



UNIVERSIDAD AUTÓNOMA CHAPINGO

---

---

DEPARTAMENTO DE IRRIGACIÓN E INGENIERÍA MECÁNICA AGRÍCOLA

POSGRADO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

MONITOREO DEL ESTRÉS HÍDRICO EN CULTIVO DE MAÍZ (*Zea mays* L.) MEDIANTE IMAGENES MULTIESPECTRALES DE UN VEHÍCULO AÉREO NO TRIPULADO

## TESIS

Que como requisito parcial para obtener el grado de:  
**DOCTOR EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA**

Presenta:

**MISAE LÓPEZ HERNÁNDEZ**

Bajo la supervisión de: **RAMÓN ARTEAGA RAMÍREZ, DR.**

Chapingo, Estado de México, a septiembre de 2021.

---

---



**APROBADA**



# MONITOREO DEL ESTRÉS HÍDRICO EN CULTIVO DE MAÍZ (*Zea mays* L.) MEDIANTE IMÁGENES MULTIESPECTRALES DE UN VEHÍCULO AÉREO NO TRIPULADO

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

## DOCTOR EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA.

DIRECTOR:

---

Dr. Ramón Arteaga Ramírez

CODIRECTOR:

---

Dr. Héctor Flores Magdaleno

ASESOR:

---

Dr. Mario Alberto Vázquez Peña

ASESOR:

---

Dr. Agustín Ruíz García

LECTOR EXTERNO:

---

Dr. Abel Quevedo Nolasco

## CONTENIDO

1	INTRODUCCIÓN GENERAL .....	1
1.1	Importancia del problema investigado.....	1
1.2	Antecedentes.....	2
1.3	Justificación .....	3
1.4	Hipótesis.....	5
1.5	Objetivo general.....	5
1.5.1	Objetivos específicos .....	5
1.6	Breve presentación de cada uno de los capítulos .....	5
1.7	Literatura citada .....	6
2	REVISIÓN DE LITERATURA .....	9
2.1	Aplicaciones del procesamiento de imágenes en la agricultura .....	9
2.1.1	Estimación y predicción de biomasa y rendimiento .....	9
2.1.2	Identificación del estrés hídrico .....	11
2.1.3	Detección de enfermedades, plagas y malezas .....	15
2.1.4	Estimación del coeficiente de cultivo “Kc” .....	18
2.2	Índices de vegetación utilizados para identificar el estrés hídrico en el cultivo de maíz .....	21
2.3	Literatura citada .....	35
3	MONITOREO DE ESTRÉS HÍDRICO MEDIANTE ÍNDICES DE VEGETACIÓN EN UN CULTIVO DE MAÍZ ( <i>Zea mays</i> L.).....	40
3.1	Resumen .....	40
3.2	Introducción .....	41
3.3	Materiales y métodos.....	45
3.4	Resultados y discusión .....	51
3.4.1	Índices de vegetación.....	51
3.4.2	CWSI-TR.....	56
3.4.3	Materia seca y rendimiento .....	58

3.5	Conclusiones .....	60
3.6	Literatura citada .....	61
4	PREDICCIÓN DE LA ACUMULACIÓN DE MATERIA SECA Y RENDIMIENTO DEL CULTIVO DE MAÍZ ( <i>Zea mays</i> ) MEDIANTE ÍNDICES DE VEGETACIÓN. ....	64
4.1	Resumen .....	64
4.2	Introducción .....	65
4.3	Materiales y métodos.....	67
4.4	Resultados y discusión .....	72
4.4.1	GUI en Matlab .....	72
4.4.2	Predicción de la producción de materia seca y rendimiento .....	73
4.4.3	Mapeo de la producción de materia seca y rendimiento .....	76
4.4.4	Mapeo del coeficiente de cultivo Kc y ETc .....	78
4.4.5	Aplicación de una red neuronal artificial para la predicción de materia seca y rendimiento. ....	83
4.5	Conclusiones .....	85
4.6	Literatura citada .....	86
5	CONCLUSIONES GENERALES .....	89

## INDICE DE CUADROS

Cuadro 2-1. Índices de vegetación utilizados por Zhuang and Zhou (2019).....	26
Cuadro 3-1. Índices de vegetación calculados mediante el procesamiento de imágenes multiespectrales. ....	48
Cuadro 3-2. Valores de índices de vegetación de la imagen sin segmentar. ....	53
Cuadro 3-3. Valores de índices de vegetación para píxeles cubiertos de cultivo de maíz.....	54
Cuadro 3-4. Valores medios de CWSI-TR para los tratamientos de riego.....	56
Cuadro 3-5. Relación entre los IV y el CWSI-TR del cultivo de maíz. ....	57
Cuadro 3-6. Producción media de materia seca por planta (en gramos) para los tratamientos evaluados.....	59
Cuadro 4-1. Estadísticas de los modelos evaluados para estimar la producción media de materia seca por planta en gramos (g). ....	74
Cuadro 4-2. Estadísticas de los modelos evaluados para estimar el rendimiento de maíz en ton ha <sup>-1</sup> . ....	75
Cuadro 4-3. Modelos seleccionados para estimar la producción de materia seca y el rendimiento de maíz. ....	75
Cuadro 4-4. Estadísticas de los modelos MRLM para estimar el rendimiento final de maíz en ton ha <sup>-1</sup> . ....	76
Cuadro 4-5. Resultados de la prueba de medias de Tukey para el Kc y ETc....	83
Cuadro 4-6. Pesos implementados en las RNAs para la predicción de materia seca por planta y rendimiento. ....	83
Cuadro 4-7. Bias implementados en las RNAs para la predicción de materia seca por planta y rendimiento del cultivo de maíz. ....	84

## INDICE DE FIGURAS

Figura 3-1. VANT “3DR solo” equipado con un sensor multiespectral Parrot Sequoia utilizado para obtener imágenes de alta resolución espacial. ....	47
Figura 3-2. Diagrama de flujo del análisis estadístico para los índices de vegetación, materia seca y rendimiento. ....	51
Figura 3-3. Valores medios de reflectancia normalizada de los tratamientos 1, 2 y 3 (50, 75 y 100% de ETc). ....	58
Figura 4-1. Recopilación de datos de materia seca y rendimiento final para el cultivo de maíz. ....	68
Figura 4-2. Toma de imágenes del “calibration target” con el del sensor Parrot Sequoia antes de realizar los vuelos. ....	69
Figura 4-3. Procesamiento de una imagen multiespectral con la GUI de Matlab. ....	70
Figura 4-4. GUI diseñada en el entorno de Matlab para el procesamiento de imágenes multiespectrales. ....	73
Figura 4-5. Mapas de producción materia seca por planta obtenidos mediante la GUI de Matlab. ....	77
Figura 4-6. Mapas de rendimiento obtenidos mediante la GUI de Matlab. ....	78
Figura 4-7. Mapas del coeficiente de cultivo $K_{C-1}$ y $K_{C-2}$ obtenidos mediante la GUI de Matlab. ....	79
Figura 4-8. Relación entre el coeficiente de cultivo ( $K_c$ ) observado y los estimados mediante las metodologías de Cuesta et al. (2005) y Zhang et al. (2019). ....	80
Figura 4-9. Relación entre la evapotranspiración del cultivo (ETc) observado y la ETc estimada mediante $K_{C-1}$ y $K_{C-2}$ . ....	80
Figura 4-10. Mapas de evapotranspiración del cultivo, para $ET_{C-1}$ y $ET_{C-2}$ obtenidos mediante la GUI de Matlab. ....	81
Figura 4-11. Mapas de coeficiente de cultivo y evapotranspiración del maíz derivados del modelo $K_c$ GNDVI obtenidos mediante la GUI de Matlab. ....	82

Figura 4-12. Mapas de materia seca por planta (izquierda) y de rendimiento del maíz (derecha) obtenidos mediante las RNAs implementadas en la GUI de Matlab.....85

**“Cada día sabemos más y entendemos menos”**

**Por Albert Einstein.**

## **DEDICATORIA**

A mi mamá Matilde Hernández Romero y mi papá Perfecto López de Jesús quienes me han dado la confianza para alcanzar las metas propuestas y retos.

A mis hijos Jared Misael y Jesús Ismael López Fleisher, mi impulso para afrontar nuevos retos.

A mis hermanas y hermanos quienes siempre tienen una anécdota que contar y encuentran lo gracioso en cada una de ellas.

A todas las personas que ayudaron a cumplir este objetivo.

## **AGRADECIMIENTOS**

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico brindado durante mis estudios de Doctorado.

A la Universidad Autónoma Chapingo por darme la oportunidad de realizar mis estudios de educación medio superior, superior y posgrado.

Al Posgrado en Ingeniería Agrícola y Uso Integral del Agua por el apoyo brindado durante todo el periodo de Doctorado.

Al Dr. Mauricio Carrillo y al Dr. Martín Hidalgo Reyes, por su apoyo.

Al Dr. Ramón Arteaga Ramírez por su confianza, asesoría, por sus acertadas recomendaciones, pero sobre todo por su excelente dirección.

Al Dr. Héctor Flores Magdaleno por sus recomendaciones y apoyo con los vehículos aéreos no tripulados, cámaras, sensores, recursos humanos y software necesarios para la toma y procesamiento de imágenes multiespectrales.

Al Dr. Mario Alberto Vázquez Peña por su asesoría en el análisis estadístico de los datos obtenidos.

Al Dr. Agustín Ruíz García por sus aportaciones a la presente investigación.

A todos los profesores de la Preparatoria Agrícola, del Departamento de Suelos y del Posgrado en Ingeniería Agrícola y Uso Integral del Agua de la Universidad Autónoma Chapingo, que contribuyeron en mi formación académica.

A los departamentos de Fitotecnia, Mecánica Agrícola e Irrigación, que me apoyaron en los trabajos de campo y facilitaron equipo para poder realizar trabajos de laboratorio.

A todo el personal administrativo y operativo que contribuyó de alguna forma con este logro.

A mi familia por creer en mí y alentarme siempre en cada reto que se me presenta.

“La realización de este trabajo de investigación se realizó gracias al apoyo económico obtenido mediante el proyecto convencional titulado: Estrés hídrico y su efecto en el rendimiento de maíz con sensores remotos, con clave: 19360-C-65”.

## **DATOS BIOGRÁFICOS DEL AUTOR**



El autor de la presente tesis es originario del estado de Puebla, nació el 02 de abril de 1988 en el municipio de Tlatlauquitepec, sus estudios de educación básica los realizó en su comunidad Mazatepec. En enero de 2003 ingresó a la Universidad Autónoma Chapingo donde realizó sus estudios de nivel medio superior en el Departamento de Preparatoria Agrícola, egresó en el año 2011 del departamento de Suelos de la Universidad Autónoma Chapingo, obteniendo el título como Ingeniero en Recursos Naturales Renovables, con No. de cédula profesional: 09112503, que le permite ejercer dicha profesión. En agosto de 2015 ingresó al Programa de Posgrado en Ingeniería Agrícola y Uso Integral del Agua en la Universidad Autónoma Chapingo, para realizar estudios de Maestría en la línea de investigación de Uso Integral del Agua y culminó en Julio del 2017, obteniendo el grado de Maestro en Ingeniería Agrícola y Uso Integral del Agua, con No. de cédula profesional: 11049794, que le permite ejercer dicha profesión. En el ámbito profesional trabajó en proyectos institucionales de la Universidad Autónoma Chapingo, como técnico de campo, prestador de servicios profesionales, residente de obra y como superintendente de construcción en convenio con la CONAGUA, SAGARPA y la CONAFOR entre 2011 y 2013. Como asesor técnico FIRA en convenio con la SEDAGROH entre 2013 y 2015, como consultor externo del CIMMYT Int., de junio a diciembre de 2014. En agosto de 2017 ingresó al Programa de Posgrado en Ingeniería Agrícola y Uso Integral del Agua en la Universidad Autónoma Chapingo, para realizar estudios de Doctorado en la línea de investigación de Uso Integral del Agua.

## RESUMEN GENERAL

### **MONITOREO DEL ESTRÉS HÍDRICO EN CULTIVO DE MAÍZ (*Zea mays* L.) MEDIANTE IMÁGENES MULTIESPECTRALES DE UN VEHÍCULO AÉREO NO TRIPULADO**

El cultivo de Maíz para grano se cultiva en todas las entidades federativas del país, principalmente para consumo humano, autoconsumo, uso pecuario y como semilla para siembra. La agricultura es una de las actividades productivas que más se verá perjudicada por causa del impacto del cambio climático, afectando el estado hídrico de los cultivos, disminuyendo su productividad. El monitoreo del estado hídrico de los cultivos se ha desarrollado mediante el uso de imágenes de satélite o de vehículos aéreos no tripulados (VANT) en combinación con técnicas de teledetección. En la presente investigación, se estableció un experimento de maíz con tres tratamientos de riego complementario: 100%, 75% y 50% de la Evapotranspiración del cultivo (ETc), las láminas fueron aplicadas mediante un sistema de riego por goteo superficial. La presente investigación permitió identificar las etapas del cultivo en las que se presentó estrés hídrico, a partir del cálculo de índices de vegetación (IV) con el procesamiento de imágenes multiespectrales de alta resolución espacial adquiridas mediante el sensor Parrot Sequoia acoplado a un VANT. Además, se determinaron modelos de predicción de materia seca por planta y rendimiento del cultivo. También, fue posible el mapeo de las variables biofísicas medidas, el coeficiente de cultivo Kc y la ETc. Lo anterior permitiría el monitoreo y manejo del riego del cultivo de maíz.

**Palabras clave:** Índices de vegetación, Rendimiento, Materia seca, *Zea mays* L., Predicción.

Tesis de Doctorado en Ingeniería

Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Misael López Hernández

Director de Tesis: Ramón Arteaga Ramírez

## GENERAL ABSTRACT

### MONITORING OF WATER STRESS IN CORN CROPS (*Zea mays* L.) THROUGH MULTISPECTRAL IMAGES OF AN UNMANNED AERIAL VEHICLE

The cultivation of corn crop is grown in all states of the country, mainly for human consumption, self-consumption, livestock use and as seed for sowing. Agriculture is one of the productive activities that will be most affected by the impact of climate change, affecting the water status of crops, reducing their productivity. The monitoring of the water status of crops has been developed by satellite images or unmanned aerial vehicles (UAV) in combination with remote sensing techniques. In the present research, a corn experiment was established with three complementary irrigation treatments: 100%, 75% and 50% of the Evapotranspiration of the crop (ET<sub>c</sub>), the sheets were applied by means of a superficial drip irrigation system. The present research allowed to identify the crop stages in which water stress was presented from the calculation of vegetation indices (VI) with the processing of multispectral images acquired using the Parrot Sequoia sensor coupled to an UAV. In addition, prediction models of dry matter per plant and crop yield were determined. Also, it was possible to map the biophysical variables measured, the culture coefficient K<sub>c</sub> and ET<sub>c</sub>. This would allow the monitoring and management of the irrigation of the corn crop.

**Keywords:** Vegetation indices, Yield, Dry matter, *Zea mays* L., prediction.

Tesis de Doctorado en Ingeniería

Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Misael López Hernández

Director de Tesis: Ramón Arteaga Ramírez

# 1 INTRODUCCIÓN GENERAL

## 1.1 Importancia del problema investigado

El cultivo de Maíz para grano es el cereal primordial en la dieta de los mexicanos y se cultiva en todas las entidades federativas del país con un consumo anual per cápita de 335.8 kg. En 2019 México fue el 8° productor mundial, ocupa el 12° lugar en producción mundial de alimentos y el 11° lugar en producción mundial de cultivos agrícolas, sin embargo, es el mayor importador de maíz grano (SIAP, 2020).

En el ciclo 2018/2019 el 52.7% de la producción se obtuvo en condiciones de temporal y el 47.3% de riego, se alcanzó un rendimiento promedio para maíz blanco de 8.6 y 2.5 ton ha<sup>-1</sup>, para superficie bajo el régimen de riego y temporal, respectivamente. El maíz blanco se utiliza principalmente para consumo humano, siendo el Estado de México uno de los principales productores de maíz a nivel nacional, presentó la mayor reducción en su producción en 2018, con una tasa anual de 13.4%, así como de la superficie cosechada y rendimientos, los cuales se redujeron en los últimos dos años tanto en superficies de riego como de temporal (FIRA, 2019).

Escenarios futuros de cambio climático predicen un incremento en la temperatura y la variabilidad de la precipitación, además se agudizará la presencia de fenómenos como las sequías, inundaciones, heladas, etc. Siendo la agricultura una de las actividades que más se verá vulnerada por causa del impacto del cambio climático, afectando el estado hídrico y por ende la productividad de los cultivos.

El estrés hídrico se desarrolla ante la ausencia de lluvia y riego, y cuando el agua almacenada en la zona radicular se agota hasta el punto en que los procesos de la planta se ven afectados. El estrés reduce la conductancia estomática y acelera la senescencia de las hojas más viejas, la transpiración y fotosíntesis del cultivo se reduce debido a la reducción del crecimiento (o al aumento de la senescencia) del dosel y de una menor conductancia estomática, ocasionando reducción de la tasa de producción de biomasa y la disminución del rendimiento de grano. Otro

efecto es que la aceleración de la senescencia del dosel disminuiría la duración de este y acortaría el período de llenado del grano, sin dar el tiempo suficiente para que el índice de cosecha alcance su nivel máximo normal, provocando que la reducción del rendimiento del grano sea incluso mayor a la reducción de la producción de la biomasa (Steduto, Raes, Hsiao, Fereres y Heng, 2012).

Para el cultivo de maíz las etapas de floración y formación del rendimiento son sensibles al estrés, mientras que el valor del factor de respuesta del rendimiento ( $K_y$ ) es mayor cuando el déficit de agua se presenta durante el desarrollo del cultivo (igual a 1.5), lo cual implica que la disminución del rendimiento es proporcionalmente mayor que la disminución del uso del agua debido al estrés. Sus efectos impactan en el crecimiento del dosel, la conductancia estomática, la senescencia del dosel, la profundización de las raíces y el índice de cosecha, la expansión foliar (por ende, el dosel) es el más sensible al estrés hídrico, si el estrés es lo suficientemente severo puede provocar y acelerar la senescencia del dosel en cualquier momento durante el ciclo biológico del cultivo, dichos procesos conducen a la producción de biomasa, de los cuales depende el rendimiento. Los efectos negativos directos del estrés hídrico son la inhibición de la polinización y la formación del embrión (Steduto et al., 2012).

## **1.2 Antecedentes**

El uso de imágenes satelitales procesadas con Sistemas de Información Geográfica (SIG) y su combinación con información meteorológica, permite estimar el consumo de agua de los cultivos y estimar en forma aproximada el rendimiento (Zenteno, Palacios, Tijerina y Flores, 2017).

La Estación de Recepción México (ERMEX) recibe telemetría directa de la constelación de Satélites para la Observación de la Tierra (SPOT), de la empresa AIRBUS Defence & Space, este proyecto permite el monitoreo permanente del territorio en conjunto entre la Secretaría de Agricultura y Desarrollo Rural (SADER), a través del Servicio de Información Agroalimentaria y Pesquera (SIAP) y la Secretaría de la Defensa Nacional (SEDENA). Mediante el cual

desarrollan aplicaciones de: agricultura, seguridad nacional, recursos naturales, desastres naturales, catastro, planificación urbana, monitoreo marítimo, contaminación marina, gestión del territorio, monitoreo de instalaciones estratégicas, cartografía, dinámica territorial y modelación 3D. Además, permite la conformación del "Conjunto de Datos Vectoriales de la Frontera Agrícola de México" escala 1:10,000, Mediante técnicas de interpretación visual y procesamiento digital de imágenes satelitales, este es un insumo fundamental para la toma de decisiones y para la elaboración de políticas públicas en beneficio del sector rural, ya que es utilizado para realizar análisis y estudios de impacto ambiental, económico, social y desarrollo sustentable para los sectores gubernamental, académico y privado a nivel nacional e internacional, y también ha sido posible detectar cambios en el uso de suelo (SIAP, 2020).

### **1.3 Justificación**

Salas, Grueso y Bernal (2020) mencionan que el uso de vehículos no tripulados en comparación con la agricultura tradicional permite el manejo eficiente de cultivos, riego controlado, acople con sensores remotos e internet de las cosas, aplicación de agroquímicos controlada, identificación de afectaciones y protección de cultivos. El SIAP emplea los Sistemas Aéreos no Tripulados para el monitoreo de las superficies agropecuarias afectadas en caso de siniestro por la ocurrencia de fenómenos naturales, tales como inundaciones, heladas, fuertes vientos, lluvia severa y granizadas, que permite cuantificar los daños con exactitud y de manera oportuna. Los técnicos geoespaciales integran la información estratégica agroalimentaria en el desarrollo de importantes proyectos, utilizando Sistemas de Información Geográfica (SIG), en conjunto con información georreferenciada (tecnología GPS) de imágenes satelitales y de vehículos aéreos no tripulados (VANT), para generar la oferta estadística (SIAP, 2020).

Los VANT se han utilizado para estimar la biomasa y rendimiento de los cultivos, así como también la cobertura vegetal y densidad de plantas mediante el procesamiento de imágenes RGB y multiespectrales (García et al., 2020). Los

índices son calculados a partir de la información espectral de la fracción de vegetación, este tipo de herramientas ha permitido en algunos casos calcular recomendaciones de fertilización con nitrógeno (Padilla, Gallardo, Peña, De Souza & Thompson, 2018) y estimar su contenido en las hojas de las plantas (Elvanidi, Katsoulas, Augoustaki, Loulou, & Kittas, 2018), mediante la modelación con el uso de índices de vegetación (como el NDVI) como valor de entrada (Tagarakis & Ketterings, 2018).

La escasez del recurso hídrico requiere un uso eficiente del agua en la agricultura, que permita incrementar la productividad por unidad de volumen de agua. Lo mencionado determina la necesidad de obtener metodologías para estimar el nivel de estrés hídrico y a su vez la predicción temprana del rendimiento de los cultivos. Existen técnicas de teledetección que en combinación con sensores remotos permite el seguimiento del crecimiento y desarrollo de la vegetación, mediante la aplicación de relaciones empíricas calculadas entre las variables biofísicas de la vegetación y los índices de vegetación (IV).

La agricultura de precisión (AP) puede proporcionar información del dosel agrícola, como elemento crítico para describir y predecir la productividad de manera confiable a partir de modelos matemáticos, que sirvan para tomar decisiones en relación con el manejo de insumos y las prácticas de gestión (Aguilar, 2015). Las plantas en estado saludable reflejan gran cantidad de energía en el rango del infrarrojo cercano, mientras que las plantas enfermas reflejan más en el rojo, esto ha permitido determinar e identificar fácilmente problemas de cultivos al determinar índices de vegetación como el NDVI (Berrío, Mosquera & Alzate, 2015).

Quille, Ramos, Ontiveros, Ojeda y Jorge (2019) mencionan que el uso de índices de vegetación es viable para la detección temprana el estrés hídrico en los cultivos. El uso de sensores multiespectrales tiene potencial para comprender el

estrés hídrico, lo cual permitiría tomar decisiones de producción casi en tiempo real (Zúñiga, 2018).

#### **1.4 Hipótesis**

El estrés hídrico del cultivo de maíz se puede identificar con el uso de índices de vegetación obtenidos a partir del procesamiento de imágenes multiespectrales obtenidas con un vehículo aéreo no tripulado (VANT).

#### **1.5 Objetivo general**

Validar una metodología para monitorear el estrés hídrico de un cultivo de maíz mediante el procesamiento de imágenes multiespectrales obtenidas con un vehículo aéreo no tripulado.

##### **1.5.1 Objetivos específicos**

- Determinar la relación de los índices de vegetación (IV) con los niveles de estrés hídrico en el cultivo de maíz.
- Predecir variables biofísicas del cultivo mediante índices de vegetación.

#### **1.6 Breve presentación de cada uno de los capítulos**

En el capítulo dos se presenta una revisión de literatura acerca de las aplicaciones del procesamiento de imágenes en la agricultura sobre la estimación y predicción de la biomasa y rendimiento de los cultivos, la identificación del estrés hídrico, la detección de enfermedades y malezas, la estimación del coeficiente de cultivo (Kc), así como también se muestran los índices de vegetación utilizados en trabajos de investigación para identificar el estrés hídrico en el cultivo de maíz.

El capítulo tres se estudia la relación entre los IV y el estrés hídrico en el cultivo de maíz, mientras que en el capítulo cuatro se indican los modelos obtenidos para predecir el rendimiento de maíz a partir de IV, además de los mapas temáticos obtenidos para materia seca por planta, rendimiento, coeficiente de cultivo Kc y de evapotranspiración del cultivo (ETc). Finalmente, en el capítulo cinco se presentan las conclusiones generales de la investigación.

## 1.7 Literatura citada

- Aguilar R., N. (2015). Percepción remota como herramienta de competitividad de la agricultura. *Rev. Mex. Cienc. Agríc.*, 6, 399-405.
- Berrío M., V. A., Mosquera T., J. y Alzate V., D. F. (2015). Uso de drones para el análisis de imágenes multiespectrales en agricultura de precisión. *Ciencia y Tecnología Alimentaria*, 13, 28-40.
- Elvanidi, A., Katsoulas, N., Augoustaki, D., Loulou, I. & Kittas, C. (2018). Crop reflectance measurements for nitrogen deficiency detection in a soilless tomato crop. *Biosystems Engineering*, 176, 1-11.
- FIRA (Fideicomisos Instituidos en Relación con la Agricultura). (2019). Panorama Agroalimentario Maíz 2019. Consultado en: <https://www.inforural.com.mx/wp-content/uploads/2019/11/Panorama-Agroalimentario-Ma%C3%ADz-2019.pdf>.
- García M., H., Flores M., H., Ascencio H., R., Khalil G., K., Tijerina C., L., Mancilla V., O. R. & Vázquez P., M. A. (2020). Corn Grain Yield Estimation from Vegetation Indices, Canopy Cover, Plant Density, and a Neural Network Using Multispectral and RGB Images Acquired with Unmanned Aerial Vehicles. *Agriculture*, 10, 1-24.
- Padilla, F. M., Gallardo, M., Peña F., M. T., De Souza, R. & Thompson, R. B. (2018). Proximal Optical Sensors for Nitrogen Management of Vegetable Crops: A Review. *Sensors*, 18, 1-23.
- Tagarakis, A. C. & Ketterings, Q. M. (2018). Proximal sensor-based algorithm for variable rate nitrogen application in maize in northeast U.S.A. *Computers and Electronics in Agriculture*, 145, 373-378.
- Quille M., J. A., Ramos F., L., Ontiveros C., R. E., Ojeda B., W. y Jorge P., Z. R. (2019). Relación de la altura de planta del cultivo de arroz bajo estrés hídrico con índices de vegetación obtenidas de imágenes de dron [Artículo]. Quinto Congreso Nacional COMEII 2019, Mazatlán, Sin.
- Salas C., W. R., Grueso C., S. y Bernal S., D. P. (2020). Agricultura sostenible como alternativa de control y mitigación de impactos ambientales. *Especialización en Control de la Contaminación Ambiental*, 1-16.
- SIAP (SERVICIO DE INFORMACIÓN AGROALIMENTARIA Y PESQUERA). 2020. Panorama Agroalimentario 2020. Consultado en: <https://www.inforural.com.mx/wp-content/uploads/2020/11/Atlas-Agroalimentario-2020.pdf>.
- Steduto, P, Raes, D., Hsiao, T. C., Fereres, E. y Heng, L. (2012). Respuesta del rendimiento de los cultivos herbáceos al agua. Consultado en: [www.fao.org/publications](http://www.fao.org/publications).
- Zenteno C., G. A., Palacios V., E., Tijerina C., L. y Flores M., H. (2017). Aplicación de tecnologías de percepción remota para la estimación del rendimiento en caña de azúcar. *Rev. Mex. Cienc. Agríc.*, 8, 1575-1586.

Zúñiga E., C. (2018). Evaluation of water stress in horticultural crops using proximal and remote sensing techniques. (Tesis doctoral, WASHINGTON STATE UNIVERSITY).

## 2 REVISIÓN DE LITERATURA

### 2.1 Aplicaciones del procesamiento de imágenes en la agricultura

#### 2.1.1 Estimación y predicción de biomasa y rendimiento

Ruíz et al. (2005) realizaron una clasificación supervisada de la superficie cultivada con el cultivo de la cebada (*Hordeum vulgare* L.) en imágenes de satélite Landsat 7 y MODIS y obtuvieron mediante un análisis de regresión una ecuación lineal entre el rendimiento y los índices de vegetación, con un  $R^2$  de 0.88 y 0.93 para los índices NDVI y EVI, respectivamente, para los píxeles que estaban cubiertos en 100% por cultivo. Soria, Fernández and Granados (2004), realizaron una máscara digital en formato vectorial garantizando que cualquier píxel seleccionado estuviera rodeado de maíz (de las imágenes NOAA-AVHRR) y a partir de los datos multitemporales de NDVI lograron predecir el rendimiento de grano con una probabilidad del 78.9%.

