	2	1000	0:00:01	3.13E-04	1.45E-03	1.00E-06
	3	1000	0:00:01	2.66E-04	1.55E-02	1.00E-07
Promedio		862,8333	1,16E-05	2,7963E-4	2,05352E-3	1,2E-06

Tabla 7.12 Tabla de promedios de desempeño por operación derivada de k-means.

Promedio de desempeño de la Ec.4.3	4.39E-04
Promedio de desempeño de la Ec.4.4	3.01E-04
Promedio de desempeño de la Ec.4.5	1.86E-04
Promedio de desempeño de la Ec.4.6	1.93E-04

Tabla 7.13 Tabla de promedios de desempeño por planta.

Promedio de desempeño en la planta 1	2.04E-04
Promedio de desempeño en la planta 2	4.46E-04
Promedio de desempeño en la planta 3	1.89E-04

Discusión de resultados y conclusiones

El objetivo principal de esta tesis es realizar un análisis comparativo del método de segmentación de imágenes RGB con k-means vs el método que usa el índice de vegetación diferencial normalizado y aproximar sus comportamientos usando redes neuronales para validar la segmentación k-means como método de detección de deshidratación en plantas. Después de observar los datos obtenidos en el experimento se puede mencionar lo siguiente:

- Observando los índices NDVI obtenidos en la tabla 8.2, clasificando los resultados usando la tabla 5.4 y haciendo una evaluación visual sobre el estado de la planta se puede concluir que el método NDVI desarrollado en esta tesis tiene un desempeño satisfactorio para detectar la deshidratación y salud de una planta.
- En la tabla 8.12 se observan los promedios de los errores medios cuadráticos del entrenamiento de la red neuronal para cada ecuación. Mientras más bajos sean significa que el entrenamiento tuvo un mejor desempeño para la ecuación en cuestión y esto a su vez indica que tan bien se puede aproximar al comportamiento del índice NDVI. Se puede concluir que el desempeño del entrenamiento de la red neuronal fue superior con la ecuación 4.5 seguida estrechamente con la ecuación 4.6, luego la ecuación 4.4 y por último la peor fue la ecuación 4.3.
- En la tabla 8.13 podemos observar que el desempeño del entrenamiento fue mejor en la planta 3 (60 ml de riego) estrechamente seguida de la planta 1 (10 ml de riego) y por último la peor fue la planta 2 (30 ml de riego). Esto puede ser debido a que la planta 2 tuvo una baja de área total, hojas a lo largo de los tallos empezaron a quemarse inesperadamente, aún se desconoce la causa.
- Los porcentajes de áreas sanas y áreas muertas o dañadas de la planta que entrega el método de segmentación por k-means no son suficientes para saber el estado de salud de la planta. Dado que estos porcentajes se calculan en base a la cantidad

de follaje detectada, cuando las hojas se marchitan no aparecen en la toma y no se considera en los porcentajes, pero al realizar la operación TTRT se resuelve este problema y se puede correlacionar con el índice NDVI para saber el estado de la planta.

- Las plantas no se comportaron como se proyectó, se tuvo una fluctuación inesperada debido a que algunas de las hojas se marchitaban por alguna razón que se desconoce aparentemente sin relación a la cantidad de riego que se le suministraba.
- La cámara See3_cam cu40 tuvo un desempeño satisfactorio para el cálculo del índice NDVI, pero la falta de compatibilidad con el programa MATLAB dificultó el proceso.

Finalmente teniendo en cuenta los puntos anteriores se puede concluir que fue posible hacer una aproximación entre el comportamiento del método de detección de deshidratación basado en el índice NDVI y del método basado en segmentación K-means usando redes neuronales, logrando así validarlo como índice de detección de deshidratación en plantas.