Farrell y Rivas (2010) utilizaron imágenes captadas por el sensor MODIS-TERRA, al relacionar el rendimiento Girasol a nivel lote y regional con el índice de vegetación Enhanced Vegetations Index (EVI, por sus siglas en inglés), determinaron un modelo de regresión lineal con una correlación positiva de 0.79.

Por su parte, Ocampo, Rivas, Carmona, Figueredo y Palazzani (2011) lograron estimar el rendimiento del trigo en el momento del espigado mediante una función exponencial, en donde utiliza los valores de NDVI como valor de entrada, indican que la resolución (30 x 30 m) en imágenes captadas por el sensor Thematic Mapper (Landsat 5) es apropiada para su uso en agricultura de precisión en parcelas de 2 ha de extensión. En otros cultivos como la caña de azúcar, se han utilizado imágenes Landsat 7ETM+, a partir de un modelo lineal que requiere como dato de entrada el valor promedio de todos los píxeles ubicados dentro de los límites para una parcela del índice de vegetación NDVI (Zenteno et al., 2017).

García et al. (2020) desarrolló una red neuronal de alimentación directa de tipo perceptrón multicapa utilizando el software Matlab, con 2 capas y 40 neuronas, donde se ingresó como parámetros de entrada una combinación de los índices de vegetación normalizados (obtenidos del procesamiento de imágenes tomadas

con un VANT), la densidad de plantas y la cobertura del dosel, siendo el rendimiento en toneladas por hectárea como etiquetas y parámetros de salida. Encontraron que los índices de vegetación multiespectral y visible presentaron una alta correlación al estimar el rendimiento de grano de maíz. Concluyen que la densidad de plantas, el índice WDRVI y el índice NDVI son los predictores más importantes del rendimiento, y el menos importante resultó ser el índice de VARI.

La producción de biomasa ha sido objeto de estudio con la finalidad de modelar y mapear la biomasa aérea natural para desarrollar metodologías para la planificación del manejo de las masas boscosas, la mitigación de GEI y, otros aspectos de desarrollo local y conservación de la biodiversidad. Manrique, Núñez, Franco y Seghezzo (2010) utilizaron imágenes Landsat 5 para determinar el NDVI (Normalized Difference Vegetation Index) y el índice SAVI (Soil Adjusted Vegetation Index). Los autores relacionaron los índices con los datos de producción de biomasa, Sus resultados indican que el índice NDVI estimó con mejor ajuste la biomasa, mediante un modelo logarítmico con un  $R^2$  de 0.92. Al realizar la prueba no paramétrica de Mann Whitney sus resultados mostraron que no existían diferencias estadísticamente significativas entre la biomasa estimada y observada. Martínez et al. (2016) concluyen que los índices espectrales relacionados con la humedad son los más apropiados para predecir componentes forestales.

Por su parte, Gordillo (2018), determinó a partir de imágenes de una cámara Canon S110 NIR con un sensor CMOS de alta sensibilidad de 12 MP dispuesto en un VANT, los índices BNDVI y GNDVI para la vegetación de interés. El autor determinó al índice BNDVI como el más confiable con un  $R^2$  de 0.75 para predecir el peso seco del cultivo del trigo. A diferencia de Wahab, Hall & Jirström, 2018 que indican que el GNDVI extraído de cámaras modificadas montadas en UAV predice con precisión el vigor y el rendimiento de los cultivos, y índice es considerado el más apropiado para estimar los rendimientos de maíz a partir de imágenes tomadas al momento de la floración (Farrell, Gili & Noellemeyer, 2018).

### **2.1.2 Identificación del estrés hídrico**

Segura (2020) usó técnicas de teledetección en imágenes satelitales multiespectrales del satélite Sentinel 2 para calcular el Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice de Agua de Diferenciación Normalizada (NDWI), para determinar problemas de estrés hídrico en el cultivo de caña de Azúcar. Sus resultados indicaron que al relacionar los valores de NDVI y NDWI, muestran que a mayor vigor de la planta menor estrés hídrico, sin embargo, encontraron una relación débil y casi nula entre la humedad del suelo con los índices NDVI y NDWI, con valores de coeficiente de determinación máximos de 0.6 y 0.53, respectivamente.

Por su parte, Pineda et al. (2020) reportan el uso del índice DSWI (Índice de estrés de la enfermedad y el agua) para determinar algún grado de estrés hídrico en el cultivo de caña de azúcar, el índice se calcula como el cociente de la banda verde entre la banda roja.

Chamorro y Erazo (2019), además del NDVI, utilizaron el Índice de Vegetación Ajustado al Suelo (SAVI) y el Índice de estrés hídrico (CWSI) para conocer el estado de salud de las plantaciones de tuna, mediante el procesamiento de imágenes Sentinel 2A. Sus resultados muestran que el índice SAVI disminuye las alteraciones del valor del NDVI debido a que el cultivo de tuna se considera de densidad intermedia y este se desarrolla en una zona árida. Mientras que los valores del índice CWSI, indicaron que la tasa de transpiración es mínima y que para obtener valores más exactos de los índices en el cultivo de tuna es recomendable utilizar imágenes de mayor resolución.

Zúñiga (2018) en su tesis doctoral determinó índices mediante el procesamiento de imágenes térmicas y multiespectrales de alta resolución obtenidas mediante un vehículo aéreo no tripulado (VANT). Sus resultados mostraron que un alto nivel de riego corresponde a un valor mayor de NDVI, lo que indica cultivo vigoroso en comparación a los niveles de riego medio y bajo. Mientras que el

NDVI no fue representativo de las diferencias de tratamientos correspondientes a niveles de riego medio y bajo.

Quito, Tacuri, López y Lupercio (2020) sometieron al cultivo brócoli a estrés hídrico instantáneo durante trece días en la etapa considerada de mayor consumo de riego por parte del cultivo (a los 45 y 75 Días Después del Trasplante). El sensor utilizado fue el Parrot Sequoia a una altura de 2 metros para la toma de imágenes multispectrales, las cuales fueron procesadas para aislar únicamente los pixeles que corresponden a la vegetación de interés, con un análisis falso color y clasificación no supervisada. Encontraron que a los 45 DDT los tratamientos de anegamiento obtuvieron el mayor porcentaje de pixeles estresados (NDVI menor a 0.4), mientras que, en plantas de 75 DDT, el estrés hídrico por falta de agua fue más evidente y no por anegamiento.

El uso de imágenes de satélite para determinar índices de vegetación también se ha utilizado para el desarrollo de otras herramientas, como la ASIS-País, herramienta calibrada por Ortega, Ordoñez, Rojas, Hernández y de la Cruz (2019). Los autores utilizaron imágenes de satélite provenientes del sensor denominado Radiómetro Avanzado de Muy Alta Resolución (AVHRR) obtenidas en los canales visibles e infrarrojo cercano para detectar y clasificar el estrés de la vegetación causado por sequía. El Índice de salud de la vegetación (VHI) es el indicador más elemental y la entrada principal para la herramienta ASIS-País, es un índice compuesto por la unión del Índice de Condición de la Vegetación (VCI) y el Índice de Condición de la Temperatura (TCI), donde el VCI se deriva a su vez del Índice Diferencial Normalizado de Vegetación (NDVI). El ASIS-País permite detectar con precisión los periodos de estrés hídrico, identificando las unidades administrativas que presentan mayor probabilidad de ocurrencia de sequía, cuyos resultados se presentan a través de mapas de fácil interpretación, lo cual hace posible implementar medidas de prevención y mitigación.

Cocero, Riaño y Chuvieco (2000) indican que la relación entre el NDVI y la temperatura de la superficie (TS) ha sido utilizada como un indicador de estrés

hídrico y el riesgo de incendio, al indicar el contraste entre la actividad fotosintética y la temperatura que afectan a la vegetación.

Chuvienco, Salas, Aguado, Cocero y Riaño (2001) encontraron que el índice NDVI se comporta muy bien para estimar el contenido de agua en pastizales debido a que el NDVI mide un efecto indirecto de la pérdida de agua y es más sensible a las variaciones del verdor que acompañan a la pérdida de agua en las herbáceas, que al contenido de agua en sí. Además, indican que el índice NDII resulta más sensible al contenido de agua, pues está calculado a partir del infrarrojo medio de onda corta (SWIR), banda espectral muy sensible a la absorción de agua en la hoja. Mientras que el cociente NDVI/TS sería preferible utilizarlo, frente al NDVI, en caso de que sea necesario abordar una estimación mixta para pastizales y matorrales.

Pérez y Alarcón (2014) indican que, un alto rango radiométrico de la imagen mejora la sensibilidad para expresar los datos recogidos por el sensor aumentando el número de Niveles Digitales (ND) utilizados (8 bits=256; 11 bits=2048; 16 bits= 65536 valores). Además, encontraron correlación significativa entre el potencial hídrico ( $\Psi_s$ ) y el NDVI,  $R= 0.746$ . A diferencia de González, Fandiño, Rey y Cancela (2016), que en su estudio no encontraron una buena relación entre el NDVI y el potencial hídrico del tallo ( $\psi_{stem}$ ) en el caso de un viñedo.

Cobos (2020) utilizaron el índice TVDI, para determinar la disponibilidad de agua en el suelo y sobre la cobertura de maíz. El autor generó mapas de TVDI, con valores de 0 a 1, los valores de píxeles cercanos a 0 indican mucha humedad y los cercanos a 1, sequía, determinó en el cultivo de maíz que al presentar valores de TVDI mayores a 0.6 indicaban un grado de estrés hídrico. Rangos de 0.6-0.8 y de 0.8-1.0 corresponden a rangos seco y muy seco, respectivamente.

Por su parte Vázquez (2013) en su trabajo estudió la sensibilidad de diferentes índices de estrés hídrico a la disponibilidad de agua en el suelo (DAS), mediante

el uso de imágenes satelitales, entre ellos el índice Temperature–Vegetation Dryness Index (TVDI). Observó que el TVDI, el cual utiliza solamente información de satélite, es el más sensible a cambios en la DAS ( $R^2 = 0.92$ ) en comparación a los índices Crop Water Stress Index (CWSI) y Water Deficit Index (WDI), que combinan información de satélite con datos de estaciones meteorológicas. Además de que se puede generar diagnósticos a un menor costo y tiempo de ejecución, con respecto al CWSI y WDI. Sánchez y Carvacho (2013) consideran al TVDI de fácil implementación para determinar el déficit hídrico o sequía en áreas de vegetación natural y agrícola-forestal. Los autores mencionan que este índice serviría en el diseño de políticas públicas para el aprovechamiento del agua de riego y la focalización de los cultivos, según sus requerimientos hídricos en las áreas de secano.

Girolimetto (2014) derivó un nuevo índice de estrés hídrico (IEH) denominado  $WSI_{EW}$ , este índice fue comparado con el índice DWI para determinar el mejor índice como indicador del estrés hídrico. El autor menciona el índice WDI requiere de información de campo (medidas de radiación neta, flujo de calor del suelo,  $T_a$ , velocidad del viento, entre otras) en comparación con el índice  $WSI_{EW}$ , el cual presenta la ventaja de requerir sólo datos teledetectados (imágenes de  $T_s$  y NDVI), por lo que es aplicable con diferentes misiones satelitales, además de necesitar un mínimo de procesamiento, siendo una metodología de fácil y rápida aplicación a diferencia del WDI.

Jiménez (2009) evaluó la capacidad del índice Photochemical Reflectance Index (PRI) para la detección de estrés hídrico con imágenes obtenidas de cámaras térmicas y multiespectrales desde la plataforma VANT (vehículos aéreos no tripulados). Sus resultados mostraron una buena relación entre el PRI y la temperatura del dosel (de los mismos niveles de NDVI) con un coeficiente de determinación  $R^2=0.69$ , pudiendo detectar los niveles de estrés hídrico de los cultivos desde la plataforma VANT.

### **2.1.3 Detección de enfermedades, plagas y malezas**

La inteligencia artificial ha encontrado soluciones al problema que se asocian al reconocimiento automático de imágenes. Gracias al aprendizaje profundo y la alta capacidad de procesamiento de datos, se han desarrollado métodos para distinguir malezas en medio de los cultivos, el equipo discrimina las malezas mientras avanza, tomando decisiones de control de manera automatizada. Posibilitando el desarrollo de aplicaciones para el control dirigido de malezas en postemergencia (León, Campos & Reyes, 2021).

Las principales áreas de la agricultura en las que se puede utilizar la inteligencia artificial (IA) son: planificación agraria y de recursos naturales, gestión integral de cultivo, control de plagas y enfermedades, diagnóstico, análisis de inversiones, selección de maquinaria, control de riego, entre otras (Pascual, Ramírez & Ortiz, 2016).

Por su parte Guadalima, Lojano y Cabrera (2020) indican que la IA ha sido utilizada en la prevención de enfermedades en las plantas, las técnicas son con base en emplear imágenes para el aprendizaje y entrenamiento de los algoritmos empleados, las fotografías de hojas con diversas enfermedades (arroz, soya, maíz, tomate, etc.) son analizadas para diagnosticar su afectación y sugerir los cuidados oportunos. Sin embargo, indican que el reto es su implementación debido a los costos y que los cultivos se realizan en campos abiertos que dificulta mantener un ambiente controlado. Las técnicas de IA aplicadas a la sanidad vegetal son Data Mining, Neural Networks, Expert System, Machine Learning, siendo el Data Mining el de mayor prioridad debido a los sistemas son con base en recolección de datos. En sanidad vegetal la adopción de sistemas expertos en el diagnóstico temprano de las enfermedades de las plantas es el más importante y de menor costo.

Russo et al. (2018) indican que los nuevos procesadores, sensores y capacidades de almacenamiento han sostenido el desarrollo de nuevas técnicas de inteligencia artificial, en particular de visión artificial. Los desarrollos

tecnológicos aplicados a la agricultura de precisión con base en el uso de imágenes y técnicas de visión. Buscan dotar de sistemas de visión artificial a una plataforma robótica y un vehículo aéreo no tripulado, con la finalidad de que los sistemas puedan estar relacionados entre sí y trabajen de manera conjunta en el censado de datos del cultivo.

También es posible el mapeo de cultivos, con el fin de monitoreo y manejo sostenible mediante técnicas de IA como el aprendizaje autónomo en combinación con técnicas de teledetección y la toma de imágenes de drone multiespectrales o de RGB (Mohd, Al & Nisa, 2019).

Rojas (2016) menciona que el uso de sensores en las áreas de cultivos permite captar información relevante en cualquier momento. Los datos captados se transmiten a sistemas remotos permitiendo generar conclusiones, que sirven para la toma de decisiones finales. En su estudio propone diseñar un sistema experto destinado al cultivo de cítricos para el monitoreo de las plagas que afectan dichos cultivos.

Las redes neuronales artificiales presentan una serie de ventajas frente a las expresiones estadísticas utilizadas para la predicción, pues los modelos neuronales normalmente no parten de restricciones respecto de los datos de partida (tipo de relación funcional entre variables), ni suele imponer presupuestos como distribución gaussiana u otras (Pascual et al., 2016). Ozderim and Polat (2020) mencionan que los métodos de inteligencia se han utilizado ampliamente en los últimos años, especialmente para la clasificación de imágenes hiperespectrales. De las cuales se puede obtener una información muy detallada sobre los cultivos a nivel de campo a partir de imágenes hiperespectrales adquiridas de las cámaras ubicadas en los drones, posibilitando identificar enfermedades de los cultivos y frutos maduros que se pueden recolectar en el momento óptimo, permitiendo incrementar la eficiencia.

Algunos estudios realizados se describen a continuación:

✚ Campanioni (2020), diseño e implementó un vehículo autónomo que recorre los cultivos de manera manual o automática (definida por el usuario), capaz de tomar imágenes, a las cuales les aplicó filtros para mejorar su calidad, reducir el tamaño, y adecuarlas, para introducirlas a una red neuronal (convolucional) diseñada y entrenada para la detección de daños en los cultivos causados por hierbas y plagas no deseadas.

✚ Paoletti, Haut, Plaza y Plaza (2019) compararon los métodos: 1) Support Vector Machines (SVM), 2) el Multinomial Logistic Regression (MLR) y 3) el Multilayer Perceptron (MLP) y 4) la Spectral Convolutional Neural Network (CNN), discutiendo su aplicación al análisis de imágenes hiperespectrales. Concluyen que cuando se tienen mezclas no lineales en los datos la SVM-RBF, el Perceptron multicapa (MLP) y la red convolucional (CNN) son los modelos más precisos para el procesamiento eficaz de imágenes hiperespectrales. Y que los métodos basados en redes neuronales artificiales (ANN) son los que pueden extraer con mayor precisión las características más discriminantes de las imágenes cuando además de existir relaciones no lineales, los datos presentan ruido o gran variabilidad intraclases.

✚ Escobar (2018) procesó imágenes mediante técnicas de redes neuronales (redes neuronales convolucionales, CNN), el autor utilizó y reentrenó una CNN llamada AlexNet para predecir la presencia de agentes patógenos en plantas ornamentales a partir del reconocimiento de características en las imágenes y su clasificación.

✚ Vázquez, Ibarra, Flores & Moreno utilizaron el algoritmo de Levenberg-Marquardt para el entrenamiento de una red neurona de control de riego bajo invernadero de plantas de Albahaca. El algoritmo

de procesamiento de imagen se centra en la detección de zonas amarillas en las hojas, el cual permite mantener un riego eficiente para mejorar el desarrollo del cultivo.

✚ Negrón, Legarda y Uc (2018) usaron imágenes obtenidas con la cámara multiespectral Sequoia Parrot acoplada a un dron para muestrear las áreas de interés para la recolección de muestras de flora apícola. Diseñaron, programaron y entrenaron una red neuronal para la clasificación de la vegetación utilizando los índices NDVI, GNDVI y el CIR como descriptores de la vegetación. Las diferencias espectrales de las plantas de limón y naranja sirvieron como indicador para marcar la diferencia espectral en la diversidad de la flora (específica), ya que ambas plantas tienen información única que les permitiría construir un clasificador eficiente.

#### **2.1.4 Estimación del coeficiente de cultivo “Kc”**

La metodología para estimar el coeficiente de cultivo mediante índices espectrales se denomina “Kc NDVI”, fue propuesta por Cuesta, Montoro, Jochum, López y Calera (2005), los autores derivaron valores medios de NDVI en parcelas bajo condiciones óptimas de riego a partir de imágenes de satélite y determinaron la ecuación 1 para Kc para las fases inicial, desarrollo y media.

$$K_C = 1.25 * NDVI + 0.2 \quad (1)$$

Mientras que para la fase final obtuvieron la ecuación 2, de la forma:

$$K_C = 1.5625 * NDVI - 0.05 \quad (2)$$

León, Montalvo y Paula (2016) determinaron coeficientes con la metodología Kc-NDVI mediante ortofotos captadas con dron, encontraron que el Kc obtenido con el dron tiene una tendencia similar para las fases fenológicas a los obtenidos mediante los métodos de determinación de Kc de su investigación. Además, utilizaron la metodología para obtener un mapa de valores de Kc para cada imagen disponible. Indican que, una secuencia de imágenes permite el

seguimiento de la evolución temporal del coeficiente de cultivo en sus diferentes fases de desarrollo. Esta metodología también fue validada por Paula, León y Paula (2017), mencionan que los datos obtenidos por este método son muy cercanos a los valores tabulados de coeficiente de cultivo (Kc).

Además de la metodología Kc NDVI descrita anteriormente, la determinación de la evapotranspiración mediante datos remotos también se realiza mediante modelos de balance de energía, que consideran los flujos de calor latente (LE) y sensible (H) juntos o por separado, por ejemplo, el modelo METRIC que determina el flujo del calor latente como residuo de la ecuación de balance de energía. En un estudio realizado por González, Villodre, Campos, Calera y Balbontín (2015) utilizaron el método Kc-METRIC, el modelo determina el flujo de calor latente LE ( $W \cdot m^{-2}$ ) como residuo de la ecuación 3, de balance de energía:

$$LE = R_n - H - G \quad (3)$$

Donde,  $R_n$  es el flujo de radiación neta ( $W m^{-2}$ ),  $H$  es el flujo de calor sensible ( $W m^{-2}$ ) y  $G$  el flujo de calor en suelo ( $W m^{-2}$ ).

Los detalles se pueden consultar en la publicación del modelo METRIC (Allen, Tasumi & Trezza, 2007). Los autores indican que, el valor de la evapotranspiración a la hora de paso del satélite  $ET_{inst}$  ( $mm h^{-1}$ ) se calcula para cada píxel dividiendo LE ( $W \cdot m^{-2}$ ) por el calor latente de vaporización, y multiplicando por el factor 3600 para convertir de segundos a escala horaria, siendo  $ET_{oinst}$  la evapotranspiración de referencia a escala horaria, finalmente la evapotranspiración de cultivo se determina como:  $ET_c = \frac{ET_{inst}}{ET_{oinst}} ET_o$ , donde, el cociente  $ET_{inst}/ET_{oinst}$  puede considerarse constante a la hora de paso del satélite. Sus resultados muestran que los valores de Kc obtenidos con METRIC fueron adecuados para hacer un seguimiento del cultivo, así como para la gestión del riego. Indican que la limitación del modelo es la selección de los píxeles de calibración, para lo que se requiere automatización, conocimiento de la zona de aplicación y un usuario con experiencia, ya que es un punto crítico del modelo.

Zhang, Han, Niu and Li (2019) en su estudio establecieron modelos de regresión para  $K_c$ , al relacionar índices de vegetación multispectrales sensibles al estrés hídrico en maíz y coeficientes de cultivo medidos. Para establecer un modelo de regresión entre IV y  $K_c$ , utilizaron los IV: NDVI, TCARI/RDVI y TCARI/SAVI. Sus fórmulas de cálculo corresponden a las ecuaciones 4, 5, 6 y 7:

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (4)$$

$$RDVI = \frac{\rho_{nir} - \rho_{red}}{\sqrt{\rho_{nir} + \rho_{red}}} \quad (5)$$

$$SAVI = \frac{(1 + 0.5)(\rho_{nir} - \rho_{red})}{\rho_{nir} - \rho_{red} + 0.5} \quad (6)$$

$$TCARI = 3 \left[ (\rho_{rededge} - \rho_{red}) - 0.2(\rho_{rededge} - \rho_{green}) * \left( \frac{\rho_{rededge}}{\rho_{red}} \right) \right] \quad (7)$$

Donde  $\rho_{red}$ ,  $\rho_{rededge}$ ,  $\rho_{green}$  y  $\rho_{nir}$  son los valores de reflectancia en las bandas rojo, borde del rojo, verde e infrarrojo cercano, respectivamente.

El  $K_c$  puede ser obtenido por la ecuación 8 o 9 de la forma:

$$K_c - 1 = \begin{cases} 1.15 \left( 1 - \frac{NDVI_{max} - NDVI}{NDVI_{max} - NDVI_{min}} \right) + 0.9(1 - 1.19(NDVI - NDVI_{min})); & (TCARI/RDVI \leq 0.195) \\ (1.47 - 2.41 \left( \frac{TCARI}{RDVI} \right)) \left( 1.15 \left( 1 - \frac{NDVI_{max} - NDVI}{NDVI_{max} - NDVI_{min}} \right) \right) + 0.9(1 - 1.19(NDVI - NDVI_{min})); & (0.195 < TCARI/RDVI < 0.609) \\ 0 & (0.609 < TCARI/RDVI) \end{cases} \quad (8)$$

$$K_c - 2 = \begin{cases} 1.15 \left( 1 - \frac{NDVI_{max} - NDVI}{NDVI_{max} - NDVI_{min}} \right) + 0.9(1 - 1.19(NDVI - NDVI_{min})); & (TCARI / (SAVI \leq 0.182)) \\ (1.45 - 2.46 \left( \frac{TCARI}{SAVI} \right)) \left( 1.15 \left( 1 - \frac{NDVI_{max} - NDVI}{NDVI_{max} - NDVI_{min}} \right) \right) + 0.9(1 - 1.19(NDVI - NDVI_{min})); & (0.182 < TCARI / (SAVI < 0.589)) \\ 0 & (0.589 < TCARI / (SAVI)) \end{cases} \quad (9)$$

Sus resultados mostraron que los IV multispectrales podían distinguir diferentes niveles de tratamientos de riego deficitario. En general, los IV multispectrales NDVI y TCARI/RDVI podrían usarse para monitorear el  $K_c$  del maíz de campo durante todo el período de crecimiento y bajo diferentes tratamientos de agua.

Por su parte Marcial, Ontiveros, Jiménez and Ojeda (2021) estimaron el coeficiente de cultivo de maíz ( $K_c$ ) como una función del producto de los índices

espectrales de vegetación (IV) y la fracción de cobertura vegetal ( $f_v$ ), utilizando imágenes multiespectrales de alta resolución mediante un VANT y un eficiente enfoque basado en OBIA para clasificar píxeles de imagen. Validaron su metodología usando  $K_c$ , estimados con un enfoque de Grados Días de Crecimiento Acumulativo (CGDD). Los índices de vegetación fueron calculados con las ecuaciones 10, 11 y 12:

$$NDVI = \frac{NIR - R}{NIR + R} \quad (10)$$

$$WDRVI = \frac{\alpha NIR - R}{\alpha NIR + R} \quad (11)$$

$$EVI2 = 2.5 \left( \frac{NIR - R}{NIR + 2.4R + 1} \right) \quad (12)$$

Donde  $\alpha$  es un coeficiente de ponderación con valor igual a 0.2, NIR y R son la reflectancia del infrarrojo cercano y la banda del rojo, respectivamente.

Tanto  $f_v$  como NDVI mejoró la predicción de  $K_c$  ( $f_v$ : NDVI), ya que  $f_v$  es una expresión de cobertura de biomasa "sólo verde" y el NDVI estima la "calidad" de verdor. Los autores indican que el modelo que mejor estima  $K_c$  es  $f_v$ :NDVI, ya que, cuando la vegetación se aísla del suelo a una alta resolución espacial, NDVI puede superar los problemas de alta densidad de copa y producir mejores resultados que EVI2 y WDRVI. Utilizando modelos espectrales para estimar  $K_c$  basados en imágenes de alta resolución espacial y temporal, solo para píxeles verdes para calcular los IV y  $f_v$ , ofrecen una herramienta precisa y simple para determinar la distribución espacial del coeficiente de cultivo  $K_c$  y evaluar la ETC en la programación del riego en áreas agrícolas.

## **2.2 Índices de vegetación utilizados para identificar el estrés hídrico en el cultivo de maíz**

Mousabeygi, Rezaei and Akhavan (2020) exploraron el uso de cámaras modificadas de bajo costo para determinar índices de vegetación en respuesta a tratamientos de riego y variaciones de nitrógeno. Determinaron correlaciones con

el contenido relativo de agua (RWC), con la finalidad de proporcionar una guía para el monitoreo rápido y no destructivo del estado del agua en el cultivo de maíz. Evaluaron cuatro tratamientos de riego (I1: 100% (control), I2: 80%, I3: 60% e I4: 40% de la capacidad de campo) y cuatro tratamientos con nitrógeno (N1: sin nitrógeno, N2: 100 kg N ha<sup>-1</sup>, N3: 200 kg N ha<sup>-1</sup> y N4: 300 kg N ha<sup>-1</sup>) aplicado como urea (46% N). Sus resultados mostraron que CTCV (ecuación 13), CTSD (ecuación 14) y DANS (ecuación 15) proporcionaron los mejores valores de coeficiente de determinación (R<sup>2</sup> igual a 0.67, 0.76 y 0.88, respectivamente) al estimar RWC (RWC=-155.44(CTCV)+95.515, RWC=-7.3981(CTSD)+98.795 y CTCV RWC=-3.054(DANS)+101.02,) en comparación con el índice de vegetación de diferencia (DVI), el índice de vegetación mejorado (EVI), el índice de vegetación de diferencia normalizada (NDVI), la relación simple (SR) y el índice de vegetación transformada (TRVI), ecuaciones 16 a 20 respectivamente, mostraron coeficientes de determinación menores a 0.50. Los índices de vegetación seleccionados para imágenes térmicas, infrarrojas y RGB, se calcularon de la forma:

$$CTCV = \frac{CTSD}{\bar{T}_c} \quad (13)$$

$$CTSD = \sqrt{\left[ \frac{(T_{c1} - \bar{T}_c)^2 + (T_{c2} - \bar{T}_c)^2 + \dots + (T_{cn} - \bar{T}_c)^2}{n} \right]} \quad (14)$$

$$DANS = \begin{cases} \bar{T}_c - T_{NS}, & \bar{T}_c > 28^\circ C \\ 0, & \bar{T}_c < 28^\circ C \end{cases} \quad (15)$$

$$DVI = IR - R \quad (16)$$

$$EVI = 2.5 \left( \frac{IR - R}{IR + 6R - 7.5B + 1} \right) \quad (17)$$

$$NDVI = \frac{IR - R}{IR + R} \quad (18)$$

$$SR = \frac{IR}{R} \quad (19)$$

$$TRVI = \frac{\sqrt{IR - R}}{IR + R} + 0.5 \quad (20)$$

R, G, B e IR son la media del número digital de las bandas roja, verde, azul e infrarroja, respectivamente.  $\overline{Tc}$  es la Tc media del maíz dentro de una parcela de muestreo obtenida por el método RGRI-Otsu,  $T_{NS}$  es la Tc del maíz sin estrés y a 28 °C,  $T_{ci}$  ( $i = 1, 2, \dots, n$ ) es el Tc real de cada píxel del dosel de maíz dentro de una parcela de muestreo, y n es el número de píxeles del dosel de maíz dentro de una parcela de muestreo.

Los autores encontraron altas correlaciones entre los índices con base en imágenes térmicas con el estado hídrico del maíz. Para mejorar la precisión de la extracción de Tc y la eliminación de fondo, utilizaron el método RGRI-Otsu. El cual consiste en calcular el índice de relación rojo-verde (RGRI= R/G, donde R y G representan los números digitales de las bandas roja y verde) para posteriormente aplicar el algoritmo de Otsu al RGRI para separar los píxeles en dos clases. La cobertura vegetal fraccionada (FVC) de maíz en imágenes RGB se utilizó como una máscara binaria para segmentar las plantas verdes contra el fondo. Su hallazgo mostró que DANS, CTSD y CTCV pueden estimar el estrés hídrico del maíz de manera más simple que el índice CWSI, además DANS no requiere ningún factor meteorológico. Concluyen que el uso de cámaras térmicas y cámaras modificadas permite estimar el RWC para evaluar el estado hídrico del maíz.

En un estudio similar, Naveen et al. (2020) sometieron el cultivo de maíz a tres niveles de riegos (IW/CPE: 0.60, 0.8 y 1.2) y tres niveles de nitrógeno (100, 200 y 300 kg de nitrógeno ha<sup>-1</sup>) para crear un ambiente de estrés hídrico y nitrogenado. Para distinguir el estrés hídrico y de nitrógeno calcularon los índices de vegetación NDVI, GNDVI, WBI y SR, dados por las ecuaciones 21 a 24, donde

R y el número de subíndice indican la reflectancia de la luz a una longitud de onda específica (en nm), de la forma:

$$NDVI = \frac{R_{850} - R_{670}}{R_{850} + R_{670}} \quad (21)$$

$$GNDVI = \frac{R_{780} - R_{550}}{R_{780} + R_{550}} \quad (22)$$

$$WBI = \left( \frac{R_{900}}{R_{970}} \right) \quad (23)$$

$$SR = (R_{900}/R_{680}) \quad (24)$$

Mencionan que los tratamientos de riego mostraron que los valores de NDVI y GNDVI disminuyeron al aumentar el nivel de estrés hídrico en las etapas de VT y masosa del cultivo, mientras entre los diferentes niveles de nitrógeno, los valores disminuyeron al aumentar el estrés de nitrógeno en las etapas de espigado y masa del cultivo. Sus resultados muestran que los índices de vegetación son más altos en la etapa de espigado y disminuyen en la etapa de masa del cultivo en todos los tratamientos, la senescencia de las plantas afecta las propiedades de reflectancia y los índices de vegetación disminuyen después de la etapa de borlas. Indican que los índices NDVI, GNDVI y SR son de gran utilidad para explicar la condición del cultivo bajo un ambiente de estrés hídrico y de nitrógeno, además de que podrían cuantificar el crecimiento y rendimiento del cultivo. Por otro lado, encontraron que ninguno de los índices resultó significativo en la discriminación del estrés inducido bajo niveles graduados de nitrógeno y mencionan que los índices NDVI y GNDVI distinguen la severidad del estrés hídrico y de nitrógeno en el cultivo de maíz.

En su estudio, de Lara, Longchamps and Khosla (2019) evaluaron si los índices de vegetación obtenidos por satélite junto con mediciones del agua del suelo podrían mejorar la relación entre el rendimiento de grano de maíz y las mediciones del contenido de agua del suelo (SWC). Mediante un análisis de

correlación (Correlación de Pearson con valor de  $p= 0.05$ ) estudiaron la relación entre SWC, datos de teledetección y valores de rendimiento. Los índices evaluados fueron el NDVI (índice de vegetación de diferencia normalizada), RECI (índice de clorofila de borde rojo), RENDVI (índice de vegetación de diferencia normalizada de borde rojo) y EVI (índice de vegetación mejorado), calculados con las ecuaciones 25 a 28:

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (25)$$

$$RECI = \frac{NIR}{Red\_edge} - 1 \quad (26)$$

$$RENDVI = \frac{NIR - Red\_edge}{NIR + Red\_edge} \quad (27)$$

$$EVI = 2.5 \frac{NIR - Red}{1 + NIR + 6 Red - 7.5 Blue} \quad (28)$$

Donde NIR, Red, Red\_edge se refieren a la banda 5 (760-850 nm), banda 3 (630-685 nm) y banda 4 (690-730 nm) de RapidEye's, respectivamente. Mientras que, para EVI, NIR, Red, Blue se refieren a la banda 2 (841-876 nm), banda 1 (620-670 nm) y banda 3 (459-479 nm) de MODIS, respectivamente.

Los autores indican que:

- un monitoreo más profundo de la SWC sería más apropiado para una gestión de riego más eficiente, el modelo de imágenes (combinación de mediciones de agua del suelo y datos de teledetección) permite obtener mapas de agua del suelo de alta frecuencia,
- los mapas frecuentes de la cubierta vegetales estimados por teledetección combinados con mapas del rendimiento potencial de los cultivos podrían proporcionar información útil sobre el estado hídrico de la planta en todo el campo,

- los índices de vegetación permiten mejorar la predicción del rendimiento de maíz por SWC, siendo RECI y RENDVI los IV que mejoran el modelo SWC. El monitoreo de SWC en etapas reproductivas combinado con índices de vegetación podría ser una herramienta para mejorar el manejo del riego del maíz.

Zhang and Zhou (2019) evaluaron los efectos de los tratamientos de estrés hídrico en los índices de vegetación espectrales del dosel para siete tratamientos de régimen de riego (120, 100, 80, 60, 40, 25 y 15 mm) y uno de control (de seco). Los autores en este estudio utilizaron cuatro índices espectrales de vegetación (IV), que están indirectamente relacionados con el agua del dosel y seis sensibles al agua, para determinar el potencial de los IV espectrales para estimar la cantidad de contenido de agua de las hojas en el maíz por unidad de área de superficie del suelo (CWC), el contenido de agua del cultivo por unidad de área foliar (EWT) y el contenido de humedad del combustible vivo (LFMC).

Los IV se calcularon como se muestra en Cuadro 2-1.

Cuadro 2-1. Índices de vegetación utilizados por Zhuang and Zhou (2019).

Índice	Fórmula
VI espectrales indirectos sensibles al agua	
agua NDVI	$(R_{nir} - R_{rojo}) / (R_{nir} + R_{rojo})$
borde rojo NR	$(R_{750} - R_{710}) / (R_{750} + R_{710})$
CI verde	$(750 R / 550 R) - 1$
borde rojo CI	$(R_{750} / R_{710}) - 1$
VIs espectrales sensibles al agua directos	
WI	$R_{900} / R_{970}$
MSI	$R_{1600} / R_{820}$
SRWI	$R_{860} / R_{1240}$
NDWI	$(R_{860} - R_{1240}) / (R_{860} + R_{1240})$
NDWI <sub>1640</sub>	$(R_{858} - R_{1640}) / (R_{858} + R_{1640})$
NDWI <sub>2130</sub>	$(R_{858} - R_{2130}) / (R_{858} + R_{2130})$

$R_{nir}$  y  $R_{rojo}$  son la reflectancia promedio entre el rango de la banda de ondas para coincidir con los datos MODIS en las longitudes de onda del infrarrojo cercano (841-876 nm) y rojo (620-670 nm), respectivamente.

Los autores encontraron que los IV en respuesta a los diferentes tratamientos de agua más sensibles, fueron especialmente los indirectos ( $CI_{borde\ rojo\ NR}$ ,  $CI_{borde\ rojo\ verde}$  y  $CI_{borde\ rojo\ CI}$ ), así como también el  $NDWI_{1640}$  y  $NDWI_{2130}$ . Los IV indirectos,  $CI_{borde\ rojo\ verde}$ ,  $CI_{borde\ rojo\ NR}$  y  $CI_{borde\ rojo\ CI}$ , presentaron una mejor predicción del contenido de agua del cultivo correlacionados con CWC ( $R^2 = 0.745-0.791$ ), siendo el  $NDWI_{1640}$  y  $NDWI_{2130}$  los IV directos que presentaron la mayor sensibilidad a CWC y EWT ( $R^2 = 0.727-0.732$ ). Donde CWC es el indicador de agua de cultivo más ideal para monitorear el estrés hídrico de los cultivos utilizando técnicas de espectroscopía de campo.

Geraldi, Agüero y Gastón (2019) presentaron la variación estacional del NDVI y NDWI a partir de imágenes Landsat 8 OLI. Además, calcularon el índice de estrés hídrico TDVI (temperatura dryness vegetation index). El índice de vegetación normalizada (NDVI) y el índice de diferencia normalizada de agua (NDWI) fueron calculados mediante las ecuaciones 29 y 30, a partir de las bandas 4, 5 y 6, respectivamente, de Landsat 8, de la forma:

$$NDVI = \frac{BANDA5 - BANDA4}{BANDA5 + BANDA4} \quad (29)$$

$$NDWI = \frac{BANDA5 - BANDA6}{BANDA5 + BANDA6} \quad (30)$$

Sus resultados indican que en la región pampeana donde los cultivos predominantes son trigo y maíz. Los valores del índice NDVI representaron la vigorosidad y la cobertura de los cultivos. Mientras el NDWI mostró las variaciones en la cantidad de agua para los distintos cultivos en sus diferentes etapas de desarrollo. En el análisis del TVDI indicó un déficit alto (0.8 a 1) y moderado (0.6 a 0.8) de humedad en los cultivos. Los autores mencionan que el

TVDI se puede usar para determinar nuevas áreas de riego o relocalizar las ya regadas.

Zhang, Zhang, Niu and Han (2019) para establecer un modelo de regresión entre índices de vegetación (VI) multiespectrales basado en vehículos aéreos no tripulados (VANT) y el CWSI, seleccionaron nueve IV, NDVI, RDVI, SAVI, OSAVI, TCARI, TCARI/NDVI, TCARI/RDVI, TCARI/SAVI y TCARI/OSAVI. Estos índices se calcularon a partir de las ecuaciones 31, 32, 33, 34 y 35 de la forma:

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (31)$$

$$RDVI = \frac{\rho_{nir} - \rho_{red}}{\sqrt{\rho_{nir} + \rho_{red}}} \quad (32)$$

$$SAVI = \frac{(1 + 0.5)(\rho_{nir} - \rho_{red})}{\rho_{nir} - \rho_{red} + 0.5} \quad (33)$$

$$OSAVI = \frac{(1 + 0.16)(\rho_{nir} - \rho_{red})}{\rho_{nir} - \rho_{red} + 0.16} \quad (34)$$

$$TCARI = 3 \left[ (\rho_{rededge} - \rho_{red}) - 0.2(\rho_{rededge} - \rho_{green}) * \left( \frac{\rho_{rededge}}{\rho_{red}} \right) \right] \quad (35)$$

Donde  $\rho_{red}$ ,  $\rho_{rededge}$ ,  $\rho_{green}$  y  $\rho_{nir}$  son los valores de reflectancia en las bandas rojo, borde del rojo, verde e infrarrojo cercano, respectivamente.

Los autores realizaron un análisis de regresión lineal entre CWSI y los IV para obtener un modelo. Los resultados mostraron que antes de la cobertura efectiva del dosel los índices de vegetación no distinguían eficazmente los tratamientos de riego deficitario, hasta alcanzar la cobertura efectiva, especialmente en la etapa de maduración. Los autores mediante TCARI/RDVI y TCARI/SAVI determinaron modelos de regresión lineal entre IV y CWSI. Ecuaciones 36 y 37:

$$CWSI - 1 = \begin{cases} 0 & (TCARI/RDVI \leq 0.195) \\ 2.41(TCARI/RDVI) - 0.47 & (0.195 < TCARI/RDVI < 0.609) \\ 1 & (0.609 < TCARI/RDVI) \end{cases} \quad (36)$$

$$CWSI - 2 = \begin{cases} 0 & (TCARI/SAVI \leq 0.182) \\ 2.46(TCARI/SAVI) - 0.45 & (0.182 < TCARI/SAVI < 0.589) \\ 1 & (0.589 < TCARI/SAVI) \end{cases} \quad (37)$$

Los autores indican que es viable mapear el estado hídrico del cultivo de maíz y monitorear su variabilidad espacial a escala de finca mediante el uso de modelos de regresión CWSI-IV multiespectrales a partir de VANT. Por su parte, Costa, Chávez and Comas (2020) utilizaron el NDVI y OSAVI, junto con la temperatura superficial radiométrica, para estimar el flujo de calor sensible y la energía disponible, en un estudio para obtener el índice de estrés hídrico del cultivo (CWSI).

Jiménez (2009) evaluó la capacidad del índice Photochemical Reflectance Index (PRI) para la detección de estrés hídrico desde la plataforma VANT (vehículos aéreos no tripulados). El índice PRI se determina mediante la ecuación 38:

$$PRI = \frac{R_{570} - R_{530}}{R_{570} + R_{530}} \quad (38)$$

El autor evaluó la detección de estrés estudiando las relaciones entre PRI y la temperatura entre parcelas de maíz con el mismo rango de NDVI, obtenida de las cámaras térmicas y multiespectrales del VANT. Sus resultados mostraron una buena relación entre el PRI y la temperatura del dosel (de los mismos niveles de NDVI) con un coeficiente de determinación  $R^2=0.69$ , se pudo detectar los niveles de estrés hídrico de los cultivos desde la plataforma VANT.

Por su parte Elsayed and Darwish (2017) evaluaron si los índices espectrales (para las longitudes de onda 720, 790, 880, 900, 940, 960 y 970 nm) pueden reflejar cambios en el estado hídrico, la biomasa y el rendimiento en grano de los cultivares de maíz en condiciones de salinidad y estrés hídrico. Sus resultados mostraron que los índices espectrales  $(R_{970}-R_{900})/(R_{970}+R_{900})$  y

$(R_{970}-R_{920})/(R_{970}+R_{920})$  tenían los mayores valores de  $R^2$  con las variables medidas. Indican que los índices hídricos  $(R_{970}-R_{880})/(R_{970}+R_{880})$ ,  $(R_{970}-R_{900})/(R_{970}+R_{900})$  y  $(R_{970}-R_{920})/(R_{970}+R_{920})$  parecen ser buenos indicadores del estado hídrico, la biomasa y el rendimiento de cultivos de maíz, en condiciones de riego y en interacción entre tratamientos de salinidad y estrés hídrico.

da Silva, Filgueiras, Rodrigues, da Cunha and Aleman (2020) estimaron el coeficiente de estrés hídrico ( $K_s$ ) a través de información obtenida mediante teledetección combinada con datos de campo. Sus resultados muestran que la metodología necesita ser evaluada para las etapas inicial y final del desarrollo del cultivo, aunque tiene potencial para su uso en el manejo del riego en las etapas intermedias.

Tang, Han and Zhang (2019) en su estudio comparó la evapotranspiración (ET) calculada con índices de estrés agua (CWSI y  $T_{relación\ de\ c}$ ) y NDVI a la ET calculada con la ecuación de FAO-56 por el método de  $K_c$  dual modificado mediante la evaluación del indicador de estrés de agua adecuado para la estimación de la ET para maíz a nivel local. Los autores establecieron modelos de regresión entre los IV multiespectrales y los coeficientes de cultivo (NDVI vs.  $K_{cb}$  y  $TCARI/RDVI$  vs.  $K_s$ ) para determinar el  $K_{cb}$  y  $K_s$ , mientras el CWSI y el  $K_s$  fueron calculados con las ecuaciones 39 y 40:

$$CWSI = \begin{cases} 0 & (TCARI/RDVI \leq 0.195) \\ 2.41(TCARI/RDVI) - 0.47 & (0.195 < TCARI/RDVI < 0.609) \\ 1 & (0.609 < TCARI/RDVI) \end{cases} \quad (39)$$

$$K_{s-CWSI} = \begin{cases} 1 & (TCARI/RDVI \leq 0.195) \\ 1 - (2.41(TCARI/RDVI) - 0.47) & (0.195 < TCARI/RDVI < 0.609) \\ 0 & (0.609 < TCARI/RDVI) \end{cases} \quad (40)$$

Según los autores los IV multiespectrales calculados a partir de la reflectancia del dosel se pueden utilizar para simular  $K_{cb}$  en tiempo real y mediante vehículos aéreos no tripulados se puede obtener información sobre  $K_{cb}$  más sofisticada para la gestión del riego. Al estimar  $K_s$  para el maíz con el CWSI fue útil para estimar

la ET, con una precisión aceptable en comparación con el método FAO-56  $K_c$  modificado. El modelo puede ser adecuado para distinguir claramente los diferentes esquemas de riego. Finalmente indican que es posible mapear la ET del cultivo de maíz en condiciones de estrés hídrico y monitorear su variabilidad espacial a escala de campo mediante el uso de los modelos de regresión IV- $K_{cb}$  y IV- $K_s$ .

Argolo et al. (2020) evaluaron modelos empíricos de coeficiente  $K_{cb}$  para estimar la evapotranspiración real del cultivo a través de la normalización de los valores del Índice de Vegetación de Diferencia Normalizada (NDVI) y del Índice de Vegetación Ajustado por Suelo (SAVI). Usaron un sensor RGNIR a bordo de un vehículo aéreo no tripulado (VANT) DJI Phantom 4 fabricado por DJI Innovations. Sus resultados mostraron que el modelo SAVI utilizado para determinar  $K_{cb}$  fue más sensible al estrés hídrico debido a que este modelo tiende a tener un coeficiente basal más alto, lo que influye en el mayor potencial de transpiración del cultivo. El  $K_{cb}$  fue estimado con la ecuación 41:

$$K_{cb} = K_{cbmax} \left[ 1 - \left( \frac{VI_{max} - VI}{VI_{max} - VI_{min}} \right)^n \right] \quad (41)$$

Donde n corresponde a la relación  $K/K'$ ; K es un coeficiente relacionado con la arquitectura foliar del cultivo, que varía de 0.5 a 0.7; y  $K'$  es un coeficiente que varía de 0.5 a 0.7 y de 0.8 a 1.3 cuando los índices de vegetación utilizados son SAVI y NDVI, respectivamente. El  $K_{cbmax}$  adoptado fue 1.15. El NDVI y SAVI fueron utilizados para determinar el  $K_{cb}$  del maíz a lo largo de su crecimiento. Para el NDVI, solo fue necesario reemplazar el valor del IV, asumiendo el valor medio entre los coeficientes K y  $K'$ . Para SAVI, los parámetros VI de la ecuación anterior fueron reemplazados y la relación entre K y  $K'$  fue igual a 1.

Sus resultados muestran que la transpiración real del cultivo ( $T_a$ ) determinada por el modelo empírico de  $K_{cb}$  derivado del NDVI mostró mayor variabilidad espacial que el modelo empírico de  $K_{cb}$  derivado de SAVI. El modelo empírico con base

en SAVI tiene una mayor capacidad predictiva que el modelo de NDVI, proporcionando un R<sup>2</sup> de 0.74 para la biomasa de maíz.

En su estudio Alvino et al. (2020) obtuvieron datos de un sensor OLI (Operational Land Imager) integrado en una plataforma satelital Landsat-8, para evaluar cinco parcelas de cultivo de maíz bajo riego de pivote central. Los autores probaron los índices de vegetación dados por las ecuaciones 42, 43, 44, 45, 46, 47 y 48 para detectar variabilidad en cultivos de maíz de regadío: NDVI (índice de vegetación de diferencia normalizada), EVI (índice de vegetación mejorado), SAVI (índice de vegetación ajustado al suelo), GNDVI (índice de vegetación de diferencia normalizada verde), SR (proporción simple), MSI (Índice de estrés por humedad) y NDWI (índice de vegetación de diferencia normalizada) Index).

$$NDVI = \frac{\rho NIR - \rho RED}{\rho NIR + \rho RED} \quad (42)$$

$$EVI = G * \left( \frac{\rho NIR - \rho RED}{\rho NIR + C1 * \rho RED - C2 * \rho BLUE + L} \right) (1 + L) \quad (43)$$

$$SAVI = \frac{(\rho NIR - \rho RED)(1 + L)}{\rho NIR - \rho RED + L} \quad (44)$$

$$GNDVI = \frac{\rho NIR - \rho VERDE}{\rho NIR + \rho VERDE} \quad (45)$$

$$SR = \frac{\rho NIR}{\rho RED} \quad (46)$$

$$MSI = \frac{\rho SWIR1}{\rho NIR} \quad (47)$$

$$NDWI = \frac{\rho NIR - \rho SWIR1}{\rho NIR + \rho SWIR1} \quad (48)$$

Donde  $\rho VERDE$ ,  $\rho Red$ ,  $\rho NIR$ ,  $\rho Blue$  y  $\rho SWIR1$  son la reflectancia de banda verde, roja, infrarrojo cercano, azul e infrarroja de onda corta, respectivamente. L

es el factor de ajuste, C1 y C2 son coeficientes de ajuste de los efectos de los aerosoles en la atmósfera y G la ganancia ajustada.  $L= 0.5$ ,  $C1=6$ ,  $C2=7.5$  y  $G=2.5$

Sus resultados mostraron que el MSI tenía una alta sensibilidad a los cambios en el contenido de agua en el dosel del maíz, ya que a medida que cambiaba la etapa del cultivo, la demanda de riego aumentaba y por lo tanto el MSI disminuía. Otro índice con correspondencia directa con el contenido de agua del dosel de maíz fue el NDWI. Este índice es importante para el análisis en áreas irrigadas y fue más sensible durante el final del ciclo de cultivo. Estos índices son capaces de monitorear los cambios en el contenido de agua de la vegetación y, por lo tanto, se pueden usar para mejorar el riego y el monitoreo de cultivos. Los autores indican que es aconsejable el uso de un conjunto de estos índices, ya que algunos responden mejor a determinadas peculiaridades que otros.

Por su parte Li et al. (2018) evaluaron el desempeño de índices espectrales (NDVI, RDVI, REP, TO (TCARI/OSAVI), TVI y PRI) para detectar el estado hídrico del maíz y las condiciones de producción. Evaluaron el Contenido de agua de la hoja (LWC) y el Potencial de agua de la hoja (LWP), los indicadores productivos LAI y contenido de clorofila, además del indicador térmico CWSI (Índice de estrés hídrico de los cultivos) para determinar la respuesta del maíz a niveles de agua continuos, desde sequía hasta el anegamiento. Los índices fueron calculados a partir de las reflectancias de las longitudes de onda correspondientes, a partir de las ecuaciones 49, 50, 51, 52, 53 y 54:

$$NDVI = \frac{R_{800} - R_{670}}{R_{800} + R_{670}} \quad (49)$$

$$RDVI = \frac{R_{800} - R_{670}}{\sqrt{R_{800} + R_{670}}} \quad (50)$$

$$TCARI = 3 \left[ (R_{700} - R_{670}) - 0.2(R_{700} - R_{550}) * \left( \frac{R_{700}}{R_{670}} \right) \right] \quad (51)$$

$$OSAVI = \frac{(1 + 0.16)(R_{800} - R_{670})}{R_{800} + R_{670} + 0.16} \quad (52)$$

$$TVI = \frac{120(R_{750} - R_{550}) - 100(R_{670} - R_{550})}{2} \quad (53)$$

$$PRI = \frac{R_{570} - R_{531}}{R_{570} + R_{531}} \quad (54)$$

REP (posición del borde rojo), fue calculado mediante el enfoque de interpolación de cuatro puntos con las ecuaciones 55 y 56:

$$\rho_I = \frac{\rho_1 + \rho_4}{2} \quad (55)$$

$$\lambda_I = \lambda_2 + (\lambda_3 - \lambda_2) \frac{\rho_I - \rho_2}{\rho_3 - \rho_2} \quad (56)$$

dónde  $\rho_I$  es la reflectancia en la posición del borde rojo,  $\lambda_I$  (borde rojo, punto de inflexión), a saber,  $\lambda_1$ ,  $\lambda_2$ ,  $\lambda_3$  y  $\lambda_4$  son longitudes de onda a 670, 700, 740 y 780 nm, respectivamente, y  $\rho_1$ ,  $\rho_2$ ,  $\rho_3$  y  $\rho_4$  son reflectancia en longitudes de onda  $\lambda_1$ ,  $\lambda_2$ ,  $\lambda_3$  y  $\lambda_4$ , respectivamente.

Sus resultados revelaron que REP era sensible a las condiciones del agua del maíz LWP y podría usarse como un índice completo para la detección de la condición de estrés. Mientras el PRI fue el índice más sensible a los indicadores de producción en comparación al NDVI.

El uso de índices de vegetación como el NDVI de imágenes de satélite sirve como parámetro para delimitar las zonas de manejo para los sistemas de cultivo anual en busca de hacer un uso más eficiente de los recursos: semillas, fertilizantes, agua y pesticidas (Melo et al., 2020).

### 2.3 Literatura citada

- Allen, R. G., Tasumi, M. & Trezza, R. (2007). Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)—Model. *Journal of irrigation and drainage engineering*, 133, 380-394.
- Argolo d. S., R., Chartuni M., E., Filgueiras, R., Inácio F. F., E., Barbosa d. S., A. C. & Peroni V., L. (2020). Actual Evapotranspiration and Biomass of Maize from a Red-Green-Near-Infrared (RGNIR) Sensor on Board an Unmanned Aerial Vehicle (UAV). *Water*, 12, 1-20.
- Campanioni M., S. (2020). Procesamiento de imágenes, obtenidas por un vehículo autónomo, para el reconocimiento de daños en cultivos. (Tesis de licenciatura, Universidad Tecnológica de La Habana José Antonio Echeverría).
- Chamorro S., H. y Erazo, A. (2019). Estudio multiespectral del cultivo de tuna para determinar los índices NDVI, CWSI y SAVI, a partir de imágenes SENTINEL 2A, en el cantón Guano, provincia de Chimborazo, Ecuador. *Enfoque UTE*, 10, 55-66.
- Chuvienco, E., Salas, F. J., Aguado, I., Cocero, D. y Riaño, D. (2001). Estimación del estado hídrico de la vegetación a partir de sensores de alta y baja resolución. *GeoFocus*, 1, 1-16.
- Cobos R., I. M. (2020). Determinación del índice de estrés hídrico a partir de imágenes satelitales (Ecuador). (Tesis de maestría, Universidad de Salzburg).
- Cocero, D., Riaño, D. y Chuvienco, E. (2000). Estimación de la Humedad de Diferentes Especies Vegetales Mediterráneas mediante Distintos Sensores de Teledetección. *Tecnologías Geográficas para el Desarrollo Sostenible*, 200-221.
- Cuesta, A. Montoro, A., Jochum, A. M., López, P. y Calera, A. (2005). Metodología operativa para la obtención del coeficiente de cultivo desde imágenes de satélite. *ITEA*, 101, 212-224.
- Costa F., E., Chávez, J. L. & Comas, L. (2020). Determining maize water stress through a remote sensing-based surface energy balance approach. *Irrigation Science*, 38, 501–518.
- da Silva A., E, Filgueiras, R., Rodrigues, L. N., da Cunha, F. F. & Aleman, C. C. 2020. Water stress coefficient determined by orbital remote sensing techniques. *agriambi*, 24, 847-853.
- de Lara, A., Longchamps, L. & Khosla, R. (2019). Soil Water Content and High-Resolution Imagery for Precision Irrigation: Maize Yield. *Agronomy*, 9, 1-12.
- Elsayed, S. & Darwish, W. (2017). Hyperspectral remote sensing to assess the water status, biomass, and yield of maize cultivars under salinity and water stress. *Bragantia*, 76, 62-72.