Trabajo a futuro

- Las tomas de imágenes fueron manuales, se podría buscar en un futuro incorporar la cámara See3_Cam cu40 a la estación de trabajo del proceso automático de k-means.
- Realizar las pruebas con plantas en mejor estado y por más tiempo para ver cómo reacciona el sistema.
- Hacer pruebas con diferentes especies de plantas para aumentar el rango de respuesta de la aproximación y hacer más robusto el sistema.
- Usar un entrenamiento o estructura de la red neuronal más complejos para que aproxime automáticamente el método de K-means al de NDVI sin tener que entrenar la neurona con cada set de datos.

Bibliografía

- [1] Néstor Felipe Chaves-Barrantes, Marco Vinicio Gutiérrez-Soto; Respuestas al estrés por calor en los cultivos. I. aspectos moleculares, bioquímicos y fisiológicos; Agron. Mesoam. 28(1):237-253. 2017 ISSN 2215-3608 doi:10.15517/am.v28i1.21903 (Consultado: 15/11/17).
- [2] Cecilio Pedro SecunzaSchott, Adriana Vargas Flores; 2017; Problemática del agua en la Comarca Lagunera; <http://www.trcimplan.gob.mx/blog/problematika-del-agua-en-la-comarca-lagunera.html>; (Consultado 07/11/2019).
- [3] El Siglo de Torreón; Va en aumento la demanda de alimento en México; <https://www.elsiglodetorreon.com.mx/noticia/1384769.va-en-aumento-la-demanda-de-alimento-en-mexico.html>; (Consultado 29/11/17).
- [4] MA Altieri, CI Nicholls; Cambio Climático y Agricultura Campesina: impactos y respuestas adaptativas; LEISA revista de agroecología, 2009 - socla.co; (Consultado 27/11/17).
- [5] Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación SAGARPA; México: El sector agropecuario ante el desafío del cambio; <http://www.sagarpa.gob.mx/programas2/evaluacionesExternas/Lists/Otros%20Estudios/Attachments/37/Cambio%20Climatico.pdf> ; (consultado 3/12/17).
- [6] Jimena Jaschek; 2017; <http://www.tiloom.com/estres-hidrico-en-las-plantas/>; (Consultado 15/11/17).
- [7] JosepPeñuelas, IolandaFilella, Visible and near-infrared reflectance techniques for diagnosing plant physiological status, Volume 3, Issue 4, P151-156, April 01, 1998. (Consultado 02/10/19).
- [8] Janick, J. et al., "Basil: a source of aroma compounds and a popular culinary and ornamental herb", en *Perspectives on new crops and new uses*. Alexandria, VAASHS Press, 1999. (Consultado 25/10/19).

- [9] Christopher Sullivan, "Herbs", 09 in collage Seminar 235, Food For Thought: The Science, Culture, & Politics of Food, Spring 2009.
http://academics.hamilton.edu/foodforthought/our_research_files/herbs.pdf.
(Consultado 17/11/2019).
- [10] Antonio Amigo, 2015, Tipos de albahaca, <https://www.mundohuerto.com/cultivos/albahaca/tipos>. (Consultado 25/10/19).
- [11] Ahmed, Khalid. (2006). Influence of water stress on growth, essential oil, and chemical composition of herbs (*Ocimum* sp.). *International Agrophysics*. 20. (Consultado 17/11/2019).
- [12] Jerez Mompie, Eduardo & Barroso, L. (2002). Comportamiento de la albahaca blanca (*Ocimum basilicum* L.) ante reducciones de las cantidades de agua aplicada por fases del desarrollo. *Cultivos Tropicales*. 23. 39-46. (Consultado 17/11/2019).
- [13] J. Jiang et al., "What is the space of spectral sensitivity functions for digital color cameras?" 2013 IEEE Workshop on Applications of Computer Vision (WACV), Tampa, FL, 2013, pp. 168-179. (Consultado 02/10/19).
- [14] Y. Pritch et al. "Webcam Synopsis: Peeking Around the World," 2007 IEEE 11th International Conference on Computer Vision, Rio de Janeiro, 2007, pp. 1-8. (Consultado 19/10/19).
- [15] Yanitza Matos Frómeta, 2012, Cámara web, https://www.ecured.cu/Cámara_Web. (Consultado 19/10/19).
- [16] Zhenyue Chen et al., RGB-NIR multispectral camera, *OPTICS EXPRESS* Vol. 22, 2014. (Consultado 20/10/19).
- [17] Gholamreza Anbarjafari; Digital Image Processing; <https://sisu.ut.ee/imageprocessing/book/1>; (Consultado 27/11/07).
- [18] Microsoft, 2019, <https://www.microsoft.com/accessories/es-es/d/lifecam-hd-6000-for-notebooks>. (Consultado 20/10/19).
- [19] e-con Systems, 2019, <https://www.e-consystems.com/OV4682-RGB-IR-USB3-camera.asp>. (Consultado 20/10/19).