- Escobar A., E. (2018). Predicción de Agentes Patógenos en Plantas Ornamentales Utilizando Redes Neuronales. (Tesis de maestría, Instituto Tecnológico de Colima).
- Farrell, M., Gili, A. & Noellemeyer, E. (2018). Spectral indices from aerial images and their relationship with properties of a corn crop. *Precision Agric.*, 19, 1127–1137.
- Farrell, M. y Rivas, R. (2010). Estimación de Rendimiento en Girasol a Partir de Imágenes Captadas por el Sensor MODIS-TERRA. *Ciencia*, 5, 29-43.
- García M., H., Flores M., H, Ascencio H., R., Khalil G., K., Tijerina C., L., Mancilla V., O. R. & Vázquez P., M. A. (2020). Corn Grain Yield Estimation from Vegetation Indices, Canopy Cover, Plant Density, and a Neural Network Using Multispectral and RGB Images Acquired with Unmanned Aerial Vehicles. *Agriculture*, 10, 1-24.
- Geraldi, A. M., Agüero, J y Gastón B., F. (2019). Análisis de parámetros biofísicos a partir de información multiespectral. Caso arroyo Corto y arroyo Pescado. Argentina. *Revista de Topografía Azimut*, 10, 1-17.
- Girolimetto, D. T. (2014). Evaluación del estrés hídrico y de los factores que lo afectan usando información teledetectada. (Tesis doctoral, UNIVERSIDAD NACIONAL DEL LITORAL).
- González P., J., Villodre, J., Campos, I., Calera, A. y Balbontín, C. (2015). Seguimiento de los flujos de calor sensible y calor latente en vid mediante la aplicación del balance de energía METRIC. *Revista de Teledetección*, 43, 43-54.
- González, X. P., Fandiño, M., Rey, B. J. y Cancela, J. J. (2016). Valoración del estrés hídrico empleando Índices de Vegetación en *Vitis vinifera* cv. Treixadura en la DO Ribeiro (España). II SIMPOSIO NACIONAL DE INGENIERÍA AGRÍCOLA, Almería, España.
- Gordillo S., V. M. (2018). Evaluación del estado del nitrógeno y estimación de biomasa en el cultivo de trigo, usando sensores remotos y vehículos aéreos no tripulados (UAV). Tesis de doctorado, Colegio de posgraduados. Consultado en: <https://www.biopasos.com/biblioteca/Evaluacion-nitrogeno-biomasa-trigo-remotos-tesis.pdf>
- Guadalima I., G, Lojano C., R. y Cabrera S., M. (2020). Revisión sistemática de literatura: Inteligencia Artificial en sanidad vegetal. Congreso Estudiantil de Inteligencia Artificial Aplicada a la Ingeniería y Tecnología, UNAM, FESC, Estado de México.
- Jiménez B., J. A. (2009). Determinación del estado hídrico de la vegetación mediante teledetección basada en vehículos aéreos no tripulados. (Tesis doctoral, UNIVERSIDAD DE CÓRDOBA).

- León G., L., Campos M., C. y Reyes T., G. (2021). Inteligencia artificial: importancia actual y proyecciones para el control de malezas. *Tierra adentro*, 101-104. Consultado en: <https://inia.prodigioconsultores.com/bitstream/handle/123456789/5493/NR42388.pdf?sequence=1>
- León R., J., Montalvo A., N. y Paula A., P. (2016). Determinación del coeficiente del cultivo y parámetros biométricos basados en imágenes captadas con drone, lisímetros de drenaje y métodos indirectos para el cultivo de papa *solanum spp.* *Rev. del Instituto de Investigación (RIIGEO), FIGMMG-UNMSM*, 19, 177-188.
- Li, M., Chu, R., Yu, Q., Islam, A. R. M. T., Chou, S. & Shen, S. (2018). Evaluating Structural, Chlorophyll-Based and Photochemical Indices to Detect Summer Maize Responses to Continuous Water Stress. *Water*, 10, 1-16.
- Manrique, S, Núñez, V., Franco, J. y Seghezzo, L. (2010). PREDICCIÓN DE BIOMASA NATURAL A PARTIR DE SENSORES REMOTOS EN EL VALLE DE LERMA. *ASADES*, 14, 63-70.
- Marcial P., M. de J., Ontiveros C., R. E., Jiménez J., S. I. & Ojeda B., W. (2021). Coefficient Estimation Based on Spectral Vegetation Indices and Vegetation Cover Fraction Derived from UAV-Based Multispectral Images. *Agronomy*, 11, 1-19.
- Martínez B., R. A., Aguirre C., O. A., Benedicto V., L., Jiménez P., J., Treviño G., E. J. y Yerena Y., J. I. (2016). Modelación de biomasa y carbono arbóreo aéreo en bosques del estado de Durango. *Revista Mexicana de Ciencias Forestales*, 7, 91-105.
- Melo D., J., de Castro P., O. E., Cherubin, M. R., Zachi da F., A., Zibetti F., E. & Santi, A. L. (2020). Applying the NDVI from satellite images in delimiting management zones for annual crops. *Sci. agric.*, 77, 1-11.
- Mohd S., H Z., Al H., M. M. y Nisa S, N. S. (2019). Métodos de inteligencia artificial (IA) para aplicaciones de teledetección de palma de aceite. *Revista Palmas*, 40, 185-193.
- Mousabeygi, F., Rezaei, Y. & Akhavan, S. (2020). Assessment of maize water status using a consumer-grade camera and thermal imagery. *Water Supply*, 1-10.
- Naveen, H. R., Balaji N., B., Sreenivas, G., Kumar, A., Adinarayana, J., Avil K., K. & Shankaraiah, M. (2020). Hyperspectral Remote Sensing for Determining Water and Nitrogen Stress in Maize during RabiSeason. *CJAST*, 38, 1-9.
- Negrón G., J. J., Legarda S., R. y Uc C., V. (2018). Enfoque para la clasificación de vegetación polinífera usando imágenes multiespectrales y redes neuronales. *Research in Computing Science*, 147, 79-91.

- Ocampo, D., Rivas, R., Carmona, F., Figueredo H. y Palazzani, L. (2011). Estimación de rendimiento de trigo por ambientes a partir de datos del sensor Thematic Mapper. En Rivas, R., Carmona F. y Ocampo, D (Eds.). Teledetección: Recientes aplicaciones en la Región Pampeana. Consultado en: [http://cursosihlla.bdh.org.ar/Libro\\_011/](http://cursosihlla.bdh.org.ar/Libro_011/).
- Ortega G., D., Ordoñez, A., Rojas, O., Hernández, T. y de la Cruz, J. (2019). Monitoreo y alerta temprana de sequía en la agricultura: evaluación del sistema del índice de estrés agrícola (ASIS-País) de la FAO [Artículo]. Quinto Congreso Nacional COMEII 2019, Mazatlán, Sin.
- Ozdemir, A. & Polat, K. (2020). Deep Learning Applications for Hyperspectral Imaging: A Systematic Review. Journal of the Institute of Electronics and Computer, 2, 39-56. <https://doi.org/10.33969/JIEC.2020.21004>.
- Paoletti, M. E., Haut, J. M., Plaza, J. y Plaza, A. (2019). Estudio Comparativo de Técnicas de Clasificación de Imágenes Hiperespectrales. Revista Iberoamericana de Automática e Informática Industrial, 16, 129-137.
- Pascual, I. de los A., Ramírez, J. L. y Ortiz, A. (2016). Métodos de inteligencia artificial para la predicción del rendimiento y calidad de gramíneas. REDVET, 17, 1-9.
- Paula A., P., León R., J. y Paula A., P. (2017). Variables biofísicas (NDVI, fPAR, IAF, Fc, kc) obtenidas del procesamiento de imágenes multi-espectrales captadas con cámara Canon SX260HS para el cultivo de papa Solanum spp. Revista Caribeña de Ciencias Sociales, 1-16.
- Pérez C., P. y Alarcón C., J. J. (2014). Empleo de técnicas de teledetección de muy alta resolución espacial para el análisis del comportamiento de las variables fenológicas en cultivos (prunus pérsica) con riego deficitario controlado. Papeles de Geografía, 59-60, 113-124.
- Quito, N., Tacuri, E., López, M. y Lupercio, L. (2020). Detección de estrés hídrico en brócoli (brassica oleracea var. itálica), utilizando ndvi sobre imágenes multiespectrales capturadas a corta distancia. JOURNAL OF SCIENCE AND RESEARCH, 5, 41-59.
- Rojas R., F. (2016). Agricultura de precisión con sensores inalámbricos. 3er Congreso Internacional AMITIC. 8-11.
- Russo, C., Ramón, H., Serafino, S., Cicerchia, B., Sarobe, M., Balmer, A., Álvarez, E., Luengo, P., Useglio, G. y Faroppa, M. (2018). Visión artificial aplicada en Agricultura de Precisión. XX Workshop de Investigadores en Ciencias de la Computación, 992-996.
- Sánchez M., M. y Carvacho B., L. (2013). Aproximación a la determinación del déficit hídrico en la Región del Libertador General Bernardo O'Higgins, Chile, a partir de imágenes MODIS y datos meteorológicos. Revista de Geografía Norte Grande, 55, 109-124.

- Segura H., M. (2020). Correlación entre la humedad del suelo y los índices NDVI y NDWI como indicativo del estrés hídrico en el cultivo de caña de azúcar (*Saccharum officinarum*) en la Variedad BC 001220, ingenio Taboga 2019. (Tesis de licenciatura, UNIVERSIDAD TECNICA NACIONAL).
- Soria R., J., Fernández O., Y. & Granados R., R. (2004). Methodology for prediction of corn yield using remote sensing satellite data in Central Mexico. *Investigaciones geográficas*, 55, 61-78.
- Tang, J., Han, W., & Zhang, L. (2019). UAV Multispectral Imagery Combined with the FAO-56 Dual Approach for Maize Evapotranspiration Mapping in the North China Plain. *Remote Sens*, 11, 1-22.
- Vázquez, P. (2013). Comparación de índices de estrés hídrico, a partir de información captada por el sensor MODIS, en la región pampeana argentina. *Cuadernos Geográficos*, 52, 46-68.
- Vázquez R., M. G., Ibarra R., M., Flores G., F. G. y Moreno C., H. A. (2018). Redes neuronales aplicadas al control de riego usando instrumentación y análisis de imágenes para un microinvernadero aplicado al cultivo de Albahaca. *Research in Computing Science*, 147, 93-103.
- Wahab, I., Hall, O. & Jirstrom, M. (2018). Remote Sensing of Yields: Application of UAV Imagery-Derived NDVI for Estimating Maize Vigor and Yields in Complex Farming Systems in Sub-Saharan Africa. *Drones*, 2, 1-16.
- Zenteno C., G. A., Palacios V., E., Tijerina C., L. y Flores M., H. (2017). Aplicación de tecnologías de percepción remota para la estimación del rendimiento en caña de azúcar. *Rev. Mex. Cienc. Agríc*, 8, 1575-1586.
- Zhang, F. & Zhou, G. (2019). Estimation of vegetation water content using hyperspectral vegetation indices: a comparison of crop water indicators in response to water stress treatments for summer maize. *BMC Ecol*, 19, 1-12.
- Zhang, L., Zhang, H., Niu, Y. & Han, W. (2019). Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. *Remote Sens*, 11, 1-24.
- Zhang, Y., Han, W., Niu, X. & Li, G. (2019). Maize Crop Coefficient Estimated from UAV-Measured Multispectral Vegetation Indices. *Sensors*, 19, 1-17.
- Zúñiga E., C. (2018). Evaluation of water stress in horticultural crops using proximal and remote sensing techniques. (Tesis doctoral, WASHINGTON STATE UNIVERSITY).

### 3 MONITOREO DE ESTRÉS HÍDRICO MEDIANTE ÍNDICES DE VEGETACIÓN EN UN CULTIVO DE MAÍZ (*Zea mays* L.).

#### 3.1 Resumen

El suministro de los requerimientos hídricos en el cultivo de maíz durante la etapa reproductiva es esencial, durante la floración y el llenado de grano es sensible al estrés hídrico, disminuye la producción de materia seca aérea y el rendimiento potencial del maíz. El objetivo del estudio fue comparar el uso de seis índices de vegetación para identificar el estrés hídrico en un cultivo de maíz. Se estableció un experimento completamente aleatorizado con cinco repeticiones, para evaluar tres tratamientos de riego 50, 75 y 100 % ETc. Se realizaron vuelos con un VANT “3DR solo” para obtener imágenes multiespectrales con el sensor Parrot Sequoia (a los 96, 110, 134 y 147 días después de la siembra), los valores de reflectancia se utilizaron para calcular índices de vegetación (IV), el NDVI, GNDVI, GRNDVI, NDVIREDEEDGE, GRVI y WDRVI, para cada repetición de los tratamientos de riego aplicados. Se realizó un análisis estadístico de los IV obtenidos, los índices fueron comparados mediante la prueba de medias (Tukey y Games-Howell) o medianas (Mann-Whitney) para determinar si existía diferencia significativa entre los valores de los índices de vegetación. Los resultados muestran que mientras el cultivo se acerca al final de la etapa reproductiva es posible percibir diferencias significativas en los valores de los IV para cultivos con un estrés hídrico severo.

**Palabras clave:** Reflectancia, *Zea mays* L., CWSI-TR, VANT, Análisis estadístico.

Tesis de Doctorado en Ingeniería

Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Misael López Hernández

Director de Tesis: Ramón Arteaga Ramírez

### **3.2 Introducción**

El maíz se cultiva en todas las entidades federativas del país, debido a la gran importancia agrícola de este cereal en la dieta de los mexicanos (SIAP, 2020). En México el consumo nacional mostró una tendencia creciente (en 2018/2019 fue de 3.3 por ciento), motivado principalmente por mayor uso para la alimentación animal, debido a que la avicultura sigue siendo el principal usuario del grano (FIRA, 2019).

Sánchez et al. (2015) mencionan que en ecosistemas áridos las variables climáticas adquieren relevancia, la precipitación pluvial define la capacidad productiva (o potencial productivo) de las especies cultivadas. Steduto et al. (2012) indican que, donde la cantidad y distribución de la precipitación es generalmente favorable y el suelo es profundo con una alta capacidad de retención de agua, el maíz se cultiva sin necesidad de riego o únicamente con riego suplementario a diferencia de las zonas más áridas, en donde es indispensable el riego de los cultivos. Mencionan que, en zonas de cultivo, en donde la precipitación coincide con el período de crecimiento del maíz, se puede implementar la agricultura de secano o el riego suplementario. Haciendo un uso estacional del agua del maíz dependiendo de la demanda evaporativa de la atmósfera (según el clima), el momento de la estación en la que se siembre el cultivo, la duración del ciclo biológico de este y la disponibilidad de agua.

Las funciones agua-rendimiento y su utilidad dentro de la planificación del uso del agua, han sido objeto de estudio como estrategia para lograr el incremento de la productividad, González, Herrera and López (2010) encontraron correlaciones positivas entre la cantidad de agua aplicada y el rendimiento, determinaron valores del coeficiente de determinación ( $R^2$ ) para sorgo (0.73), soya (0.51) y maíz (0.45), los autores asumen que el rendimiento de estos cultivos se incrementa con el aumento del agua aplicada. Sin embargo, el maíz es el cultivo con mayor factor de sensibilidad al déficit hídrico, lo que confirma su baja tolerancia a la escasez de agua, siendo su alta sensibilidad al estrés hídrico que bajo condiciones limitadas de agua se hace difícil la implementación de

estrategias de manejo, teniendo importantes pérdidas de rendimiento (González, Herrera, López & Cid, 2011).

Steduto et al. (2012) indican que el maíz, con respecto a otros cultivos, se considera sensible al estrés hídrico. El estrés hídrico se desarrolla ante la ausencia de lluvia y riego, y cuando el agua almacenada en la zona radicular se agota hasta el punto en que los procesos de la planta se ven afectados. Aunque algunas variedades de maíz se adaptan a condiciones de déficit hídrico y son resistentes al fenómeno, al entrar a un periodo de latencia el cual se reinicia cuando hay disponibilidad de agua (Valenzuela et al., 2016), después de que el período de estrés hídrico se supera mediante riego o precipitación no es posible compensar la pérdida en productividad (Steduto et al., 2012). Ya que, en la medida que los requerimientos de los cultivos y la oferta ambiental (precipitación pluvial, temperaturas, tipo de suelo, etc.) se separan, en esa medida el potencial de producción se reduce.

Mayer, Rattalino, Navarrete, Maddonni y Otegui (2012) indican que, en regiones agrícolas templadas las precipitaciones anuales suelen ser superiores a la demanda de agua del cultivo de maíz, pero, su distribución e intensidad en conjunto con la alta demanda atmosférica, determina un déficit hídrico estacional, ocasionando un estrés hídrico, resultando en efectos negativos sobre el rendimiento del maíz, por lo cual recomiendan realizar fechas de siembra tempranas o siembra tardías, con la finalidad de adelantar o retrasar la floración.

Zarazúa, Ruiz, González, Flores y Ron (2011) estimaron escenarios futuros, en los cuales habrá un incremento de 6.5 °C en temperaturas máximas, 3.6 °C en temperaturas medias y de 0.09 °C en temperaturas mínimas, y una tendencia promedio a la disminución de la precipitación acumulada durante el ciclo primavera-verano. Por lo anterior, la estación de crecimiento (EC) se acortaría debido a una mayor acumulación de grados día desarrollo, observaron un acortamiento generalizado de 30% en la duración de cada una de las etapas de la EC. Además, el cultivo de maíz deberá soportar temperaturas máximas

mayores a 35 °C, siendo afectada la etapa floración-madurez del grano, ya que, la tasa fotosintética disminuye a temperaturas arriba de 32 °C y cesa a temperaturas mayores a 38 °C. Estas condiciones de aumento de temperaturas y disminución de la precipitación se traducen en estrés, afectando el llenado de grano.

El uso de sensores con los que se equipan los VANT permite obtener índices espectrales que se relacionan con el vigor de los cultivos, además de obtener imágenes infrarrojas y multiespectrales utilizadas para identificar coberturas agrícolas y, crear modelos digitales de elevación y de superficie que permiten estimar la altura de las plantas (SIAP, 2020). Las imágenes adquiridas mediante un Sistema de Aeronaves Pilotadas a Distancia (RPAS) o VANT, permite delimitar e identificar con precisión coberturas dispuestas en áreas pequeñas (Ramírez et al., 2020).

Los drones son una herramienta importante para analizar las diversas variables de interés en la agricultura de precisión, en donde, el poder real proviene del procesamiento de las imágenes y el análisis de los datos recopilados, aunque aún existe el reto de automatizar este proceso (Jiménez, Ojeda & Marcial, 2019). Por su parte, Pino (2019) menciona que se puede recopilar información de diversas bandas del espectro energético con una resolución espacial de hasta 5 centímetros en aquellos momentos que son críticos para el desarrollo de los cultivos.

En México, el SIAP emplea los drones para observar y monitorear al campo mexicano en caso de siniestro por la ocurrencia de fenómenos naturales, tales como inundaciones, heladas, fuertes vientos, lluvia severa y granizadas, lo que permite cuantificar daños oportunamente con una gran exactitud (SIAP, 2020).

El uso de índices de vegetación espectrales en las aplicaciones de la tecnología de los sensores remotos es muy común, estos intentan aproximar relaciones entre los datos espectrales capturados por sensores remotos y variables

biofísicas, como el índice de área foliar (IAF), la biomasa o la cobertura aérea (Romero et al., 2009). Sin embargo, tienen problemas de saturación mínimos y corresponden a un patrón expo–lineal del crecimiento (vegetativo–reproductivo) de la vegetación (Paz, Reyes & Mediano, 2011).

El procesamiento de una imagen espectral permite obtener información real (NDVI) al discriminar colores, formas, tamaños, entre otros (Bautista, Constante, Gordon & Mendoza, 2018). García et al. (2020) indican que al clasificar los píxeles el resultado es un valor medio de la vegetación (valores de los índices pertenecientes al maíz). Las imágenes multiespectrales procesadas mediante el software PIX4D permite tener una alta correlación (0.98 para todas las bandas) entre los valores de reflectancia calculada y los valores verdaderos de la reflectancia del suelo (Cubero et al., 2018).

Sepúlveda (2019) menciona, que el uso de imágenes obtenidas con Drones permite abordar variables como la detección de plagas durante el periodo de crecimiento del cultivo, mejorar la aplicación de fertilizantes en zonas puntuales del cultivo, así mismo optimizar el riego localizado, disminuyendo los costos de producción. Los valores de los índices de vegetación son asociados al vigor de la vegetación (Pineda et al., 2020), varían de acuerdo con las diferencias en el contenido de humedad del suelo y la disponibilidad de nitrógeno (Farrell et al., 2018). Estos índices de vegetación permiten a los agricultores enfocarse en realizar actividades oportunas de manejo, que se consideran críticas para mejorar los rendimientos finales, como la aplicación de fertilizantes y el riego de los cultivos (Wahab et al., 2018). El objetivo del estudio fue comparar el uso de seis índices de vegetación para identificar el estrés hídrico durante la etapa reproductiva del cultivo de maíz, calculados a partir del procesamiento de imágenes multiespectrales obtenidas de un sensor Parrot Sequoia acoplado a un VANT.

### 3.3 Materiales y métodos

El presente estudio de investigación fue realizado en la parcela experimental del área de Meteorología del Departamento de Irrigación, situada dentro del campus de la Universidad Autónoma Chapingo (UACH), la cual se ubica a 19° 30' latitud N y 98° 51' longitud O. Esta área se caracteriza por presentar un clima templado subhúmedo con lluvias en verano ((Cb(Wo)(W)(i') g), precipitación media anual de 664 mm, época seca en invierno y temperatura media anual de 15.5 °C (López, Arteaga, Ruiz, Vázquez & López, 2019).

Se estableció un cultivo de maíz blanco para grano el 11 de Julio de 2019 de la variedad ANIBAL de la casa de semillas Aspros. El experimento consistió en tres tratamientos de riego: 50, 75 y 100% de la evapotranspiración del cultivo (ETc), tratamiento 1 (estrés severo), 2 (estrés leve) y 3 (bien regado) respectivamente, completamente aleatorizado con cinco repeticiones por tratamiento. La ETc se estimó al multiplicar la evapotranspiración de referencia (ET0) por el coeficiente de cultivo, la ET0 fue estimada por el método de FAO Penman-Montieth (Allen, Pereira, Raes & Smith, 2006). Dada por la ecuación 1:

$$ET0 = \frac{0.408 \Delta(R_n - G) + \gamma \left( \frac{900}{T + 273} \right) u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34 u_2)} \quad (1)$$

Donde, ET0 es la evapotranspiración de referencia (mm día<sup>-1</sup>), R<sub>n</sub> radiación neta en la superficie del cultivo (MJ m<sup>-2</sup> día<sup>-1</sup>), G flujo del calor de suelo (MJ m<sup>-2</sup> día<sup>-1</sup>), T temperatura media del aire a 2 m de altura (°C), u<sub>2</sub> velocidad del viento a 2 m de altura (m s<sup>-1</sup>), e<sub>s</sub> presión de vapor de saturación (kPa), e<sub>a</sub> presión real de vapor (kPa), e<sub>s</sub> - e<sub>a</sub> déficit de presión de vapor (kPa), Δ pendiente de la curva de presión de vapor (kPa °C<sup>-1</sup>) y γ la constante psicrométrica (kPa °C<sup>-1</sup>).

Las cantidades de agua requerida por el cultivo de maíz para los tratamientos 1, 2 y 3 fueron de 305, 368 y 433 mm, respectivamente, incluida la precipitación efectiva ocurrida durante el ciclo de crecimiento. Para determinar los requerimientos y momentos de riego se realizó un balance hídrico diario,

ecuación 2, este balance de entradas y salidas se explica de manera minuciosa en el Boletín 56 de la FAO (Allen et al., 2006).

$$D_{r,i} = D_{r,i-1} - (P - RO)_i - I_i - CR_i + ET_{c,i} + DP_i \quad (2)$$

Donde,  $D_{r,i}$  es el agotamiento de humedad en la zona radicular del suelo al final del día  $i$  (mm),  $D_{r,i-1}$  se refiere al contenido de humedad en la zona radicular al final del día anterior,  $i-1$  (mm),  $P_i$  es la precipitación en el día  $i$  (mm),  $RO_i$  es el escurrimiento superficial en el día  $i$  (mm),  $I_i$  representa la lámina neta de riego en el día  $i$  que infiltra en el suelo (mm),  $CR_i$  es el ascenso capilar proveniente de la mesa de agua subterránea en el día  $i$  (mm),  $ET_{c,i}$  es la evapotranspiración del cultivo en el día  $i$  (mm) y  $DP_i$  son las pérdidas de agua de la zona radicular por percolación profunda en el día  $i$  (mm).

Como parte de las actividades del experimento se realizaron cuatro muestreos destructivos durante la etapa reproductiva del cultivo, se cosecharon dos plantas por repetición, las cuales fueron fraccionadas por órgano vegetativo (tallo, hoja y mazorca) con la finalidad de deshidratarlas en un horno para secado (POM-326-F) hasta peso seco constante de cada planta. Una vez finalizado el ciclo del cultivo se cosechó una parcela útil de 24 m<sup>2</sup> (2.4 m x 10 m) por cada repetición de cada tratamiento para poder estimar el rendimiento del cultivo.

En el presente estudio se realizaron cuatro vuelos con VANT para obtener las imágenes del cultivo, se programaron el día en el que se realizaron los muestreos destructivos. Las imágenes multispectrales fueron obtenidas mediante el sensor Parrot Sequoia acoplado aun VANT "3DR solo" (ver Figura 3-1), con el sensor fue posible obtener imágenes de 4 x 4 cm de tamaño de pixel para cuatro bandas espectrales: Green (550 nm), Red (660 nm), Red Edge (735 nm) y NIR (790 nm).



Figura 3-1. VANT “3DR solo” equipado con un sensor multispectral Parrot Sequoia utilizado para obtener imágenes de alta resolución espacial.

Las imágenes multispectrales fueron procesadas mediante el software PIX4D, en el cual se realizó el procesamiento fotogramétrico y radiométrico de las imágenes, una vez realizado, se obtuvieron cuatro ortomosaicos (uno por cada banda) y también cuatro mapas de reflectancia corregidos y normalizados (valores entre 0 y 1).

García et al. (2020) mencionan, que la segmentación y clasificación de los objetos en suelo y vegetación permite filtrar los valores medios de los índices de vegetación pertenecientes a los píxeles de las plantas de maíz. Haciendo uso de los ortomosaicos se obtuvo una imagen compuesta en falso color (NIR, RED,

GREEN), se utilizó el infrarrojo cercano para facilitar la detección de los píxeles de maíz, imagen que se transformó a escala de grises y que posteriormente, mediante el algoritmo de Otsu (Otsu, 1975) se determinó el umbral para agrupar los píxeles que pertenecían al cultivo de maíz y discriminar píxeles de suelo, malezas y sombras de la imagen, logrando así obtener una imagen binaria, la cual se utilizó para obtener los índices de vegetación (IV) correspondientes al cultivo de Maíz. Ya que, por ejemplo, Paz et al. (2008) encontraron que el NDVI clásico, resulta inadecuado para estimar variables biofísicas que se asocian a la vegetación, bajo efectos combinados del suelo y de la atmósfera.

Una vez obtenidos los mapas de reflectancia (a partir de las imágenes calibradas con la tarjeta de calibración de la cámara), con estos valores se determinaron seis índices de vegetación (IV) por cada repetición de cada tratamiento: el NDVI, GNDVI, GRNDVI, NDVIREDEGE, GRVI y WDRVI, ver Cuadro 3-1.

Cuadro 3-1. Índices de vegetación calculados mediante el procesamiento de imágenes multiespectrales.

Índice de vegetación	Fórmula
Normalized difference vegetation index	$NDVI = (RNir - RRed)/(RNir + RRed)$
Green normalized vegetation index	$GNDVI = (RNir - RGreen)/(RNir + RGreen)$
Green and red normalized vegetation index	$GRNDVI = (RNir - (RGreen + RRed))/(RNir + (RGreen + RRed))$
Normalized difference red edge	$NDRE = (RNir - RRE)/(RNir + RRE)$
Green Ratio Vegetation Index	$GRVI = RNir/RGreen$
Wide dynamic range vegetation index	$WDRVI = (0.1 \times RNir - RRed)/(0.1 \times RNir + RRed)$

RNir, RRed, RRE y RGreen, son los valores de reflectancia para las bandas Nir, Red, Red edge y Green, respectivamente.

Los IV fueron calculados con el software Matlab versión académica de la UACH, con la finalidad de identificar el estrés hídrico mediante los valores de los índices de vegetación. Una vez obtenidos los valores de los IV se realizó un producto de matrices entre los IV calculados y la matriz de la imagen binaria, a la matriz resultante se obtuvo el valor promedio de cada IV para cada repetición de cada tratamiento de riego.

Al no contar con imágenes térmicas se determinó el índice de estrés hídrico del cultivo (CWSI) mediante índices espectrales, donde valores de 0 indican un

cultivo bien regado y valores de 1 para un cultivo sometido a un estrés hídrico severo, el procedimiento utilizado fue desarrollado por Zhang et al. (2019), los autores indican que la relación TCARI/RDVI puede distinguir con precisión diferentes niveles de tratamientos de riego deficitario para el cultivo de maíz.

El CWSI-TR se determinó mediante la ecuación 3, a partir de los índices RDVI y TCARI dados por las ecuaciones 4 y 5:

$$CWSI - TR = \begin{cases} 0 & (TCARI/RDVI \leq 0.195) \\ 2.41(TCARI/RDVI) - 0.47 & (0.195 < TCARI/RDVI < 0.609) \\ 1 & (0.609 < TCARI/RDVI) \end{cases} \quad (3)$$

$$RDVI = \frac{\rho_{nir} - \rho_{red}}{\sqrt{\rho_{nir} + \rho_{red}}} \quad (4)$$

$$TCARI = 3[(\rho_{rededge} - \rho_{red}) - 0.2(\rho_{rededge} - \rho_{green}) * (\rho_{rededge} / \rho_{red})] \quad (5)$$

Donde  $\rho_{red}$ ,  $\rho_{rededge}$ ,  $\rho_{green}$  y  $\rho_{nir}$  son los valores de reflectancia en las bandas rojo, borde del rojo, verde e infrarrojo cercano, respectivamente.

Con la finalidad de determinar; sí, mediante índices de vegetación es posible identificar el estrés hídrico, se realizó el análisis estadístico de los índices de vegetación calculados, materia seca y rendimiento, se realizó una prueba de hipótesis de un análisis de varianza de un factor, para lo cual, antes se verificó la independencia de las muestras mediante el método de Correlación de Pearson con un nivel de significancia del 5 % y se comprobó que se cumpliera con el supuesto de normalidad, mediante la prueba de normalidad Ryan-Joiner (similar a Shapiro-Wilk).

Posteriormente se realizó la prueba de igualdad de varianzas por el método de Bartlett con un nivel de significancia del 5 % para determinar; sí, se asumía varianzas iguales o no, esta información fue determinante en el ANOVA para comparar medias. Similar a Zhang and Zhou (2019), una vez comprobado el supuesto de normalidad se procedió a realizar el ANOVA de un solo factor con un nivel de significancia del 5%.

Es posible realizar el análisis de dos maneras: presuponiendo o no la igualdad de varianzas para el análisis. Para probar la diferencia media entre los pares de grupos, al asumir varianzas iguales se realizó la comparación de medias mediante la prueba de Tukey caso contrario (no asumiendo igualdad de varianzas) se realizó mediante el procedimiento de Games-Howell.

En los casos donde los datos no siguen una distribución normal, se realizó el análisis mediante Pruebas no paramétricas. Se utilizó la prueba de la mediana de Mood, donde se evaluó si las medianas de la población son todas iguales, en este caso no se cuenta con suficiente evidencia para rechazar la hipótesis nula de que las medianas de población son todas diferentes. Y concluye el análisis del efecto del factor riego en sus tres niveles.

Por el contrario, al concluir que no todas las medianas de las poblaciones son iguales, se realizó la Prueba de Mann-Whitney, para determinar si las medianas de población de dos grupos difieren. Similar a lo realizado por Pérez y Alarcón (2014), quienes utilizaron la prueba Mann-Whitney para poder comparar los valores espectrales de las imágenes que no seguían una distribución normal.

Se compararon las distintas combinaciones posibles entre los niveles de riego (tratamientos) para determinar si sus medianas eran estadísticamente iguales o no, para inferir si los valores de las medianas de los índices de vegetación eran mayor o menor para los tratamientos evaluados. Para más información de las pruebas realizadas se sugiere consultar la ayuda en línea de Minitab (2019). En la Figura 3-2 se muestra el diagrama de flujo del análisis estadístico de los datos realizado en este estudio.

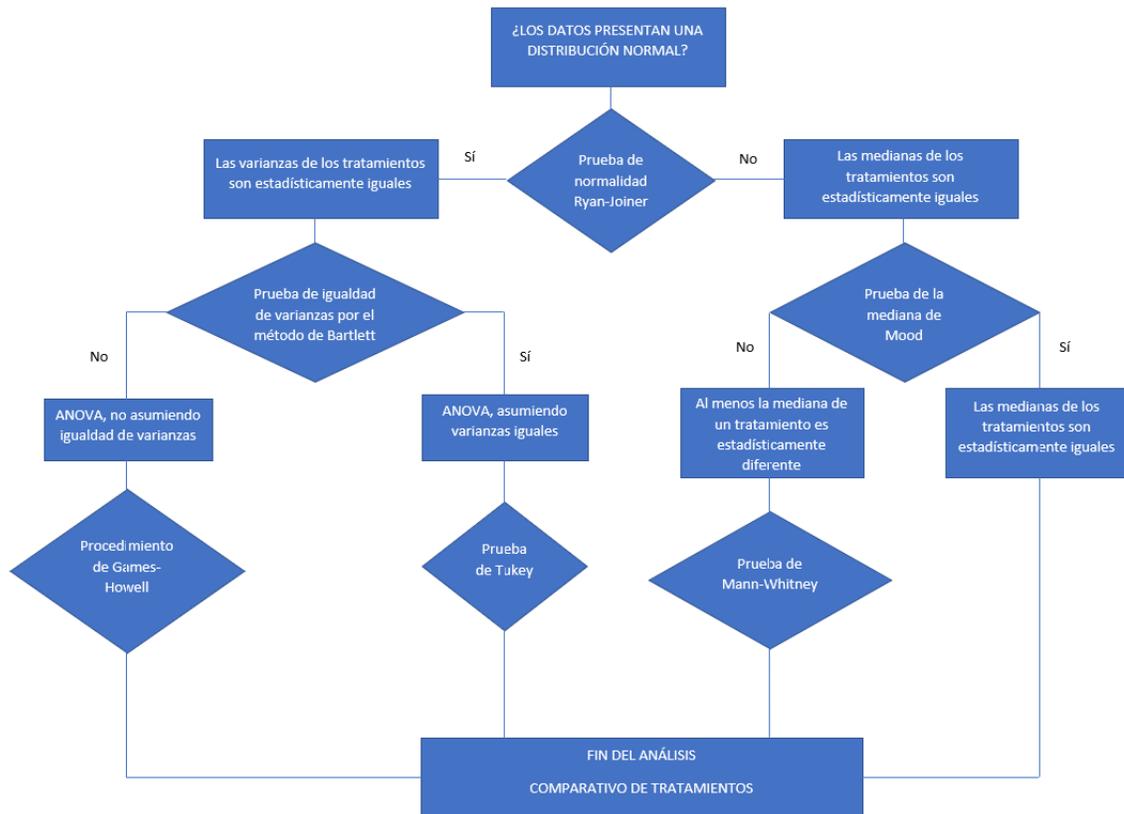


Figura 3-2. Diagrama de flujo del análisis estadístico para los índices de vegetación, materia seca y rendimiento.

### 3.4 Resultados y discusión

#### 3.4.1 Índices de vegetación

Cuando no se realiza la discriminación de píxeles que no pertenecen al cultivo, no es posible identificar en la etapa reproductiva diferencias significativas en los valores de los IV antes de los 130 DDS (días después de la siembra). Esto debido que, al promediar valores de píxeles de maleza, suelo y/o sombras de la imagen, los valores de los IV calculados son bajos. Debido a un sesgo al considerar los píxeles pertenecientes al suelo y las sombras, como resultado se obtiene un valor mixto de píxeles plantas de maíz, suelo y sombras (García et al., 2020).

Cuando el cultivo está próximo a madurez fisiológica (147 DDS), los índices NDRE y WDRVI que se podría utilizar para tratar de identificar el estrés hídrico en ocasiones no es posible realizar la segmentación de una imagen o que su resolución complique realizar este proceso, lo cual debe ser verificado con imágenes de menor resolución espacial.

Se sugiere calcular los valores de los IV en una etapa intermedia entre los 130 y 147 DDS, ya que, se encontraron diferencias significativas para todos los IV en el tercer vuelo, aunque de esta manera sólo permitió diferenciar el tratamiento con más estrés (50% ETc), ya que, los valores para los IV del tratamiento 3 (100% ETc) no son estadísticamente diferentes al tratamiento 2 (con un nivel bajo de estrés, 75% ETc), que no permite identificar niveles de estrés leve en el cultivo, ver Cuadro 3-2.

Esto se puede deber a que los pixeles que no pertenecen a la cobertura vegetal del cultivo tengan una variación de los valores de los IV en comparación a los calculados para pixeles del cultivo de maíz, Paz et al. (2007) encontraron que en esta etapa los valores de IV no se saturan por efecto del suelo, generando una gran dispersión en los valores del IV calculado.

Por otro lado, al no encontrar diferencias y con valores de IV bajos, en el mejor de los casos se podría interpretar como un cultivo estresado, al cual se le aportaría agua, corrigiendo la falta de agua en un cultivo estresado, mientras que, si se tratara de un cultivo bien regado al aportar un exceso de agua, provocaría un estrés por aireación.

Caso contrario; sí, se determina como apropiado un IV bajo para un cultivo de maíz bien regado por efecto de suelo, sombras u otro tipo de vegetación, no sería posible corregir problemas de estrés hídrico, disminuyendo la producción de materia seca y el rendimiento esperado del cultivo de maíz. Tales situaciones se pueden evitar al determinar los IV reales sólo para el cultivo de interés, separando los pixeles que no pertenecen a la superficie cubierta por maíz.

Cuadro 3-2. Valores de índices de vegetación de la imagen sin segmentar.

ÍNDICE	PRUEBA DE MEDIAS O MEDIANAS										
	PRUEBA	DIFERENCIA	T	ESTADÍSTICA	L	T	ESTADÍSTICA	L	T	ESTADÍSTICA	L
<b>96 días después de la siembra</b>											
NDVI	Games-Howell	NO	T3	0.4796	A	T2	0.4762	A	T1	0.4675	A
GNDVI	Tukey	NO	T3	0.4292	A	T2	0.4240	A	T1	0.4160	A
NDRE	Tukey	NO	T3	0.1906	A	T2	0.1849	A	T1	0.1745	A
GRNDVI	Tukey	NO	T3	0.3624	A	T2	0.3575	A	T1	0.3497	A
GRVI	Tukey	NO	T3	4.2030	A	T2	4.0740	A	T1	3.9650	A
WDRVI	Tukey	NO	T3	0.0591	A	T2	0.0564	A	T1	0.0514	A
<b>110 días después de la siembra</b>											
NDVI	Tukey	NO	T2	0.4767	A	T1	0.4679	A	T3	0.4538	A
GNDVI	Tukey	NO	T2	0.4281	A	T1	0.4197	A	T3	0.4089	A
NDRE	Tukey	SI	T3	0.1862	A	T3	0.1753	AB	T1	0.1707	B
GRNDVI	Tukey	NO	T2	0.3480	A	T1	0.3359	A	T3	0.3338	A
GRVI	Tukey	NO	T2	3.8653	A	T3	3.7490	A	T1	3.6748	A
WDRVI	Tukey	NO	T3	0.0096	A	T2	0.0042	A	T1	-0.0141	A
<b>134 días después de la siembra</b>											
NDVI	Tukey	SI	T2	0.3967	A	T3	0.3713	A	T1	0.2864	B
GNDVI	Tukey	SI	T2	0.3613	A	T3	0.3411	A	T1	0.2866	B
NDRE	Mann-Whitney	SI	T2	0.1394	A	T3	0.1382	A	T1	0.0941	B
GRNDVI	Tukey	SI	T2	0.2643	A	T3	0.2511	A	T1	0.1564	B
GRVI	Tukey	SI	T2	2.8221	A	T3	2.7320	A	T1	1.9241	B
WDRVI	Tukey	SI	T3	-0.0822	A	T2	-0.0946	A	T1	-0.2042	B
<b>147 días después de la siembra</b>											
NDVI	Games-Howell	NO	T3	0.2701	A	T2	0.1780	A	T1	0.1332	A
GNDVI	Games-Howell	NO	T3	0.2908	A	T2	0.2448	A	T1	0.2364	A
NDRE	Mann-Whitney	SI	T3	0.0921	A	T2	0.0663	A	T1	0.0540	B
GRNDVI	Games-Howell	NO	T3	0.1473	A	T2	0.0582	A	T1	0.0189	A
GRVI	Games-Howell	NO	T3	1.9860	A	T2	1.4956	A	T1	1.4117	A
WDRVI	Tukey	SI	T3	-0.2153	A	T2	-0.3045	B	T1	-0.3461	B

Valores de los índices de vegetación para los tres tratamientos (T, donde T1, T2 y T3 corresponde al 50, 75 y 100% de ETc) y diferentes letras (L) en la misma fila indican diferencias estadísticamente significativas con un  $\alpha$  de 0.05, para la prueba de medias de Tukey y Games-Howell para muestras con distribución normal o de medianas de Mann-Whitney para muestras con distribución no normal.

En el Cuadro 3-3 se observa que al separar la vegetación de interés es posible obtener el valor de IV real que corresponde al estado de salud de la planta, se tienen valores (medios) más altos para los IV al comienzo de la etapa reproductiva y estos disminuyen al final del ciclo, a los 96 DDS se determina que no es posible diferenciar entre los tratamientos de riego, debido que se satisfacen

las necesidades hídricas de la planta imposibilitando identificar el efecto del estrés hídrico mediante el uso de IV, excepto por el índice NDRE, el cual podría diferenciar el tratamiento con la lámina de riego menor (50% ETc).

Cuadro 3-3. Valores de índices de vegetación para pixeles cubiertos de cultivo de maíz.

ÍNDICE	PRUEBA DE MEDIAS O MEDIANAS										
	PRUEBA	DIFERENCIA	T	ESTADÍSTICA	L	T	ESTADÍSTICA	L	T	ESTADÍSTICA	L
<b>96 días después de la siembra</b>											
NDVI	Tukey	NO	T3	0.8473	A	T2	0.8470	A	T1	0.8441	A
GNDVI	Tukey	NO	T3	0.7579	A	T2	0.7541	A	T1	0.7509	A
NDRE	Tukey	SI	T3	0.3365	A	T2	0.3289	AB	T1	0.3154	B
GRNDVI	Tukey	NO	T3	0.6395	A	T2	0.6358	A	T1	0.6308	A
GRVI	Tukey	NO	T3	7.3970	A	T2	7.2460	A	T1	7.1430	A
WDRVI	Tukey	NO	T3	0.1024	A	T2	0.1004	A	T1	0.0911	A
<b>110 días después de la siembra</b>											
NDVI	Tukey	SI	T3	0.8220	A	T2	0.8191	AB	T1	0.8072	B
GNDVI	Tukey	SI	T3	0.7406	A	T2	0.7356	AB	T1	0.7239	B
NDRE	Mann-Whitney	NO	T3	0.3153	A	T2	0.3120	A	T1	0.2921	A
GRNDVI	Tukey	SI	T3	0.6046	A	T2	0.5982	AB	T1	0.5794	B
GRVI	Tukey	SI	T3	6.7907	A	T2	6.6440	AB	T1	6.3390	B
WDRVI	Tukey	NO	T3	0.0172	A	T2	0.0079	A	T1	-0.0243	A
<b>134 días después de la siembra</b>											
NDVI	Tukey	SI	T3	0.7486	A	T2	0.7456	A	T1	0.5905	B
GNDVI	Tukey	SI	T3	0.6876	A	T2	0.6790	A	T1	0.5909	B
NDRE	Tukey	SI	T3	0.2712	A	T2	0.2639	A	T1	0.1901	B
GRNDVI	Tukey	SI	T3	0.5063	A	T2	0.4969	A	T1	0.3226	B
GRVI	Mann-Whitney	SI	T3	5.5985	A	T2	5.4309	A	T1	3.8631	B
WDRVI	Tukey	SI	T3	-0.1652	A	T2	-0.1776	A	T1	-0.4207	B
<b>147 días después de la siembra</b>											
NDVI	Games-Howell	SI	T3	0.5443	A	T2	0.3723	AB	T1	0.2701	B
GNDVI	Games-Howell	SI	T3	0.5915	A	T2	0.5090	AB	T1	0.4793	B
NDRE	Games-Howell	NO	T3	0.1868	A	T2	0.1372	A	T1	0.1062	A
GRNDVI	Games-Howell	SI	T3	0.2936	A	T2	0.1233	AB	T1	0.0385	B
GRVI	Games-Howell	SI	T3	4.0230	A	T2	3.1130	AB	T1	2.8629	B
WDRVI	Games-Howell	NO	T3	-0.4487	A	T2	-0.6294	A	T1	-0.7014	A

Valores de los índices de vegetación para los tres tratamientos (T, donde T1, T2 y T3 corresponde al 50, 75 y 100% de ETc) y diferentes letras (L) en la misma fila indican diferencias estadísticamente significativas con un  $\alpha$  de 0.05, para la prueba de medias de Tukey y Games-Howell para muestras con distribución normal o de medianas de Mann-Whitney para muestras con distribución no normal.

Al acercarse a madurez fisiológica es más evidente la diferenciación del estado de salud de la planta (134 y 147 DDS), ya que, a diferencia del tratamiento regado al 100% ETc los tratamientos de menor riego (tratamiento 2 y 1) al tener menos disponibilidad de agua, el cultivo acelera su senescencia, por esta razón al estar sometidos a estrés en una etapa muy sensible a la falta de agua hace que los valores de los índices de vegetación disminuyan, aunque para estudios posteriores es recomendable el establecimiento del cultivo en una fecha más temprana (para el área de estudio), se espera que estos resultados sean más evidentes.

Los resultados de los valores de las medias para los IV muestran que es posible identificar el efecto de un estrés hídrico severo (tratamiento 1) a los 134 DDS, mientras que un estrés leve es menos evidente. Similar a lo encontrado por Zúñiga (2018), el autor reporta, que el NDVI no fue representativo de las diferencias de tratamientos correspondientes a niveles de riego medio y bajo, mientras, en su estudio el índice GNDVI fue más sensible (cuando el estrés hídrico se ve prolongado), a detectar diferencias entre tratamientos de estrés hídrico moderado y severo (30 y 15% de nivel de riego, respectivamente), aunque en este caso ningún índice fue sensible para diferenciar los tratamientos 1 y 2.

Se debe considerar que los IV se deben calcular antes de que las hojas comiencen a secarse, ya que como se muestra en el Cuadro 3-3, al final de la etapa reproductiva los valores de IV a los 147 DDS muestran que el tratamiento 2 estadísticamente comparte grupo de medias con los tratamientos 1 y 3, además, índices como NDRE y WDRVI no son capaces de identificar diferencias en los tratamientos.

Los valores de los índices de vegetación muestran una tendencia a disminuir conforme avanza el ciclo de crecimiento del cultivo de maíz, un cultivo de maíz bajo estrés hídrico leve (tratamiento 2) o severo (tratamiento 1) en general evidencia valores de IV menores en comparación con un cultivo bien regado (tratamiento 3), un efecto negativo del estrés hídrico al vigor del cultivo de maíz.

### 3.4.2 CWSI-TR

Los valores de CWSI-TR calculados muestran que a los 96 y 110 DDS el cultivo de maíz no refleja estrés hídrico (CWSI-TR=0), mientras que a los 134 días fue posible diferenciar el estrés hídrico severo y el estrés leve, el tratamiento 1 presentó un valor de CWSI-TR igual a 0.69, estadísticamente diferente (mayor) a los tratamientos 2 y 3, es de llamar la atención que el cultivo bien regado (tratamiento 3) el valor de CWSI-TR indicó que el cultivo expresó signos de estrés hídrico leve al ser estadísticamente igual al tratamiento 2, aunque el valor fue muy cercano a 0, acorde a lo reportado por Zhang et al. (2019), los autores obtuvieron un valor de CWSI de 0.11 para su tratamiento control (sin estrés) y de 0.4 para su tratamiento de mayor estrés hídrico, para la etapa de madurez. Mientras que a los 147 DDS el CWSI-TR es estadísticamente igual para los tres tratamientos, estos valores se pueden deber a que el cultivo entró en la etapa de senescencia, ver Cuadro 3-4.

Cuadro 3-4. Valores medios de CWSI-TR para los tratamientos de riego.

DDS	PRUEBA DE MEDIAS											
	PRUEBA	DIFERENCIA	T	ESTADISTICA	L	T	ESTADISTICA	L	T	ESTADISTICA	L	
96	CULTIVO SIN ESTRÉS HÍDRICO (CWSI-TR FUE IGUAL A 0).											
110	CULTIVO SIN ESTRÉS HÍDRICO (CWSI-TR FUE IGUAL A 0).											
134	TUKEY	SI	T1	0.6339	A	T2	0.1534	B	T3	0.1080	B	
147	TUKEY	NO	T2	0.7247	A	T1	0.6362	A	T3	0.5796	A	

Días después de la siembra (DDS).

Al relacionar el CWSI-TR con los IV los valores de  $R^2 \leq 0.38$  muestran que no es posible diferenciar el estrés hídrico a los 147 DDS mediante IV debido a que el CWSI -TR es estadísticamente igual para los tres tratamientos, mientras que a los 134 DDS fue posible diferenciar el efecto del estrés hídrico, se obtuvieron valores de  $R^2 \geq 0.94$ , siendo el GNDVI y GRVI los IV con valores muy cercanos a 1. Los coeficientes de correlación indican que a medida que los valores de los IV disminuyen, el CWSI-TR se acerca más a 1, ver Cuadro 3-5.

Cuadro 3-5. Relación entre los IV y el CWSI-TR del cultivo de maíz.

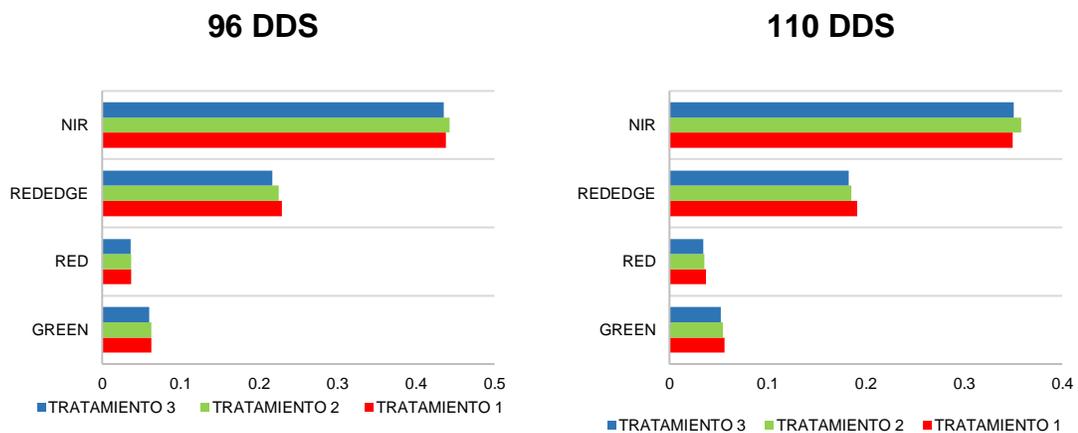
COEFICIENTE DE DETERMINACIÓN (R <sup>2</sup> )						
DDS	NDVI	GNDVI	NDRE	GRNDVI	GRVI	WDRVI
96		CULTIVO SIN ESTRÉS HÍDRICO (CWSI-TR FUE IGUAL A 0).				
110		CULTIVO SIN ESTRÉS HÍDRICO (CWSI-TR FUE IGUAL A 0).				
134	0.96	0.99	0.94	0.98	0.99	0.98
147	0.26	0.32	0.38	0.29	0.38	0.34

COEFICIENTE DE CORRELACIÓN (R)						
DDS	NDVI	GNDVI	NDRE	GRNDVI	GRVI	WDRVI
96		CULTIVO SIN ESTRÉS HÍDRICO (CWSI-TR FUE IGUAL A 0).				
110		CULTIVO SIN ESTRÉS HÍDRICO (CWSI-TR FUE IGUAL A 0).				
134	-0.98	-0.99	-0.97	-0.99	-0.99	-0.99
147	-0.51	-0.56	-0.62	-0.54	-0.62	-0.59

Días después de la siembra (DDS).

En la Figura 3-3 es posible visualizar la reflectancia normalizada de los tratamientos evaluados durante el estudio, se muestra que estas son similares a los 96 y 110 DDS cuando el CWSI-TR fue igual a 0, mientras que cuando el cultivo expresó estrés hídrico, a los 134 y 147 DDS, los valores de las reflectancias normalizadas en la banda del rojo fueron mayores para el tratamiento sometido a un estrés severo (tratamiento 1) y menores en el infrarrojo cercano en comparación con el tratamiento 2 (estrés leve) y 3. Similar a lo encontrado por Naveen et al. (2020), los autores indican que la reflectancia en la región NIR disminuye con el aumento de los niveles de estrés hídrico y es mayor en el visible.



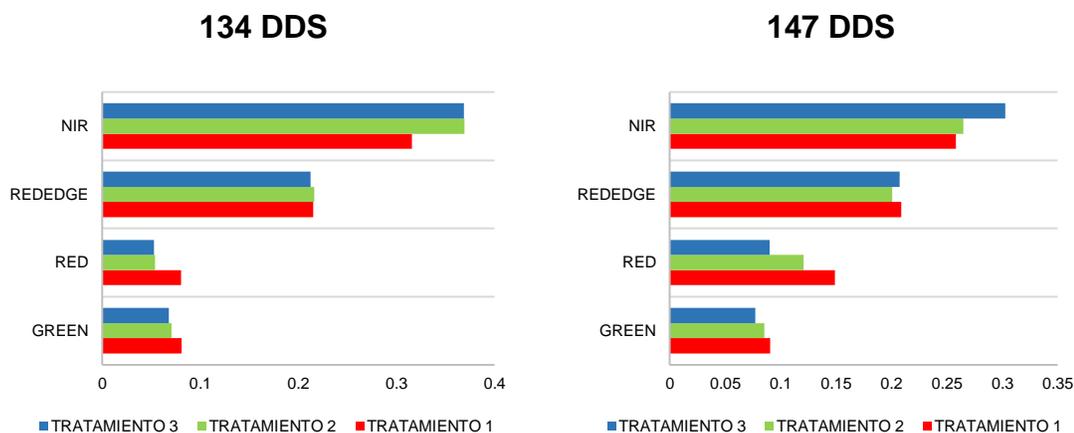


Figura 3-3. Valores medios de reflectancia normalizada de los tratamientos 1, 2 y 3 (50, 75 y 100% de ETc).

### 3.4.3 Materia seca y rendimiento

Los resultados en el Cuadro 3-6 muestran que es posible identificar a partir de los 110 DDS la diferencia en la producción de materia seca en función del tratamiento de riego, siendo más evidente el efecto de los tratamientos a los 134 DDS, donde se puede observar que el tratamiento de 100% ETc de riego permite acumular mayor cantidad de materia seca (MS) en comparación con los tratamientos de estrés hídrico 1 y 2, siendo el tratamiento de 50% de ETc en el cual la planta acumula menor cantidad de MS (134 DDS).

Lo anterior indica que se debe realizar el monitoreo del estrés hídrico a partir de los 110 DDS para poder corregir problemas de estrés hídrico en el cultivo de maíz, ya que, aunque es evidente la diferencia de producción de MS entre tratamientos, el cultivo al acercarse a madurez fisiológica ocasiona que los tratamientos que tienen una lámina de riego menor al 100% ETc entren en senescencia y no sea posible diferenciar estadísticamente o visiblemente el efecto del estrés hídrico en la planta, además de que la producción de materia seca comienza a ser constante al final del ciclo del cultivo.

La disminución en la acumulación de materia seca a los 147 DDS (cercano a madurez) debido a falta de agua fue de 23 a 31% respecto al tratamiento de 100% ETc. El estrés hídrico en la etapa vegetativa puede ocasionar diferencias

en la acumulación de MS de 23 a 31%, y una reducción de 20% de la biomasa si el estrés se manifiesta en la etapa de llenado de grano (Jiménez, 2012).