[20] Yemil Avilés de León, 2014, "Estación de Trabajo Automática para el Monitoreo de Plantas", Instituto Tecnológico de La Laguna, Torreón, Coahuila. México. (Consultado 20/10/19).

[21] Ing. Jorge Iván Galicia Reyes, 2015, "Aplicación para control vía remota, integración de sensores y sistema de riego a invernadero de pruebas automático para el monitoreo de plantas", Instituto Tecnológico de La Laguna, Torreón, Coahuila. México. (Consultado 20/10/19).

[22] T. N. Tete and S. Kamlu, "Detection of plant disease using threshold, k-mean cluster and ann algorithm," 2017 2nd International Conference for Convergence in Technology (I2CT), Mumbai, 2017, pp. 523-526. (Consultado 22/10/19).

[23] R. Anand, S. Veni and J. Aravinth, "An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method," 2016 International Conference on Recent Trends in Information Technology (ICRTIT), Chennai, 2016, pp. 1-6.

[24] TokkieGroenewald et al.; Espectroscopia de Infrarrojo Cercano (NIRs) - La técnica de análisis rápidos del futuro; <https://www.tesisenred.net/bitstream/handle/10803/3316/apg1de1.pdf?sequence=1> ; (consultado 07/08/2019).

[25] Fernando Paz Pellat et al.; Alcances y limitaciones de los índices espectrales de la vegetación: marco teórico; http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0187-57792014000300177; (consultado 08/08/2019).

[26] Pedro Muñoz Aguayo; Apuntes de Teledetección: Índices de vegetación; <http://bibliotecadigital.ciren.cl/bitstream/handle/123456789/26389/Tema%20Indices%20de%20vegetaci%C3%B3n%20Pedro%20Mu%C3%B1oz%20A.pdf?sequence=1&isAllowed=y>; (consultado 08/08/2019).

[27] Wang, Xinbing& Miao, Yuxin& Guan, Yanjie& Xia, Tingting& Lu, Junjun& Mulla, David. (2018). An Evaluation of Two Active Canopy Sensor Systems for Non-destructive Estimation of Spring Maize Biomass. (Consultado 18/11/2019).

[28] Rizki Wahyu Pratama, et al. 4th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI), Yogyakarta, 2017, pp. 1-4. (Consultado 28/10/2019).

[29] Felipe Lara Rosano; Fundamentos de Redes Neuronales Artificiales; http://conceptos.sociales.unam.mx/conceptos_final/598trabajo.pdf; (consultado 4/12/2017).

[30] Michael Nielsen, 2019, Introducing neural networks and deep learning, <http://neuralnetworksanddeeplearning.com>. (Consultado 28/10/2019)

[31] Pedro Almagro Blanco, 2016, Algoritmo de Retro propagación, http://www.cs.us.es/~fsancho/ficheros/IAML/2016/Sesion04/capitulo_BP.pdf. (Consultado 28/10/2019).

[32] VankadaraNvd Manohar et al., 2007, Function approximation using back propagation algorithm in artificial neural networks, Department of Electrical Engineering National Institute of Technology Rourkela. (Consultado 28/10/2019).

[33] Genik W. (2016) What is NDVI? <https://www.greenaerotech.com/what-is-ndvi/>. (Consultado 19/11/2019).