Cuadro 3-6. Producción media de materia seca por planta (en gramos) para los tratamientos evaluados.

DDS	PRUEBA DE MEDIAS											
	PRUEBA	DIFERENCIA	T	ESTADISTICA	L	T	ESTADISTICA	L	T	ESTADISTICA	L	
96	TUKEY	NO	T3	192	A	T2	177	A	T1	156.34	A	
110	TUKEY	SI	T3	266	A	T2	217	AB	T1	188.8	B	
134	TUKEY	SI	T3	352	A	T2	274	B	T1	210.1	C	
147	TUKEY	SI	T3	406	A	T2	311	B	T1	281.4	B	

Valores medios para producción de materia seca para los tres tratamientos (T) y diferentes letras (L) en la misma fila indican diferencias estadísticamente significativas con un  $\alpha$  de 0.05.

Los rendimientos promedio alcanzados por tratamiento fueron los siguientes:

Tratamiento 3 (100% de ETc) 12.52 ton ha<sup>-1</sup> A,

Tratamiento 2 (75% de ETc) 8.24 ton ha<sup>-1</sup> B,

Tratamiento 1 (50% ETc) 7.38 ton ha<sup>-1</sup> C,

Donde, diferentes letras indican diferencias estadísticamente significativas con un  $\alpha$  de 0.05 para la prueba de medianas de Mann-Whitney.

Se muestra que aplicar una lámina de riego menor al 100% ETc ocasiona una disminución del rendimiento del cultivo de maíz, que va de 4.28 a 5.14 ton ha<sup>-1</sup> con un estrés hídrico leve a severo respectivamente, hubo una reducción del 34 al 41% del rendimiento obtenido con el tratamiento 3 de la variedad de maíz utilizada en el presente estudio. Algo similar a lo que encontraron Sánchez, Bueno, Esquivel and Velásquez (2015) en su estudio, indican que el cultivo de maíz en respuesta al déficit hídrico rendiría el 35% del rendimiento máximo esperado, acorde a lo reportado también por Jiménez (2012), en su estudio determinó que las deficiencias hídricas durante la etapa de llenado de grano disminuyeron el rendimiento entre 29 y 31%.

### **3.5 Conclusiones**

Es posible identificar el estrés hídrico en el cultivo de maíz mediante el procesamiento de imágenes multiespectrales de alta resolución espacial obtenidas con un VANT, al calcular índices de vegetación que hacen uso de las bandas del verde, rojo, infrarrojo cercano y red edge. Fue posible identificar el estrés hídrico al determinar los valores de los índices de vegetación sólo para superficie cubierta por el cultivo, ya que, sin esta diferenciación, no se encuentran diferencias significativas entre los valores de los índices de Vegetación.

Los tratamientos que fueron sometidos a estrés hídrico son a los que les corresponden menores valores de índices de vegetación, en comparación del tratamiento regado con el 100% de ET<sub>c</sub>, el estrés hídrico fue evidente mientras el cultivo se acerca a la madurez fisiológica, siendo más evidente a los 134 y 147 días después de la siembra, cuando los valores son menores o iguales a 0.59, 0.59, 0.19, 0.32, 3.86 y -0.42, para los índices NDVI, GNDVI, NDRE, GRNDVI, GRVI y WDRVI respectivamente.

Los tratamientos de estrés hídrico evaluados durante la etapa reproductiva del cultivo de maíz muestran que la producción de materia seca y el rendimiento disminuyen. Los resultados del presente estudio permiten plantear que, al relacionar los valores de los índices de vegetación con la producción de materia seca y rendimiento del cultivo de maíz es posible predecir y representar estas variables del cultivo en mapas temáticos, de utilidad en la toma de decisiones para el manejo de cultivo.

### 3.6 Literatura citada

- Allen, R. G., Pereira, L. S., Raes, D. & Smith, M. (2006). Evapotranspiración del cultivo. Consultado en: [www.fao.org/publications](http://www.fao.org/publications).
- Bautista, R., Constante, P., Gordon A. y Mendoza, D. (2018). Diseño e implementación de un sistema de visión artificial para análisis de datos NDVI en imágenes espectrales de cultivos de brócoli obtenidos mediante una aeronave pilotada remotamente. *REVISTA INFOCIENCIA*, 12, 1-18.
- Cubero C., M., Schneider Z., K. Bellomo, M., Shi, D., Rehak M. & Strecha, C. (2018). Assessment Of The Radiometric Accuracy In A Target Less Work Flow Using Pix4D Software. *IEEE Whispers*, 1-4.
- Farrell, M., Gili, A. & Noellemeyer, E. (2018). Spectral indices from aerial images and their relationship with properties of a corn crop. *Precision Agric.*, 19, 1127–1137.
- FIRA (Fideicomisos Instituidos en Relación con la Agricultura). (2019). Panorama Agroalimentario Maíz 2019. Consultado en: <https://www.inforural.com.mx/wp-content/uploads/2019/11/Panorama-Agroalimentario-Ma%C3%Adz-2019.pdf> (Consulta: marzo 2021).
- García M., H., Flores M., H, Ascencio H., R., Khalil G., K., Tijerina C., L., Mancilla V., O. R. & Vázquez P., M. A. (2020). Corn Grain Yield Estimation from Vegetation Indices, Canopy Cover, Plant Density, and a Neural Network Using Multispectral and RGB Images Acquired with Unmanned Aerial Vehicles. *Agriculture*, 10, 1-24.
- González R., F., Herrera P., J., López S., T. y Cid L., G. (2011). Respuesta de los cultivos al déficit hídrico. *Ingeniería Agrícola*, 1, 34-40.
- González R., F., Herrera P., J. & López S., T. (2010). Water productivity of corn, soybean and sorghum in Red Ferralitic soils of the south of Havana. *Rev Cie Téc Agr*, 19, 95-97.
- Jiménez, L. (2012). Production of Corn with Water Stress at Different Stages of Development. *Agrociencia Uruguay*, 16, 92-102.
- Jiménez J., S. I., Ojeda B., W. y Marcial P., M. de J. (2019). Información de drones y su análisis en la agricultura de precisión [Artículo]. Quinto Congreso Nacional COMEII 2019, Mazatlán, Sinaloa, México. Consultado en: <http://www.riego.mx/congresos/comeii2019/docs/ponencias/extenso/COM EII-19003.PDF>.
- López H., M, Arteaga R., R, Ruiz G., A, Vázquez P. M. A. y López R., J. I. (2019). Productividad del agua normalizada para el cultivo de maíz (*Zea mays*) en Chapingo, México. *Agrociencia*, 53, 811-820.
- Mayer, L. I., Rattalino E., J. I., Navarrete S., R., Maddonni, G. A. y Otegui, M. E. (2012). Efecto de las altas temperaturas en la productividad de maíz. *AAPRESID*, 12-18.

- Software estadístico Minitab 19. (2019). [Software de ordenador]. State College, PA: Minitab, Inc. Consultado en: <https://www.minitab.com/es-mx/support/>
- Naveen, H. R., Balaji N., B., Sreenivas, G., Kumar, A., Adinarayana, J., Avil K., K. & Shankaraiah, M. (2020). Hyperspectral Remote Sensing for Determining Water and Nitrogen Stress in Maize during RabiSeason. *CJAST*, 38, 1-9.
- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica*, 11, 23-27.
- Paz P., F., Bolaños G., M., Palacios V., E., Palacios S., L. A., Martínez M., M. y Huete, A. (2008). Optimización del índice espectral de la vegetación NDVIcp. *Agrociencia*, 42, 925-937.
- Paz P., F., Palacios V., E., Bolaños G., M., Palacios S., L. A., Martínez M., M., Mejía S., E. y Huete, A. (2007). Diseño de un índice espectral de la vegetación: NDVIcp. *Agrociencia*, 41, 539-554.
- Paz P., F., Reyes, M. y Mediano, E. (2011). Diseño de índices espectrales de la vegetación usando curvas iso-suelo. *Agrociencia*, 45, 121-134.
- Pérez C., P. y Alarcón C., J. J. (2014). Empleo de técnicas de teledetección de muy alta resolución espacial para el análisis del comportamiento de las variables fenológicas en cultivos (prunus pérsica) con riego deficitario controlado. *Papeles de Geografía*, 59-60, 113-124.
- Pino V., E. (2019). Los drones una herramienta para una agricultura eficiente: un futuro de alta tecnología. *Idesia (Arica)*, 37, 75-84.
- Ramírez, M., Martínez, L., Montilla, M., Sarmiento, O., Lasso, J. y Díaz, S. (2020). Obtención de cobertura de tierras agrícolas en imágenes de satélite Sentinel-2 con inyección de imágenes de drones utilizando Random Forest en Google Earth Engine. *Revista de Teledetección*, 56, 49-68.
- Romero S., E., Paz P., F., Palacios V., E., Bolaños G., M., Valdez L., R. y Aldrete, A. (2009). Diseño de un índice espectral de la vegetación desde una perspectiva conjunta de los patrones exponenciales y lineales del crecimiento. *Agrociencia*, 43, 291-307.
- Steduto, P., D. Raes, T. C. Hsiao, E. Fereres, & L. Heng, L. (2012). Respuesta del rendimiento de los cultivos herbáceos al agua: el modelo de simulación AquaCrop. Consultado en: [www.fao.org/publications](http://www.fao.org/publications).
- Sánchez C., I., Bueno H., P., Esquivel A., G., & Velásquez V., M. A. (2015). Impact of crop sensitivity to water stress in rain feed areas of Mexico. *Revista Chapingo Serie Zonas Áridas*, 14, 61-74.
- Sepúlveda R., A. (2019). Relación entre un índice de vegetación sana (NDVI) y la productividad del trigo. *Revista Geográfica De Chile Terra Australis*, 55, 24-34.

- SIAP (SERVICIO DE INFORMACIÓN AGROALIMENTARIA Y PESQUERA). (2020). Panorama Agroalimentario 2020. Consultado en: <https://www.inforural.com.mx/wp-content/uploads/2020/11/Atlas-Agroalimentario-2020.pdf>.
- Valenzuela G., L, Rodríguez H., E. D., Durán B., E. H., Lugo A., M., Suárez S., J. C. y Narváez N., J. A. (2016). Comportamiento agronómico de Maíz (*Zea mays* L.) cultivado bajo diferentes condiciones hídricas del suelo. *Mom. Cien.*, 13, 45-50.
- Wahab, I., Hall, O. & Jirström, M. (2018). Remote Sensing of Yields: Application of UAV Imagery-Derived NDVI for Estimating Maize Vigor and Yields in Complex Farming Systems in Sub-Saharan Africa. *Drones*, 2, 1-16.
- Zarazúa V., P., Ruiz C., J. A., González E., D. R., Flores L., H. E. y Ron P., J. (2011). Impactos del cambio climático sobre la agroclimatología del maíz en Ciénega de Chapala, Jalisco. *Rev. Mex. Cienc. Agríc.*, 2, 351-363.
- Zhang, F. & Zhou, G. 2019. Estimation of vegetation water content using hyperspectral vegetation indices: a comparison of crop water indicators in response to water stress treatments for summer maize. *BMC Ecol*, 19, 1-12.
- Zhang, L., Zhang, H., Niu, Y. & Han, W. (2019). Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. *Remote Sens*, 11, 1-24.
- Zúñiga E., C. (2018). Evaluation of water stress in horticultural crops using proximal and remote sensing techniques. (Tesis doctoral, WASHINGTON STATE UNIVERSITY).

## 4 ÍNDICES DE VEGETACIÓN PARA LA PREDICCIÓN DE MATERIA SECA Y RENDIMIENTO DEL CULTIVO DE MAÍZ (*Zea mays* L.).

### 4.1 Resumen

Las técnicas de teledetección y el procesamiento de imágenes adquiridas con sensores remotos permiten predecir el rendimiento de los cultivos. En la parcela experimental de la estación meteorológica del departamento de Irrigación ubicada dentro del campus de la UACH se realizó un experimento de Maíz con tres tratamientos de riego complementario: 100%, 75% y 50% de la Evapotranspiración del cultivo (ET<sub>c</sub>), con cinco repeticiones en un diseño completamente aleatorizado. Con el objetivo de evaluar la relación de los índices de vegetación calculados mediante el procesamiento de imágenes multiespectrales de alta resolución espacial adquiridas con el sensor Parrot Sequoia implementado sobre un VANT. Se desarrolló una GUI en Matlab que permitió estimar la producción de materia seca por planta y el rendimiento del cultivo mediante modelos cuadráticos y de regresión lineal múltiple en los cuales los índices de vegetación (IV) son el valor de entrada (predictor), mediante los modelos se obtuvieron mapas de estas variables biofísicas. Los resultados mostraron que los índices GNDVI y GRVI presentaron un valor de R<sup>2</sup> mayor al resto de los IV evaluados, para predecir materia seca por planta y rendimiento del cultivo de maíz. También se mapeo el coeficiente de cultivo K<sub>c</sub> y la ET<sub>c</sub> a partir de IV. El mapeo permitiría el monitoreo y manejo del riego del cultivo de maíz, mediante el procesamiento de imágenes multiespectrales adquiridas mediante un VANT.

**Palabras clave:** *Zea mays* L., Redes Neuronales Artificiales, GUI, Modelos, Mapeo.

Tesis de Doctorado en Ingeniería

Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Misael López Hernández

Director de Tesis: Ramón Arteaga Ramírez

## **4.2 Introducción**

El uso de imágenes de satélites (de baja resolución espacial y temporal) son idóneas para monitoreo de grandes extensiones, mientras que las imágenes multiespectrales y RGB tomadas con un VANT permiten obtener imágenes de alta resolución espacial y temporal, estas imágenes permiten calcular índices de vegetación y la altura de la planta, valores que se han utilizado para estimar la producción de biomasa aérea y el rendimiento de los cultivos mediante análisis de regresión, donde los índices de vegetación son valores de entrada de los modelos reportados en investigaciones, dichos valores hacen que los modelos sean más precisos cuando toman en cuenta sólo la cobertura vegetal del cultivo, donde la discriminación de píxeles es fundamental para incrementar la precisión en las estimaciones.

Farrell y Rivas (2010), indican que el uso de imágenes satelitales MODIS es viable para obtener modelos de estimación de rendimientos, sin embargo, respecto a estimaciones a nivel de lote, se deberá trabajar con imágenes de mayor resolución espacial, ya que, el uso de imágenes de alta resolución espacial permite derivar en información más precisa (Soria et al., 2004). Además de la resolución espacial, el éxito de los resultados dependerá también de la resolución espectral y de la calidad de los datos de campo (Martínez et al., 2016).

Por su parte, Gordillo (2018) menciona que los sensores de los satélites no cumplían con la frecuencia temporal y la resolución espectral requerida, debido a lo anterior el uso de cámaras multiespectral montadas en una plataforma Dron (o UAV) en combinación con técnicas de teledetección han impulsado el uso de los UAV en el campo de la agricultura de precisión. Se detectó niveles de estrés hídrico de los cultivos desde la plataforma VANT (Jiménez, 2009). Sin embargo, Pérez y Alarcón (2014) resaltan que el rango espectral de estas imágenes no permite obtener información del espectro térmico, ni el detalle de los sensores hiperespectrales.

Los drones en la agricultura además de la estimación de biomasa y rendimiento de los cultivos también han sido utilizados para estimar la cobertura vegetal y densidad de plantas mediante el procesamiento de imágenes RGB y multiespectrales (García et al., 2020). Los índices calculados que utilizan la información de la fracción de vegetación mejoran su desempeño y producen estimaciones confiables de biomasa aérea (de maíz), gracias a la muy alta resolución del sensor de imagen que permite estimar la cobertura del suelo del dosel (Corti et al., 2019).

Cobos (2020) resalta la importancia del preprocesamiento de las imágenes para obtener mejores resultados. (Gordillo, 2018), utilizó el método del vecino más cercano para la clasificación supervisada de una imagen y definió polígonos de interés, donde calculó los índices de vegetación promedio para cada unidad experimental, este proceso también se ha realizado mediante otros métodos como clasificación no supervisada (Quito et al., 2020) obteniendo como resultado un polígono máscara de recorte, Mousabeygi et al. (2020) aplicaron el algoritmo de Otsu al RGRl para separar los píxeles en dos clases, obteniendo una máscara binaria para segmentar las plantas verdes contra el fondo.

Este tipo de herramientas permitió en algunos casos calcular recomendaciones de fertilización con nitrógeno (Padilla et al., 2018) y estimar su contenido en las hojas de las plantas (Elvanidi et al., 2018), mediante la modelación con el uso de índices de vegetación NDVI como valor de entrada (Tagarakis and Ketterings, 2018). Otros índices de vegetación como el GRVI Y EL WDRVI han sido utilizados para la predicción del rendimiento en los cultivos, como en el caso del maíz (Maresma, Ariza, Martínez, Lloveras & Martínez, 2016).

Los valores del Índice Normalizado Diferencial de Vegetación (NDVI) y Coeficiente de cultivo (Kc) presentan una relación lineal. Lo anterior permitió derivar el Kc de imágenes de satélite (un valor de Kc para cada pixel) y crear un mapa de Kc correspondiente a condiciones ideales de crecimiento (Cuesta et al., 2005).

León et al., (2016) validaron el método Kc-NDVI y encontraron que el Kc obtenido con el drone tiene una tendencia similar para las fases fenológicas a los obtenidos mediante los métodos de determinación de Kc de su investigación, indican que una secuencia de imágenes permite el seguimiento de la evolución temporal del coeficiente de cultivo en sus diferentes fases de desarrollo. Ya que, los datos obtenidos por este método son muy cercanos a los obtenidos mediante métodos de determinación de evapotranspiración en suelo como el de Penman Monteith para la Eto y valores tabulados de coeficiente de cultivo Kc (Paula et al., 2017).

Por su parte Reyes et al. (2019) establecieron una regresión lineal entre el NDVI derivado de las imágenes de satélite y el NDVI del GreenSeeker con el Kc tomado del manual FAO-56. La ecuación obtenida la usaron para estimar el Kc como una función del NDVI, estos valores de Kc y la evapotranspiración de referencia (Eto) son utilizados para determinar la ETc. Debido a lo descrito, el objetivo del estudio fue determinar modelos de predicción de materia seca por planta y rendimiento del cultivo de maíz con índices de vegetación como valores de entrada, así como también mapear el coeficiente de cultivo Kc y la evapotranspiración de cultivo (ETc), a partir del procesamiento de imágenes multiespectrales obtenidas con el sensor Parrot Sequoia acoplado a un drone.

#### **4.3 Materiales y métodos**

La presente investigación se realizó en la parcela experimental del área de Meteorología del Departamento de Irrigación de la Universidad Autónoma Chapingo (UACH), ubicada en las coordenadas 19° 30' latitud N y 98° 51' longitud O. Un cultivo de maíz blanco para grano fue establecido el 11 de Julio de 2019, de la variedad ANIBAL de la casa de semillas Aspros.

El experimento consistió en tres tratamientos de riego: 50, 75 y 100% de la evapotranspiración del cultivo (ETc), tratamiento 1 (estrés severo), 2 (estrés leve) y 3 (bien regado) respectivamente, con cinco repeticiones por tratamiento, para un diseño completamente aleatorizado. Se realizaron cuatro muestreos destructivos durante la etapa reproductiva del cultivo, se cosecharon dos plantas

de maíz por repetición, estas fueron fraccionadas por órgano vegetativo (tallo, hoja y mazorca) y deshidratadas en un horno para secado (POM-326-F) hasta peso seco constante. Una vez finalizado el ciclo del cultivo se estimó el rendimiento del cultivo al cosechar la parcela útil definida de 2.4 m x 10 m, con una superficie de 24 m<sup>2</sup>, esto se realizó para cada repetición de cada tratamiento ver Figura 4-1.



Figura 4-1. Recopilación de datos de materia seca y rendimiento final para el cultivo de maíz.

En el presente estudio se realizaron cuatro vuelos de VANT para obtener imágenes multiespectrales del cultivo a los 96, 110, 134 y 147 días después de la siembra (DDS). Las imágenes fueron obtenidas mediante el sensor Parrot Sequoia acoplado a un VANT “3DR solo”, el sensor mide la reflectancia en las siguientes longitudes de onda: Green (550 nm), Red (660 nm), Red Edge (735 nm) y NIR (790 nm).

Posteriormente se realizó el procesamiento fotogramétrico y radiométrico de las imágenes mediante el software PIX4D, se obtuvieron cuatro ortomosaicos por cada vuelo realizado y cuatro mapas de reflectancia, estas imágenes (mapas de reflectancia) fueron calibradas con los valores de la tarjeta de calibración de la cámara para cada banda (Green: 17.1%, Red: 21.6%, Red 68dgc: 26.8% y Nir: 37.2%), antes de cada vuelo se realizó la toma de imágenes al target de

calibración para poder realizar el proceso de calibración al procesar las imágenes con el software PIX4D, como se observa en la Figura 4-2.



Figura 4-2. Toma de imágenes del “calibration target” con el del sensor Parrot Sequoia antes de realizar los vuelos.

Para poder procesar las imágenes obtenidas se diseñó una interfaz gráfica de usuario GUI en Matlab (Versión académica de la UACH) la cual lee una imagen compuesta y crea una imagen en falso color llamada “VEGETACIÓN” con las bandas NIR, RED y GREEN, para las bandas 1, 2 y 3, respectivamente. Esta imagen se transformó a escala de grises, mediante el algoritmo de Otsu (Otsu, 1975) se discriminaron pixeles de suelo, malezas y sombras de la imagen, logrando así obtener una imagen binaria, ver Figura 4-3.

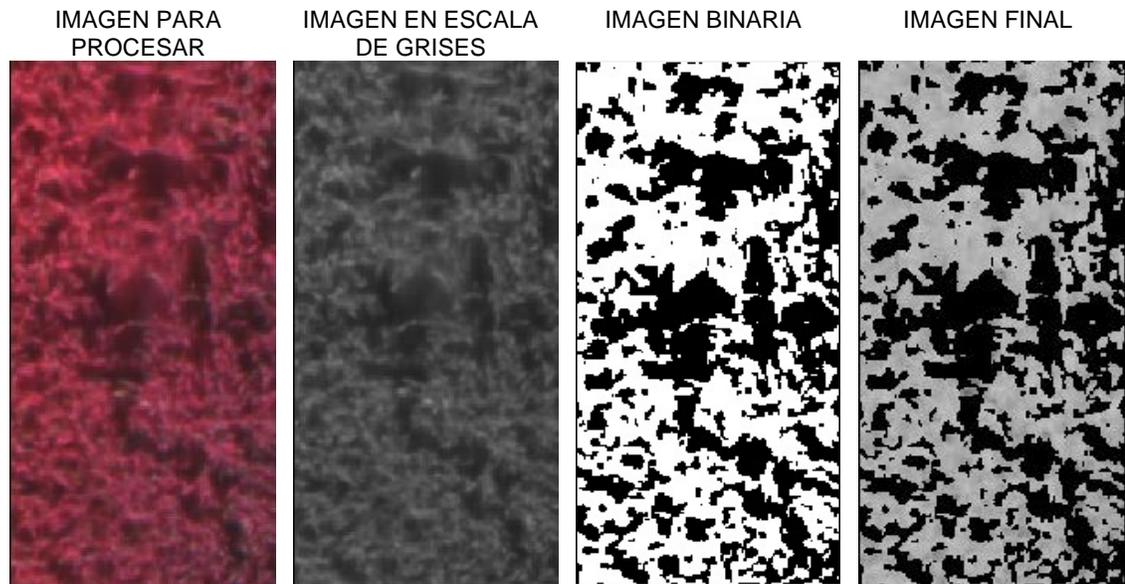


Figura 4-3. Procesamiento de una imagen multispectral con la GUI de Matlab.

La GUI permitió calcular índices espectrales mediante fórmulas a partir de los mapas de reflectancia. Seis índices de vegetación (IV) por cada repetición de cada tratamiento fueron calculados con las ecuaciones 1, 2, 3, 4, 5 y 6:

$$NDVI = \frac{R_{nir} - R_{red}}{R_{nir} + R_{red}} \quad (1)$$

$$GNDVI = \frac{RNir - RGreen}{RNir + RGreen} \quad (2)$$

$$GRNDVI = (RNir - (RGreen + RRed)) / (RNir + (RGreen + RRed)) \quad (3)$$

$$NDRE = \frac{RNir - RRE}{RNir + RRE} \quad (4)$$

$$GRVI = \frac{RNir}{RGreen} \quad (5)$$

$$WDRVI = \frac{0.1 \times RNir - RRed}{0.1 \times RNir + RRed} \quad (6)$$

Donde  $R_{nir}$ ,  $R_{red}$ ,  $RRE$  y  $R_{green}$ , son los valores de reflectancia para las bandas Nir, Red, Red Edge y Green, respectivamente.

Después se realizó el producto entre la imagen binaria (donde el valor de 1 corresponde a los pixeles de interés) y los índices de vegetación (IV) calculados. Con la finalidad de obtener el valor de la media de los índices de vegetación para las parcelas útiles de cada repetición de cada tratamiento, los cuales fueron utilizados para predecir la producción de materia seca por planta y el rendimiento. Los modelos evaluados fueron: el lineal, cuadrático, cúbico y exponencial.

Se determinó un modelo para estimar el coeficiente de cultivo ( $K_c$ ) mediante índices de vegetación, al realizar una regresión lineal para el tratamiento de 100% de ETc. También se validaron las metodologías desarrolladas por Cuesta et al. (2005) y Zhang et al. (2019) para estimar el  $K_c$  mediante índices espectrales. Cuesta et al. (2005) indican que el  $K_c$  se puede calcular con la ecuación 7:

$$K_{c-1} = 1.5625 * NDVI - 0.05 \quad (7)$$

Mientras que la metodología de Zhang et al. (2019), determina el  $K_c$  con la ecuación 8, a partir de índices de vegetación, con las ecuaciones 9 y 10:

$$K_{c-2} = \begin{cases} 1.15 \left( 1 - \frac{NDVI_{max} - NDVI}{NDVI_{max} - NDVI_{min}} \right) + 0.9(1 - 1.19(NDVI - NDVI_{min})); & (TCARI/RDVI \leq 0.195) \\ (1.47 - 2.41 \left( \frac{TCARI}{RDVI} \right)) \left( 1.15 \left( 1 - \frac{NDVI_{max} - NDVI}{NDVI_{max} - NDVI_{min}} \right) \right) + 0.9(1 - 1.19(NDVI - NDVI_{min})); & (0.195 < TCARI/RDVI < 0.609) \\ 0; & (0.609 < TCARI/RDVI) \end{cases} \quad (8)$$

$$RDVI = \frac{\rho_{nir} - \rho_{red}}{\sqrt{\rho_{nir} + \rho_{red}}} \quad (9)$$

$$TCARI = 3[(\rho_{rededge} - \rho_{red}) - 0.2(\rho_{rededge} - \rho_{green}) * (\rho_{rededge} / \rho_{red})] \quad (10)$$

Donde  $\rho_{red}$ ,  $\rho_{rededge}$ ,  $\rho_{green}$  y  $\rho_{nir}$  son los valores de reflectancia en las bandas rojo, borde del rojo, verde e infrarrojo cercano, respectivamente.  $NDVI_{max}$  es igual al valor medio máximo de los 4 vuelos realizado (0.87) y el valor de  $NDVI_{min}$  fue tomado del estudio realizado por Zhang et al. (2019), los autores determinaron un valor de  $NDVI_{min}$  igual a 0.14 para el cultivo de maíz.

Finalmente, se obtuvo la evapotranspiración del cultivo (ET<sub>c</sub>) mediante el producto del K<sub>c</sub> estimado mediante índices de vegetación y la evapotranspiración de referencia, obtenida con el método de FAO Penman-Monteith (Allen et al., 2006).

La capacidad de predicción de la producción de materia seca (por planta), el rendimiento a partir de IV se evaluó mediante el coeficiente de determinación (R<sup>2</sup>) y el estadístico S. Mientras que en el caso del coeficiente de cultivo K<sub>c</sub> y la ET<sub>c</sub>, además del R<sup>2</sup>, se realizó la prueba de medias de Tukey para determinar si los valores estimados eran estadísticamente iguales a los valores observados, con un nivel de significancia igual a 0.05. Más información sobre el coeficiente de determinación, la prueba de media de Tukey y el estadístico S se puede revisar en la ayuda en línea de Minitab (2019).

#### **4.4 Resultados y discusión**

##### **4.4.1 GUI en Matlab**

El uso del software Matlab facilitó el tratamiento de los datos al procesar las imágenes tomadas con el VANT, calcular índices de vegetación y, además, permite su visualización durante el análisis (Bonnaire, Montoya & Obando, 2021). Se programó una GUI de Matlab, que permite procesar imágenes multiespectrales, compone una imagen de vegetación en RGB con las bandas NIR, RED y GREEN, la cual es transformada en escala de grises y mediante el algoritmo de Otsu (y el valor del umbral) se obtiene la imagen binaria. Esta a su vez es multiplicada por los índices de vegetación resultado de la programación de fórmulas para obtener los índices espectrales de interés. Además, muestra las imágenes originales y finales, y sus respectivos histogramas. Los resultados son mostrados en forma de tablas, donde se muestran valores medios de los IV, índice de estrés hídrico del cultivo (CWSI-TR), el coeficiente de cultivo (K<sub>c</sub>) mediante las metodologías utilizadas para estimar esta variable, el coeficiente de estrés hídrico (K<sub>s</sub>), la evapotranspiración del cultivo, la producción de materia seca por planta y el rendimiento del cultivo de maíz.

También, es posible visualizar la reflectancia en las bandas que mide el sensor Parrot Sequoia, lo cual nos da una idea de la reflectancia de los cultivos en función del estrés hídrico y la salud de la vegetación. Permite visualizar y los valores medios de los índices de vegetación para una imagen completa y compararlos con los IV determinados a partir de la discriminación de otros tipos de vegetación diferentes al cultivo de maíz o sombras en la imagen.

Los índices de vegetación, los mapas de reflectancia, de Kc, ETC, de materia seca por planta y rendimiento estimado son exportados como imágenes proyectadas, que pueden ser usadas mediante un software de Sistemas de Información Geográfica (SIG) para procesos de interés. Los valores presentados en tablas son exportados como archivos de Excel (en formato .xlsx), la interfaz se muestra en la Figura 4-4.

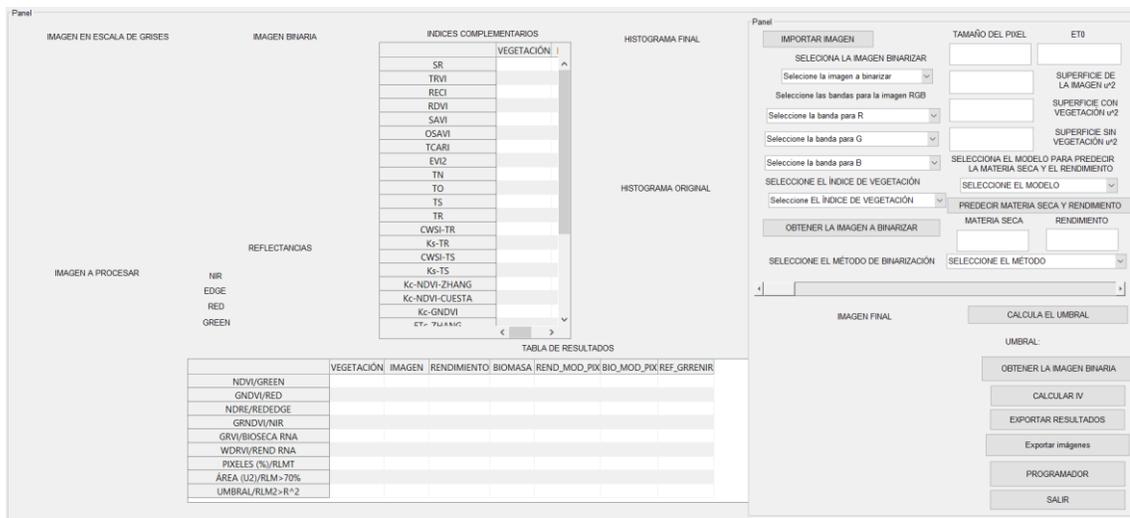


Figura 4-4. GUI diseñada en el entorno de Matlab para el procesamiento de imágenes multiespectrales.

#### 4.4.2 Predicción de la producción de materia seca y rendimiento

En el Cuadro 4-1 se muestran los estadísticos para los modelos significativos con un nivel de significancia observado menor a 0.05 para la predicción de materia seca por planta. Con referencia a la producción media de materia seca, los índices de vegetación alcanzan un mayor coeficiente de determinación mientras más se acerca el cultivo a madurez fisiológica, esto debido a que la materia seca no deja de acumularse hasta el final del ciclo del cultivo.

Los índices GNDVI y GRVI presentaron valores más altos de  $R^2$ , de 0.6 a 0.65 y de 0.54 a 0.66, respectivamente. Similar a los valores determinados por Elsayed and Darwish (2017), los autores encontraron valores de coeficiente de determinación máximos de 0.57 para la estimación de peso seco de biomasa mediante índices de vegetación, mientras que Argolo et al. (2020) obtuvieron un modelo empírico con base en SAVI con un  $R^2$  de 0.74 para la biomasa de maíz.

Cuadro 4-1. Estadísticas de los modelos evaluados para estimar la producción media de materia seca por planta en gramos (g).

INDICES DE VEGETACIÓN	LINEAL			CUADRÁTICO			CÚBICO			EXPONENCIAL		
	S	R <sup>2</sup>	MSE	S	R <sup>2</sup>	MSE	S	R <sup>2</sup>	MSE	S	R <sup>2</sup>	MSE
<b>134 días después de la siembra</b>												
NDVI	52.5	0.51	2752.8	54.5	0.52	2965.1	56.8	0.52	3230.5	52.3	0.52	2736.9
GNDVI	52.4	0.52	2748.9	53.0	0.54	2813.7	54.9	0.55	3010.5	51.8	0.53	2683.8
NDRE	50.3	0.55	2529.1	52.3	0.55	2738.3	53.5	0.57	2864.0	50.5	0.55	2548.3
GRNDVI	52.0	0.52	2705.0	53.9	0.53	2900.8	56.2	0.53	3154.4	51.8	0.53	2681.2
GRVI	50.9	0.54	2593.6	52.3	0.55	2740.3	54.6	0.55	2982.5	50.5	0.55	2550.1
WDRVI	51.8	0.53	2684.1	53.9	0.53	2907.2	56.1	0.53	3145.7	51.9	0.53	2688.9
<b>147 días después de la siembra</b>												
NDVI	51.8	0.57	2685.7	51.5	0.61	2653.4	53.8	0.61	2893.2	52.9	0.55	2793.2
GNDVI	50.0	0.60	2504.1	48.7	0.65	2373.8	50.6	0.65	2561.6	54.5	0.57	2656.5
NDRE	53.9	0.53	2906.6	53.6	0.57	2868.7	55.9	0.58	3120.7	55.0	0.51	3027.0
GRNDVI	51.5	0.57	2647.5	49.6	0.63	2464.5	51.8	0.64	2686.8	52.7	0.55	2778.2
GRVI	52.5	0.56	2753.1	48.6	0.65	2359.2	50.4	0.66	2537.2	53.9	0.53	2909.7
WDRVI	53.9	0.53	2909.4	51.6	0.60	2666.3	53.5	0.61	2861.2	55.0	0.51	3025.2

S= Desviación Estándar Residual Estimada,  $R^2$ = Coeficiente de Determinación, MSE= Cuadrado Medio del Error.

En el caso de la predicción del rendimiento de maíz mediante índices de vegetación, los modelos determinados a los 96 y 110 días después de la siembra no fueron significativos y los índices que presentaron valores más altos de  $R^2$  a los 147 días después de la siembra fueron el GNDVI y GRVI, ver Cuadro 4-2.

Los resultados muestran un  $R^2$  de 0.67 a 0.82 para la estimación del rendimiento en grano del cultivo de maíz, valores acordes a los obtenidos por Elsayed and Darwish (2017), estos autores encontraron valores de coeficiente de determinación máximos de 0.61 al relacionar IV con el rendimiento en grano.

Cuadro 4-2. Estadísticas de los modelos evaluados para estimar el rendimiento de maíz en ton ha<sup>-1</sup>.

INDICES DE VEGETACIÓN	LINEAL			CUADRÁTICO			CÚBICO			EXPONENCIAL		
	S	R <sup>2</sup>	MSE	S	R <sup>2</sup>	MSE	S	R <sup>2</sup>	MSE	S	R <sup>2</sup>	MSE
<b>134 días después de la siembra</b>												
NDVI	2.11	0.40	4.46	2.08	0.46	4.35	2.03	0.54	4.11	2.08	0.42	4.33
GNDVI	2.04	0.44	4.18	2.01	0.50	4.05	1.89	0.60	3.57	2.01	0.46	4.04
NDRE	1.99	0.47	3.97	1.87	0.57	3.51	1.79	0.64	3.21	1.94	0.50	3.75
GRNDVI	2.07	0.43	4.30	2.03	0.49	4.14	1.91	0.59	3.64	2.04	0.45	4.16
GRVI	2.00	0.47	3.99	1.95	0.53	3.81	1.74	0.66	3.03	1.96	0.49	3.83
WDRVI	2.06	0.43	4.25	2.00	0.51	4.01	1.85	0.61	3.43	2.02	0.46	4.08
<b>147 días después de la siembra</b>												
NDVI	1.50	0.70	2.24	1.56	0.70	2.42	1.62	0.70	2.61	1.50	0.71	2.25
GNDVI	1.40	0.74	1.98	1.46	0.74	2.15	1.35	0.80	1.81	1.43	0.73	2.05
NDRE	1.53	0.69	2.35	1.56	0.70	2.44	1.50	0.74	2.24	1.58	0.67	2.51
GRNDVI	1.46	0.72	2.13	1.52	0.72	2.30	1.54	0.73	2.37	1.48	0.71	2.19
GRVI	1.44	0.72	2.06	1.43	0.75	2.06	1.25	0.82	1.56	1.50	0.70	2.24
WDRVI	1.51	0.70	2.28	1.56	0.70	2.43	1.51	0.74	2.29	1.54	0.68	2.37

S= Desviación Estándar Residual Estimada, R<sup>2</sup>= Coeficiente de Determinación, MSE= Cuadrado Medio del Error.

En el Cuadro 4-3 se muestran los modelos cuadráticos seleccionados e implementados en la GUI de Matlab para predecir la materia seca y el rendimiento del cultivo de maíz.

Cuadro 4-3. Modelos seleccionados para estimar la producción de materia seca y el rendimiento de maíz.

<b>Variables biofísicas</b>
<b>Materia seca (g/planta)</b>
7.7 + 1230*NDVI – 906.1*NDVI <sup>2</sup>
- 1879 + 7178*GNDVI – 5586*GNDVI <sup>2</sup>
- 69.4 + 4186*NDRE – 8781*NDRE <sup>2</sup>
235.1 + 1010*GRNDVI – 1330*GRNDVI <sup>2</sup>
- 942.0 + 638.0*GRVI – 73.98*GRVI <sup>2</sup>
223.9 – 1108*WDRVI – 1472*WDRVI <sup>2</sup>
<b>Rendimiento (ton ha<sup>-1</sup>)</b>
4.600 + 10.16*NDVI + 4.50*NDVI <sup>2</sup>
- 14.25 + 52.2*GNDVI – 13.6*GNDVI <sup>2</sup>
- 1.748 + 104.5*NDRE – 168.8*NDRE <sup>2</sup>
6.909 + 17.88*GRNDVI – 4.83*GRNDVI <sup>2</sup>
- 18.48 + 12.66*GRVI – 1.240*GRVI <sup>2</sup>
15.07 + 0.84*WDRVI – 13.81*WDRVI <sup>2</sup>

Se determinaron tres modelos de regresión lineal múltiple (MRLM) significativos (con un nivel de significancia observado menor a 0.05) a los 147 DDS, los cuales se describen a continuación: El modelo R1) incluye a los seis IV como regresores, el modelo R2) a los IV con  $R^2$  mayor a 0.70 en la regresión lineal (GRNDVI, GRVI y GNDVI) y el modelo R3) sólo a los índices GRVI y GNDVI. Como se muestra en el Cuadro 4-4, el modelo R1 tiene un valor mayor de  $R^2$  y el modelo R3 presenta el menor RMSE de 1.47 ton ha<sup>-1</sup>.

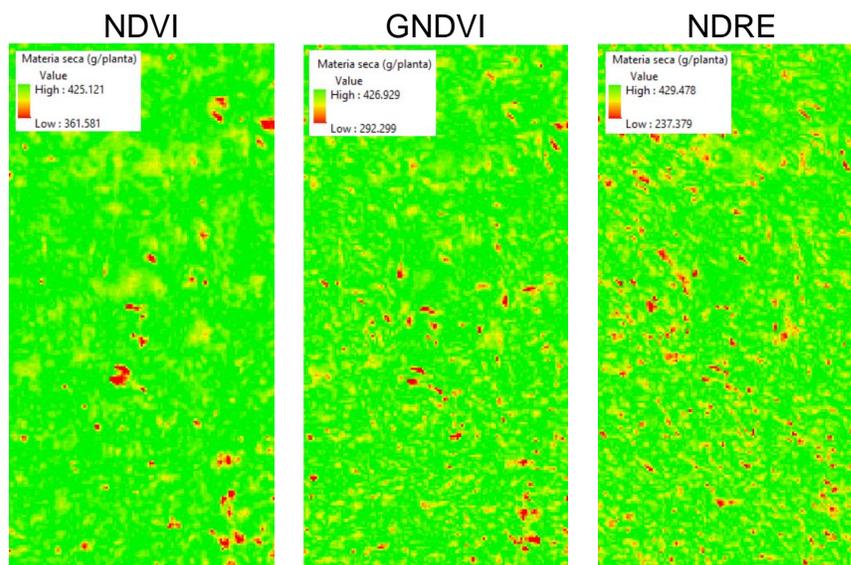
Cuadro 4-4. Estadísticas de los modelos MRLM para estimar el rendimiento final de maíz en ton ha<sup>-1</sup>.

	Modelo	S	R <sup>2</sup>	MSE
R1	$454 - 981 \cdot \text{NDVI} - 402 \cdot \text{GNDVI} + 31.6 \cdot \text{NDRE} + 1549 \cdot \text{GRNDVI} - 44.7 \cdot \text{GRVI} - 109 \cdot \text{WDRVI}$	1.72	0.76	2.96
R2	$-9.6 + 42.6 \cdot \text{GNDVI} + 3.0 \cdot \text{GRNDVI} - 1.14 \cdot \text{GRVI}$	1.53	0.74	2.34
R3	$-11.5 + 43.5 \cdot \text{GNDVI} - 0.60 \cdot \text{GRVI}$	1.47	0.74	2.15

S= Desviación Estándar Residual Estimada,  $R^2$ = Coeficiente de Determinación, MSE= Cuadrado Medio del Error.

#### 4.4.3 Mapeo de la producción de materia seca y rendimiento

Mediante la GUI desarrollada se generaron mapas de producción de materia seca por planta, en la Figura 4-5 se muestran ejemplos de los mapas obtenidos para una imagen. En total se generaron seis mapas de materia seca por planta para cada imagen procesada (uno por cada modelo de predicción para el índice de vegetación correspondiente). En total se procesaron 15 imágenes, correspondiente a las repeticiones de los tratamientos evaluados.



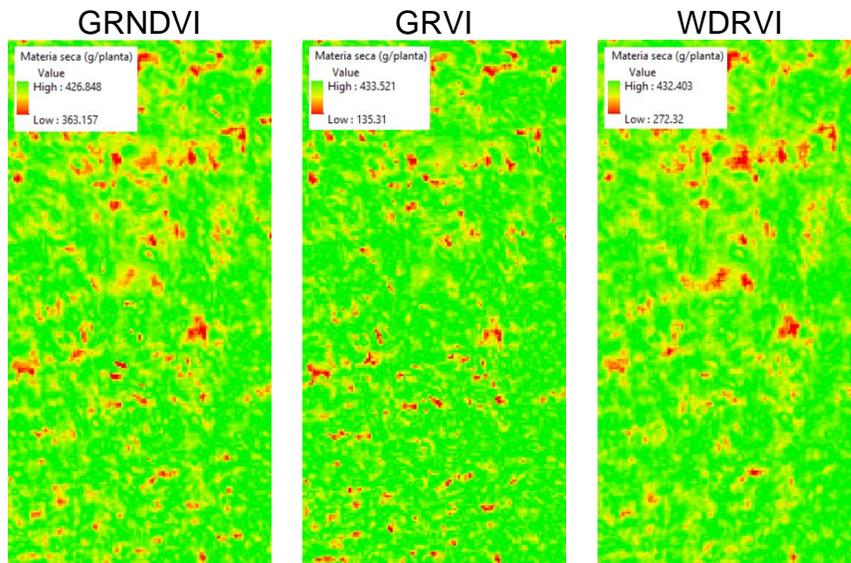
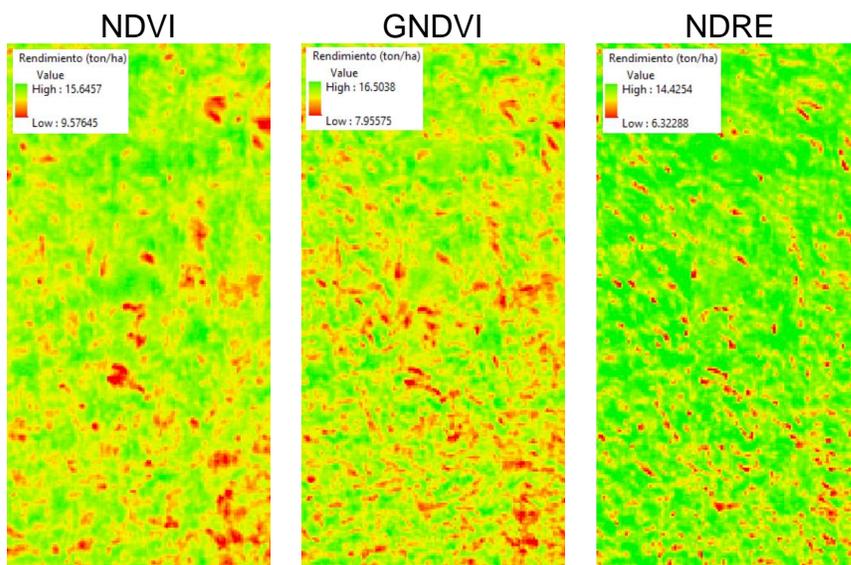


Figura 4-5. Mapas de producción materia seca por planta obtenidos mediante la GUI de Matlab.

Estos mapas se pueden procesar posteriormente en software de sistemas de información geográfica, que en combinación con muestreo en campo de la densidad de población o mediante conteo de plantas remoto, es posible determinar la producción de materia seca total.

En el caso del rendimiento del cultivo es posible obtener nueve mapas para cada imagen a procesar (uno por cada modelo de predicción), ejemplos de estos mapas se observan en la Figura 4-6.



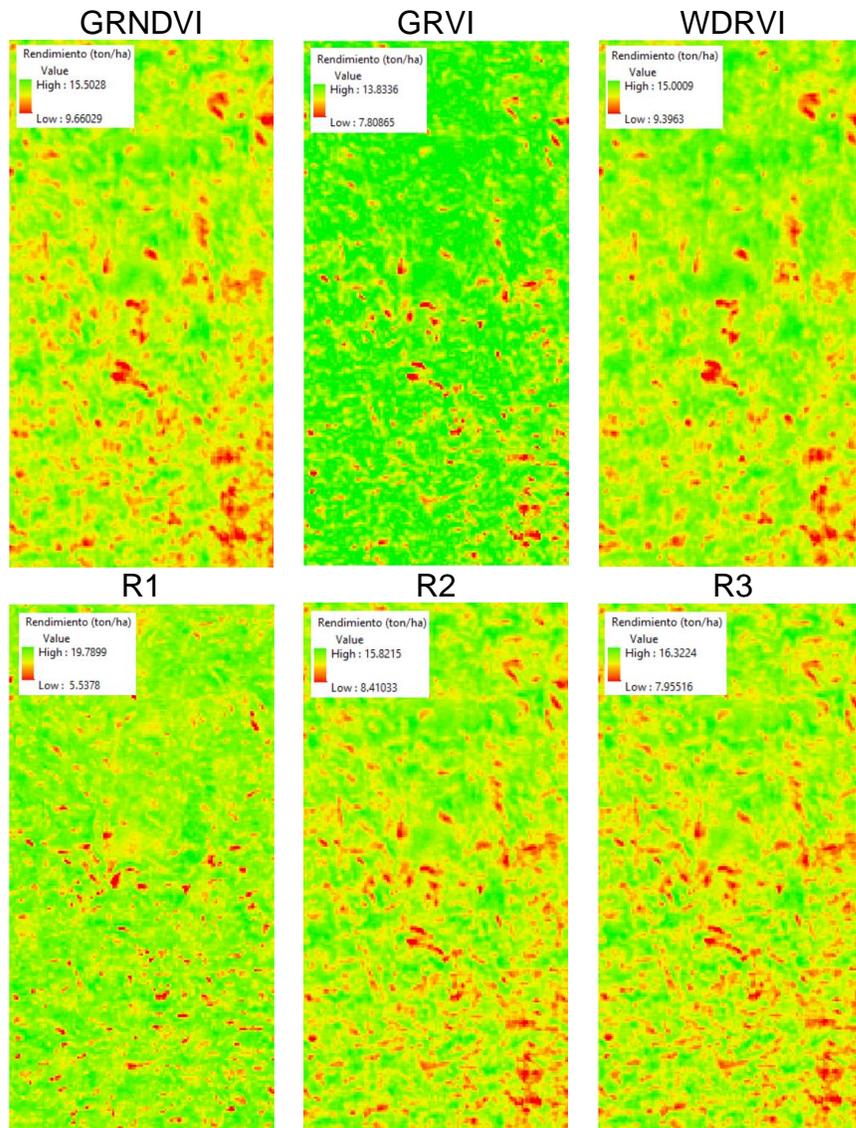


Figura 4-6. Mapas de rendimiento obtenidos mediante la GUI de Matlab.

#### 4.4.4 Mapeo del coeficiente de cultivo Kc y ETc

En la Figura 4-7 se muestran mapas ejemplo de Kc obtenidos mediante las metodologías de Cuesta et al., (2005) y Zhang et al. (2019) para una imagen procesada. Los modelos se pueden utilizar para zonificar o estimar el Kc de un área donde el riego es sectorizado, Marcial et al., (2021) define a este enfoque como “más potente” para fines de gestión de riego en comparación de un valor único.

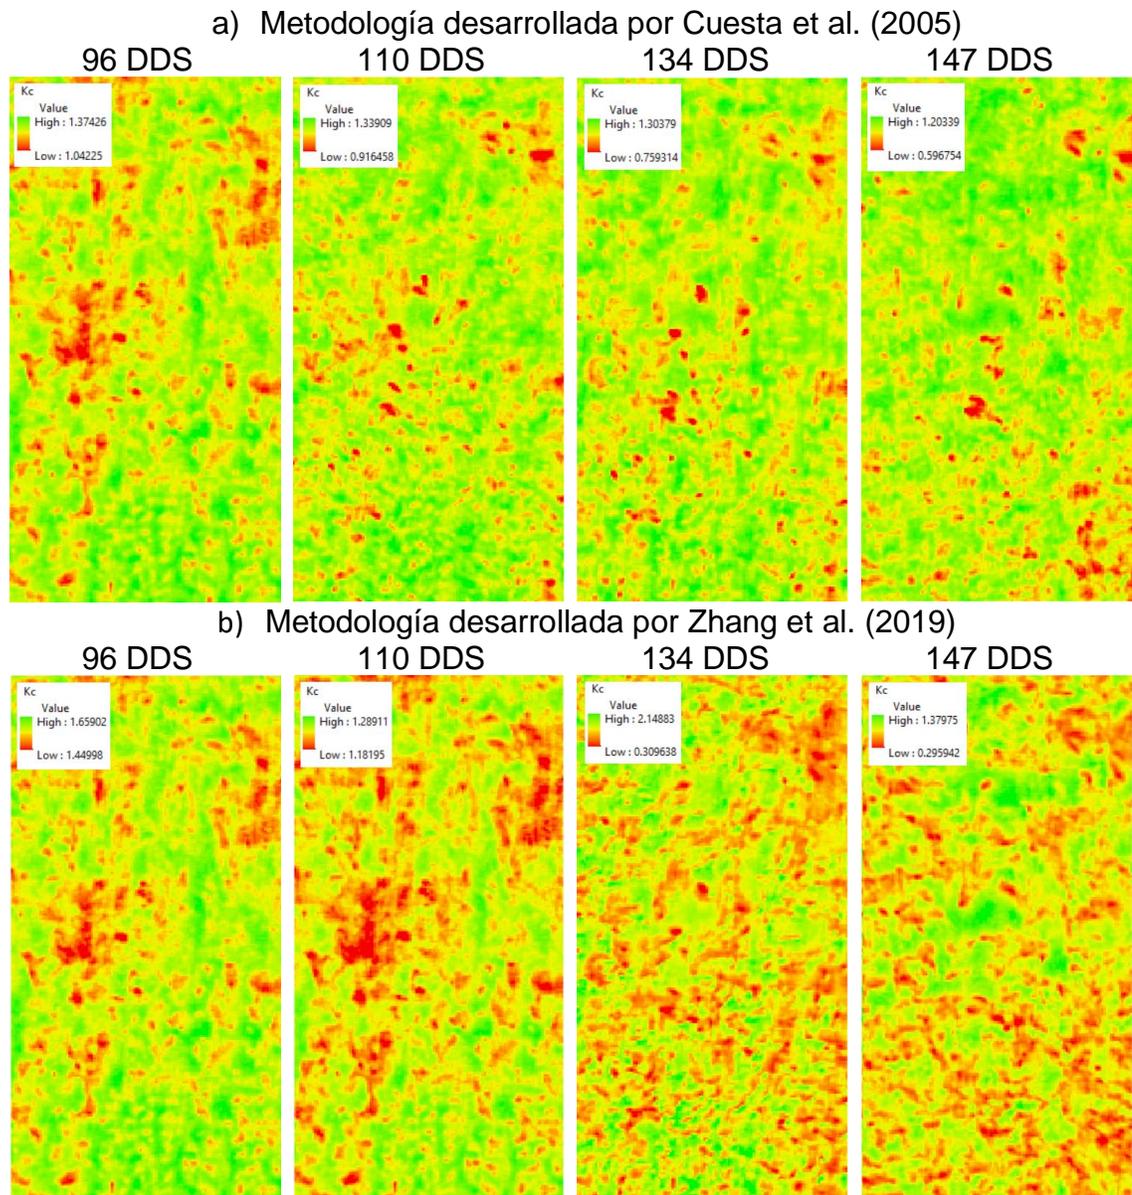


Figura 4-7. Mapas del coeficiente de cultivo  $K_{c-1}$  y  $K_{c-2}$  obtenidos mediante la GUI de Matlab.

Los coeficientes  $K_c$  del cultivo para el tratamiento de 100% de  $ET_c$  (1.2, 1.2, 1.0 y 0.8 para los 96, 110, 134 y 147 DDS, respectivamente), que se comparó con los valores medios de los mapas de  $K_c$  obtenidos mediante índices de vegetación. En ambos casos (Cuesta et al. (2005 y Zhang et al. (2019)) se obtuvo un valor de coeficiente de determinación ( $R^2$  igual a 0.95) superior a los encontrados por Zhang et al. (2019), quienes reportan un coeficiente de determinación  $R^2$  igual a 0.80 (ver Figura 4-8).

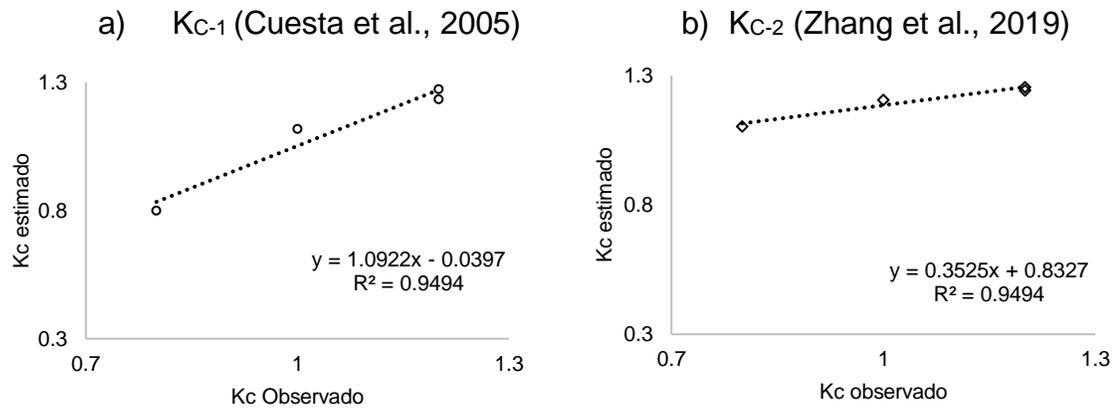


Figura 4-8. Relación entre el coeficiente de cultivo ( $K_c$ ) observado y los estimados mediante las metodologías de Cuesta et al. (2005) y Zhang et al. (2019).

Los mapas de  $K_c$  se utilizaron para estimar la evapotranspiración del cultivo ( $ET_c$ ) para las fechas en que se tenían disponibles imágenes multiespectrales. Al relacionar los valores medios de los mapas para  $ET_c$ , el coeficiente de determinación ( $R^2$ ) toma valores de 0.97 y 0.91, para  $ET_{C-1}$  y  $ET_{C-2}$  respectivamente (ver Figura 4-9). Mientras que Tang et al. (2019) obtuvieron un  $R^2$  de 0.81 al determinar la evapotranspiración del maíz a partir de índices.

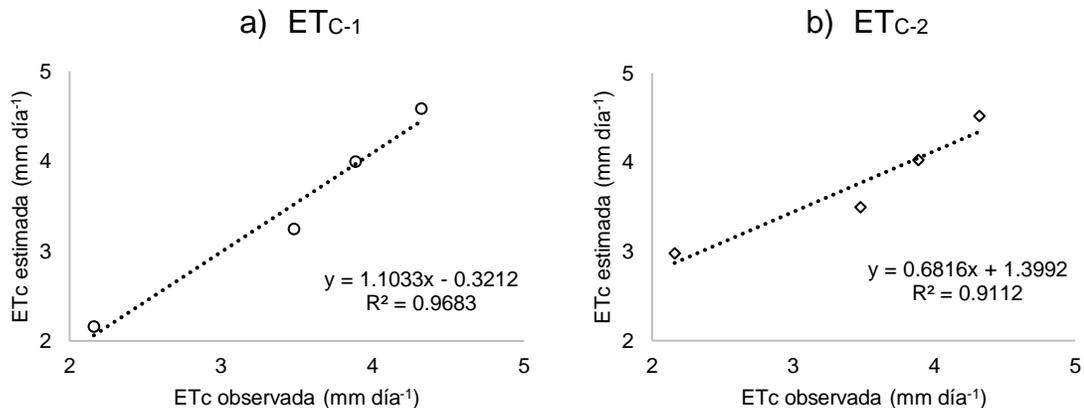


Figura 4-9. Relación entre la evapotranspiración del cultivo ( $ET_c$ ) observado y la  $ET_c$  estimada mediante  $K_{C-1}$  y  $K_{C-2}$ .

En la Figura 4-10 se muestran ejemplos de los mapas de  $ET_c$  obtenidos mediante las metodologías desarrolladas por Cuesta et al., (2005) y Zhang et al. (2019),  $ET_{C-1}$  y  $ET_{C-2}$ , respectivamente, para una imagen procesada.

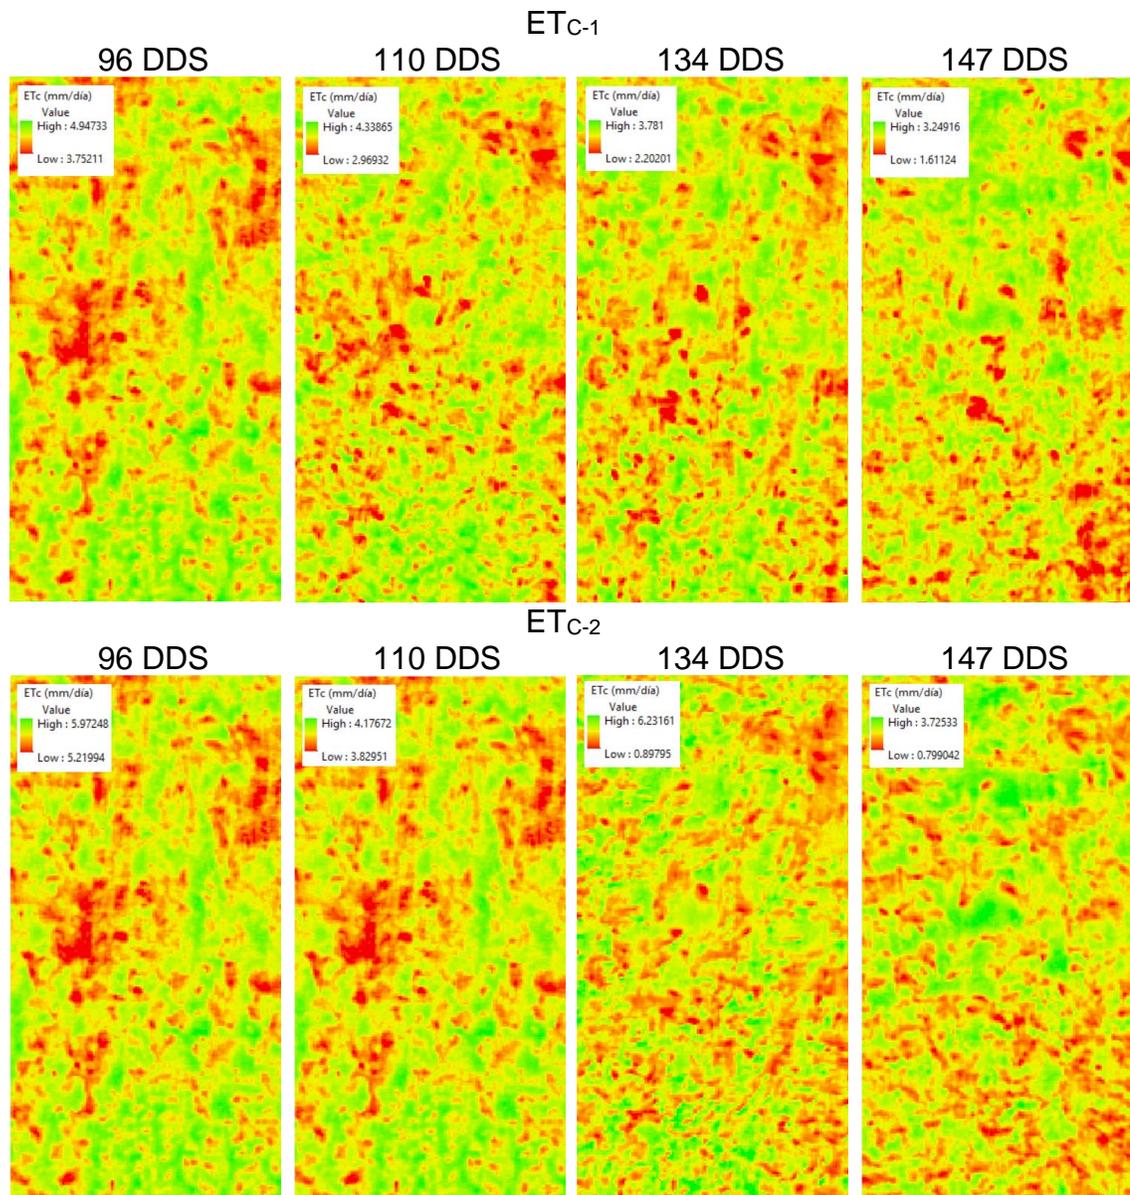


Figura 4-10. Mapas de evapotranspiración del cultivo, para ETC-1 y ETC-2 obtenidos mediante la GUI de Matlab.

Se determinaron modelos de regresión lineal entre el coeficiente de cultivo  $K_c$  para el tratamiento de 100% de ETC, de los cuales, el que se derivó a partir del índice GNDVI tuvo el mayor  $R^2$  igual a 0.98 (ecuación 11).

$$K_c_{GNDVI} = 2.5287 * GNDVI - 0.7062 \quad (11)$$

En la Figura 4-11 se muestra un ejemplo de los mapas de Kc y ETc derivados del modelo de Kc<sub>GNDVI</sub> para una imagen procesada. La ETc derivada del mapa de Kc<sub>GNDVI</sub> permitió obtener un coeficiente de determinación de 0.94.

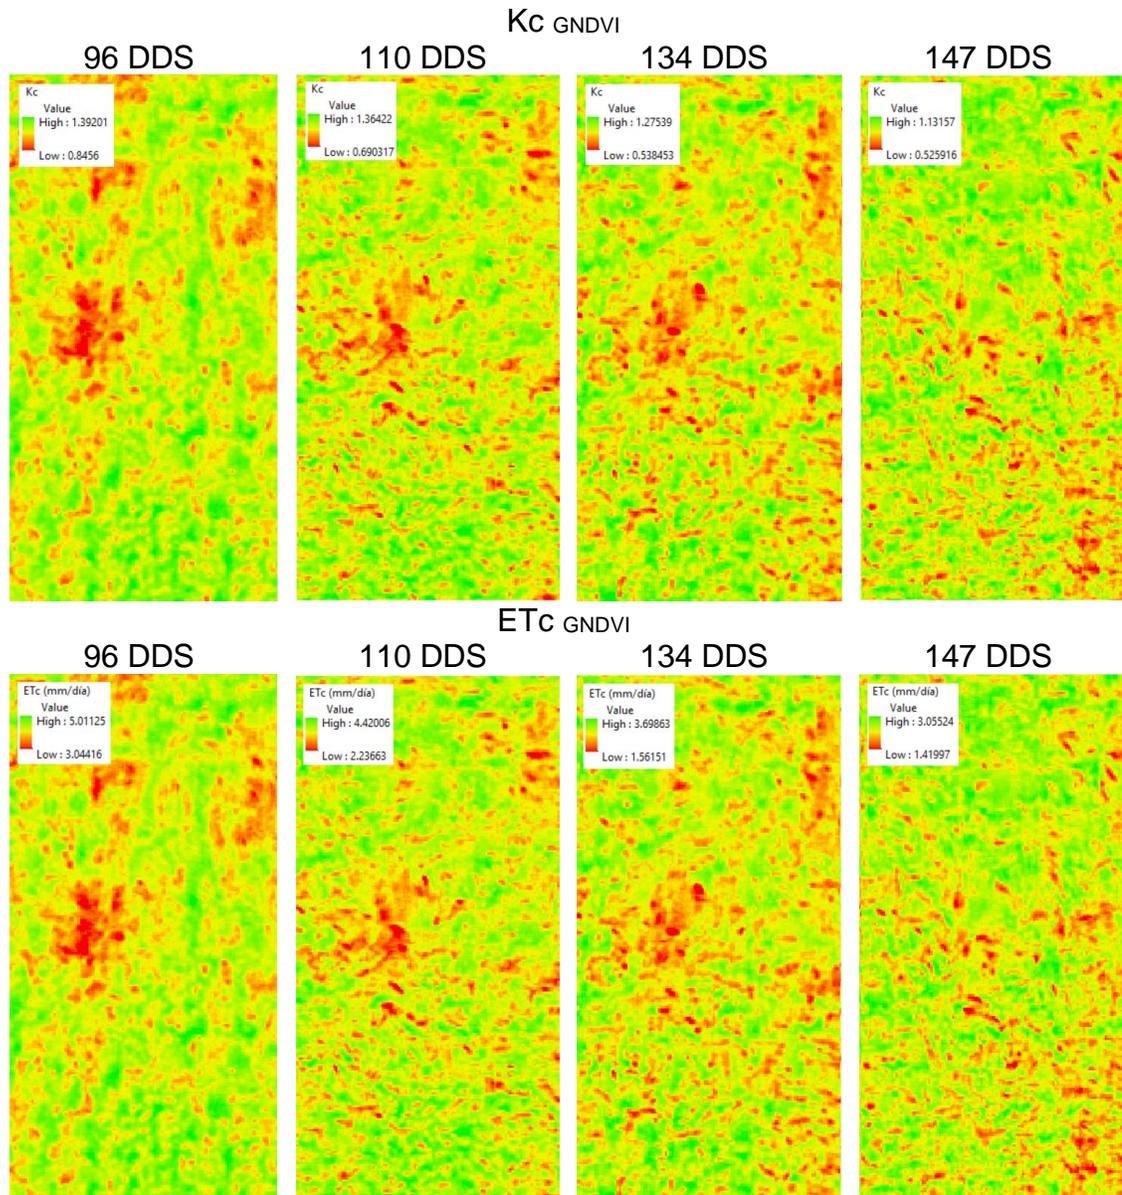


Figura 4-11. Mapas de coeficiente de cultivo y evapotranspiración del maíz derivados del modelo Kc<sub>GNDVI</sub> obtenidos mediante la GUI de Matlab.

El Kc y la ETc estimados son estadísticamente iguales a los observados, con un nivel de significancia observado de 0.583 y 0.919, respectivamente, ver Cuadro 4-5.

Cuadro 4-5. Resultados de la prueba de medias de Tukey para el Kc y ETc.

Kc		ETc	
1.20 A	K <sub>C-1</sub>	3.76	K <sub>C-1</sub>
1.11 A	K <sub>C-2</sub>	3.50	K <sub>C-2</sub>
1.05 A	Kc observado	3.46	Kc observado
1.05 A	K <sub>C GNDVI</sub>	3.32	K <sub>C GNDVI</sub>

K<sub>c</sub>= Coeficiente de cultivo, ET<sub>c</sub>= Evapotranspiración del cultivo.

#### 4.4.5 Aplicación de una red neuronal artificial para la predicción de materia seca y rendimiento.

Se creó una red neuronal artificial (RNA) de retropropagación de alimentación hacia adelante para predecir la acumulación de materia seca y el rendimiento del cultivo de maíz, respectivamente. Las redes neuronales artificiales (RNAs) obtenidas se componen de seis entradas que corresponden al NDVI, GNDVI, NDRE, GRNDVI, GRVI y WDRVI, seis neuronas y una capa oculta (6-6-1).

El método de entrenamiento de las RNAs utilizado fue el método 'trainlm' y se utilizó la función de activación 'tansig' para las neuronas, los pesos para las neuronas y la capa oculta de las RNAs para la predicción de la materia seca y rendimiento se muestran en el Cuadro 4-6.

Cuadro 4-6. Pesos implementados en las RNAs para la predicción de materia seca por planta y rendimiento.

PESOS PARA LAS NEURONAS Y LA CAPA OCULTA DE LAS RNAs						
Materia seca por planta						
Neuronas						Capa oculta
-0.2509166	-1.2500766	0.3181122	0.0710975	-0.4928237	-1.1673991	1.2643168
-0.7623349	0.3200154	-0.1334210	-0.2254077	0.7780134	0.5437283	-0.0792270
-0.1940120	0.8631730	0.9671869	0.6544671	-1.4156724	1.4771695	1.4852323
0.9049031	-0.2385889	0.8859984	0.6475486	0.8936441	-0.5017448	0.8645463
-2.2206329	0.2271866	-0.3311029	-0.4302110	0.6979357	-1.2679235	1.1726103
1.0258744	-0.2550387	1.2057601	0.7942339	0.3039096	-0.3938882	0.1976167
-0.2509166	-1.2500766	0.3181122	0.0710975	-0.4928237	-1.1673991	1.2643168
Rendimiento						
Neuronas						Capa oculta
-0.9192854	-0.0820380	0.3093428	1.0692931	-0.3407303	-1.1868366	0.4528419
-0.7187509	-0.3006855	-0.3493438	-0.1487351	1.0091353	-1.0923278	-0.5353754
-1.4071417	-1.6024435	0.8763415	-1.0310235	0.6811502	-0.9921901	-1.9606200
-0.6295258	1.6385992	1.0682239	0.5853352	0.4828019	0.2947016	-0.6487212
-0.0842501	0.1322773	-1.7566019	1.4485905	0.4161805	-1.1425407	-1.6609832
1.6408990	-0.1857885	0.8061795	0.6969131	-1.2853267	1.3604923	-1.6575632
-0.9192854	-0.0820380	0.3093428	1.0692931	-0.3407303	-1.1868366	0.4528419

Para la salida de las RANs se utilizó la función de activación 'purelin', los bias para las neuronas y la capa oculta de las RNAs para la predicción de la materia seca y rendimiento se muestran en el Cuadro 4-7.

Cuadro 4-7. Bias implementados en las RNAs para la predicción de materia seca por planta y rendimiento del cultivo de maíz.

<b>BIAS PARA LAS NEURONAS Y LA CAPA OCULTA DE LAS RNAs</b>			
<b>Materia seca por planta</b>		<b>Rendimiento</b>	
Neuronas	Capa oculta	Neuronas	Capa oculta
1.8473402	-0.8579378	2.8736353	-1.4563339
1.2350213		0.9106540	
-1.3579556		0.0245304	
-0.9037250		2.0800268	
-1.2210182		-1.5908899	
2.0368487		1.5274804	

Los pesos y bias de las redes neuronales artificiales obtenidas se implementaron en la GUI de Matlab, como una opción para predecir las variables biofísicas además de los modelos cuadráticos y de regresión lineal múltiple (sólo para rendimiento) que se indican en el apartado 4.4.2. La aplicación de las RNAs permitió obtener un coeficiente de correlación de 0.88 y 0.95 al relacionar los valores observados de materia seca y rendimiento con los simulados mediante las RNAs, similar a lo encontrado por García et al. (2020), los autores obtuvieron valores de coeficiente de correlación cercanos a uno al predecir el rendimiento de maíz mediante índices de vegetación con una RNA.

El uso de las RNAs permitió obtener un  $R^2$  de 0.77 y  $R^2$  de 0.90 para la predicción de la materia seca y el rendimiento, respectivamente, los valores de los coeficientes de determinación son superiores a los obtenidos mediante los modelos que se indican en el apartado 4.4.2. Las RNAs se implementaron en la GUI de Matlab, posibilitando el mapeo de la materia seca por planta y el rendimiento del maíz, ejemplos de estos mapas se muestran en la Figura 4-12.

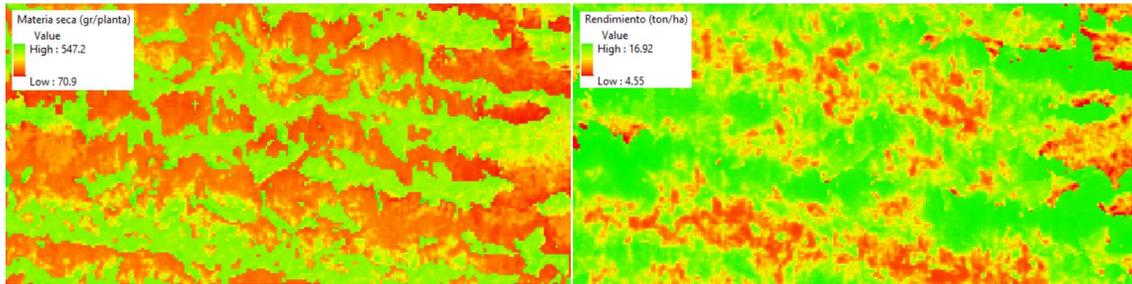


Figura 4-12. Mapas de materia seca por planta (izquierda) y de rendimiento del maíz (derecha) obtenidos mediante las RNAs implementadas en la GUI de Matlab.

#### 4.5 Conclusiones

La interfaz gráfica de usuario (GUI) en Matlab minimiza el tiempo de procesamiento de las imágenes multiespectrales, además se visualiza la reflectancia de los cultivos, valores medios de índices de vegetación y pronóstico de variables biofísicas del cultivo, etc.

Estimar los índices de vegetación (de los píxeles de la cobertura del cultivo de maíz) permite predecir la acumulación de materia seca por planta y el rendimiento del cultivo de maíz.

El uso de redes neuronales artificiales permite predecir la acumulación de materia seca por planta y el rendimiento de maíz, dado que aumentó el coeficiente de determinación en comparación con los modelos cuadráticos.

Hay una relación lineal entre el coeficiente de cultivo  $K_c$  con índices de vegetación (el índice GNDVI es el valor de entrada (predictor)) para representar en mapas la evapotranspiración del cultivo.

Las técnicas de teledetección con lenguaje de programación, para el procesamiento de imágenes multiespectrales (adquiridas mediante un VANT), permiten el monitoreo y manejo del riego del cultivo de maíz.

#### 4.6 Literatura citada

- Allen, R. G., Pereira, L. S., Raes, D. & Smith, M. (2006). Evapotranspiración del cultivo. Consultado en: [www.fao.org/publications](http://www.fao.org/publications).
- Argolo d. S., R., Chartuni M., E., Filgueiras, R., Inácio F. F., E., Barbosa d. S., A. C. & Peroni V., L. (2020). Actual Evapotranspiration and Biomass of Maize from a Red-Green-Near-Infrared (RGNIR) Sensor on Board an Unmanned Aerial Vehicle (UAV). *Water*, 12, 1-20.
- Bonnaire R. L., Montoya B., B. y Obando V., F. (2021). Procesamiento de imágenes multiespectrales captadas con drones para evaluar el índice de vegetación de diferencia normalizada en plantaciones de café variedad Castillo. *Cienc. Tecnol. Agropecuaria*, 22, 1-27.
- Cobos R., I. M. (2020). Determinación del índice de estrés hídrico a partir de imágenes satelitales (Ecuador) (Tesis de maestría, Universidad de Salzburg).
- Corti, M., Cavalli, D., Cabassi, G., Vigoni, A., Degano, L. & Marino G., P. (2019). Application of a low cost camera on a UAV to estimate maize nitrogen related variables. *Precision Agric*, 20, 675–696.
- Cuesta, A. Montoro, A., Jochum, A. M., López, P. y Calera, A. (2005). Metodología operativa para la obtención del coeficiente de cultivo desde imágenes de satélite. *ITEA*, 101, 212-224.
- Elsayed, S. & Darwish, W. (2017). Hyperspectral remote sensing to assess the water status, biomass, and yield of maize cultivars under salinity and water stress. *Bragantia*, 76, 62-72.
- Elvanidi, A., Katsoulas, N., Augoustaki, D., Loulou, I. & Kittas, C. (2018). Crop reflectance measurements for nitrogen deficiency detection in a soilless tomato crop. *Biosystems Engineering*, 176, 1-11.
- Farrell, M. y Rivas, R. (2010). Estimación de Rendimiento en Girasol a Partir de Imágenes Captadas por el Sensor MODIS-TERRA. *Ciencia*, 5, 29-43.
- García M., H., Flores M., H, Ascencio H., R., Khalil G., K., Tijerina C., L., Mancilla V., O. R. & Vázquez P., M. A. (2020). Corn Grain Yield Estimation from Vegetation Indices, Canopy Cover, Plant Density, and a Neural Network Using Multispectral and RGB Images Acquired with Unmanned Aerial Vehicles. *Agriculture*, 10, 1-24.
- Gordillo S., V. M. (2018). Evaluación del estado del nitrógeno y estimación de biomasa en el cultivo de trigo, usando sensores remotos y vehículos aéreos no tripulados (UAV). Tesis de doctorado, Colegio de posgraduados. Consultado en: <https://www.biopasos.com/biblioteca/Evaluacion-nitrogeno-biomasa-trigo-remotos-tesis.pdf>

- Jiménez B., J. A. (2009). Determinación del estado hídrico de la vegetación mediante teledetección basada en vehículos aéreos no tripulados. (Tesis doctoral, UNIVERSIDAD DE CÓRDOBA).
- León R., J., Montalvo A., N. y Paula A., P. (2016). Determinación del coeficiente del cultivo y parámetros biométricos basados en imágenes captadas con dron, lisímetros de drenaje y métodos indirectos para el cultivo de papa *solanum spp.* Rev. del Instituto de Investigación (RIIGEO), FIGMMG-UNMSM, 19, 177-188.
- Marcial P., M. de J., Ontiveros C., R. E., Jiménez J., S. I. & Ojeda B., W. (2021). Coefficient Estimation Based on Spectral Vegetation Indices and Vegetation Cover Fraction Derived from UAV-Based Multispectral Images. *Agronomy*, 11, 1-19.
- Maresma, A., Ariza, M., Martínez, E., Lloveras, J. & Martínez C., J. A. (2016). Analysis of Vegetation Indices to Determine Nitrogen Application and Yield Prediction in Maize (*Zea mays L.*) from a Standard UAV Service. *Remote Sens*, 8, 1-15.
- Martínez B., R. A., Aguirre C., O. A., Benedicto V., L., Jiménez P., J., Treviño G., E. J. y Yerena Y., J. I. (2016). Modelación de biomasa y carbono arbóreo aéreo en bosques del estado de Durango. *Revista Mexicana de Ciencias Forestales*, 7, 91-105.
- Mousabeygi, F., Rezaei, Y. & Akhavan, S. (2020). Assessment of maize water status using a consumer-grade camera and thermal imagery. *Water Supply*, 1-10.
- Padilla, F. M., Gallardo, M., Peña F., M. T., De Souza, R. & Thompson, R. B. (2018). Proximal Optical Sensors for Nitrogen Management of Vegetable Crops: A Review. *Sensors*, 18, 1-23.
- Paula A., P., León R., J. y Paula A., P. (2017). Variables biofísicas (NDVI, fPAR, IAF, Fc, kc) obtenidas del procesamiento de imágenes multi-espectrales captadas con cámara Canon SX260HS para el cultivo de papa *Solanum spp.* *Revista Caribeña de Ciencias Sociales*, 1-16.
- Pérez C., P. y Alarcón C., J. J. (2014). Empleo de técnicas de teledetección de muy alta resolución espacial para el análisis del comportamiento de las variables fenológicas en cultivos (*prunus pérsica*) con riego deficitario controlado. *Papeles de Geografía*, 59-60, 113-124.
- Quito, N., Tacuri, E., López, M. y Lupercio, L. (2020). Detección de estrés hídrico en brócoli (*brassica oleracea var. itálica*), utilizando ndvi sobre imágenes multiespectrales capturadas a corta distancia. *JOURNAL OF SCIENCE AND RESEARCH*, 5, 41-59.
- Reyes G., A., Reta S., D. G., Sánchez D., J. I., Ochoa M., E., Rodríguez H., K y Preciado R., P. (2019). Estimación de la evapotranspiración de maíz forrajero apoyada con sensores remotos y mediciones in situ. *Terra Latinoamericana*, 37, 279-290.

- Software estadístico Minitab 19. (2019). [Software de ordenador]. State College, PA: Minitab, Inc. Consultado en: <https://www.minitab.com/es-mx/support/>
- Soria R., J., Fernández O., Y. & Granados R., R. (2004). Methodology for prediction of corn yield using remote sensing satellite data in Central Mexico. *Investigaciones geográficas*, 55, 61-78.
- Tagarakis, A. C. & Ketterings, Q. M. (2018). Proximal sensor-based algorithm for variable rate nitrogen application in maize in northeast U.S.A. *Computers and Electronics in Agriculture*, 145, 373-378.
- Tang, J., Han, W., & Zhang, L. (2019). UAV Multispectral Imagery Combined with the FAO-56 Dual Approach for Maize Evapotranspiration Mapping in the North China Plain. *Remote Sens*, 11, 1-22.
- Zhang, Y., Han, W., Niu, X. & Li, G. (2019). Maize Crop Coefficient Estimated from UAV-Measured Multispectral Vegetation Indices. *Sensors*, 19, 1-17.

## **5 CONCLUSIONES GENERALES**

Se identificó el estrés hídrico en la etapa reproductiva en cultivo de maíz mediante índices de vegetación calculados a partir del procesamiento de imágenes multiespectrales obtenidas con un vehículo aéreo no tripulado (VANT).

El sensor Parrot Sequoia acoplado a un VANT permitió obtener imágenes multiespectrales de alta resolución espacial (de 4 x 4 cm de pixel) de la cobertura del cultivo de maíz y obtener valores de índices de vegetación acordes a los reportados en la literatura.

La interfaz gráfica de usuario (GUI) de Matlab, facilitó automatizar el procesamiento de las imágenes multiespectrales, así como también, se visualizan procesos y resultados valores de índices de vegetación, índice de estrés hídrico del cultivo, la predicción de la materia seca y el rendimiento del cultivo de maíz.

Se puede predecir la producción de materia seca por planta y el rendimiento del maíz mediante modelos cuadráticos significativos y redes neuronales artificiales a partir de índices de vegetación como valores de entrada. Y representarlas en mapas temáticos, así como también, el coeficiente de cultivo  $K_c$  y la evapotranspiración del cultivo (ET<sub>c</sub>).

Mapear variables del cultivo permite el manejo adecuado del cultivo de maíz y del riego. Monitorear el estado hídrico del cultivo mediante imágenes multiespectrales de alta resolución permitiría definir estrategias de riego en zonas específicas con la finalidad de aumentar la productividad del cultivo para alcanzar el rendimiento esperado al aplicar una lámina de riego del 100% de la ET<sub>c</sub>.