



UNIVERSIDAD AUTÓNOMA CHAPINGO

**POSGRADO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA**

**DETERMINACIÓN DEL ESTADO HÍDRICO DEL MAÍZ MEDIANTE
MODELOS DE APRENDIZAJE AUTOMÁTICO Y SUPER
RESOLUCIÓN EN IMÁGENES TÉRMICAS**

TESIS

Que como requisito parcial para obtener el grado de:

**DOCTOR EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA**

Presenta:

PÉREZ PAREDES JUAN JOSÉ.

Bajo la supervisión de:

DR. GILBERTO DE JESÚS LÓPEZ CANTENES



APROBADA



Chapingo, Estado de México, diciembre del 2025

DETERMINACIÓN DEL ESTADO HÍDRICO DEL MAÍZ MEDIANTE MODELOS
DE APRENDIZAJE AUTOMÁTICO Y SUPER RESOLUCIÓN EN IMÁGENES
TÉRMICAS

Tesis realizada por **MI. JUAN JOSÉ PÉREZ PAREDES** 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. Gilberto de Jesús López Canteñs

ASESOR: 
Dr. Ramón Arteaga Ramírez

ASESOR: 
Dr. Juan Carlos Olguín Rojas

ASESOR: 
Dr. Eugenio Romantchik Kriuchkova

LECTOR EXTERNO: 
Dr. Ronald Ernesto Ontiveros Capurata

AGRADECIMIENTOS

A la Universidad Autónoma Chapingo, por toda la formación recibida.

Al programa de Posgrado de Ingeniería Agrícola y Uso Integral del Agua de la Universidad Autónoma Chapingo, por concederme la formación y los medios posibles para mis estudios de posgrado.

Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por brindarme los medios posibles para la realización del doctorado, esperando retribuir a mi país el bien recibido

A los integrantes de mi comité asesor: Dr. Gilberto de Jesús López Canteñas, Dr. Ramón Arteaga Ramírez, Dr. Juan Carlos Olguín Rojas, Dr Eugenio Romantchik Kriuchkova y Dr Ronald Ernesto Ontiveros Capurata.

DATOS BIOGRÁFICOS



Nombre: Pérez Paredes Juan José.
Fecha de nacimiento: 6 de enero de 1994
Lugar de Nacimiento: Santa María Atzompa, Oaxaca.
Profesión: Ingeniero Mecánico Agrícola
Cedula profesional: 11177255

Desarrollo Académico:

Preparatoria: Universidad Autónoma Chapingo
Licenciatura: Departamento de Ingeniería Mecánica Agrícola, Universidad Autónoma Chapingo.
Maestría: Posgrado de Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo.
Doctorado: Posgrado de Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo.

CONTENIDO

AGRADECIMIENTOS.....	iii
DATOS BIOGRÁFICOS.....	iv
CONTENIDO	v
ÍNDICE DE FIGURAS.....	x
ÍNDICE DE CUADROS.....	xii
RESUMEN GENERAL.....	xiii
GENERAL ABSTRACT.....	xiv
1. INTRODUCCIÓN GENERAL.....	15
1.1 Introducción.....	15
1.2 Objetivos.....	19
1.2.1 Objetivo general	19
1.2.2 Objetivos específicos.....	19
2. REVISIÓN DE LITERATURA	20
2.1 Agricultura climáticamente inteligente	20
2.2 Riego en la agricultura.....	27
2.3 Estrés hídrico en cultivos agrícolas	28
2.4 Daños ocasionados por estrés hídrico.....	29
2.5 Determinación del estado hídrico de cultivos y contenido de agua en el suelo	33
2.6 Índices de estrés hídrico utilizando temperatura del cultivo.....	36
2.6.1 Índice de estrés hídrico de cultivos.....	37

2.6.2	Índice de conductancia estomática relativa	40
2.6.3	Grados por encima del umbral no estresado y grados por encima del umbral del dosel.....	41
2.6.4	Temperatura relativa normalizada del dosel.....	42
2.6.5	Velocidad relativa de la temperatura del dosel.....	43
2.6.6	Índice sombreado de luz solar normalizado	44
2.6.7	Índice de sequedad de temperatura-vegetación	46
2.7	Drones en el monitoreo agrícola para determinación del riego	47
2.8	Cámaras térmicas.....	52
2.8.1	Cámaras térmicas de microbolómetro.....	54
2.8.2	Cámaras térmicas de estado sólido enfriado.	56
2.9	Super resolución y pansharpening en imágenes térmicas	58
2.10	Modelos de aprendizaje automático para determinar el estado hídrico con imágenes térmicas	60
2.11	Bibliografía.....	67
3.	DESARROLLO DE CÁMARA TÉRMICA PARA RPAS UTILIZADA EN EL MONITOREO DEL ESTADO HÍDRICO DE CULTIVOS	77
3.1	Resumen.	77
3.2	Abstract.	78
3.3	Introducción.	79
3.4	Materiales y métodos.....	82
3.4.1	Sensor infrarrojo térmico IR MLX90640	83
3.4.2	Conexiones y diagrama electrónico.....	84

3.4.3	Programación	86
3.4.4	Montaje en el Sistema de Aeronave Pilotada a Distancia (RPAS) y configuración de captura.....	89
3.4.5	Evaluación de la Cámara térmica.....	89
3.4.6	Generación de imágenes térmicas y segmentación de la temperatura del dosel	92
3.5	Resultados y discusión	94
3.5.1	Caracterización de la cámara térmica desarrollada.....	94
3.5.2	Imágenes térmicas.	96
3.6	Conclusiones	97
3.7	Referencias	98
4.	MEJORAMIENTO DE IMÁGENES TÉRMICAS MEDIANTE SUPER RESOLUCIÓN E IMÁGENES RGB	102
4.1	Resumen.	102
4.2	Abstract.	103
4.3	Introducción.	105
4.4	Materiales y métodos.....	108
4.4.1	Adquisición de imágenes térmicas y RGB.....	108
4.4.2	Procesamiento y mejoramiento de imágenes térmicas mediante interpolación bicúbica	110
4.4.3	Fusión de imágenes térmicas y RGB	113
4.4.4	Procesamiento de imágenes para super resolución.....	119
4.4.5	Modelos de super resolución.....	120

4.4.6	Método 1: Procesamiento y Fusión de Imágenes Térmicas y RGB mediante Filtrado Guiado (FG)	121
4.4.7	Método 2: Realce mediante filtrado bilateral conjunto (JBU).....	122
4.4.8	Método 3 Mejoramiento por superresolución guiada (JBR).....	123
4.4.9	Evaluación de desempeño	124
4.5	Resultados y discusión	125
4.6	Conclusiones	128
4.7	Referencias	128
5.	DETERMINACIÓN DEL ESTADO HÍDRICO DEL MAÍZ MEDIANTE MODELOS DE APRENDIZAJE AUTOMÁTICO E IMÁGENES TÉRMICAS MEJORADAS MEDIANTE SUPER-RESOLUCIÓN	132
5.1	Resumen.	132
5.2	Abstract.	133
5.3	Introducción.....	134
5.4	Materiales y métodos.....	137
5.4.1	Adquisición de imágenes térmicas y RGB:.....	137
5.4.2	Medición de fisiológica del cultivo.....	138
5.4.3	Medición de humedad del suelo	139
5.4.4	Determinación del Estrés Hídrico del Cultivo mediante el Método FAO	143
5.4.5	Entrenamiento de modelos de aprendizaje automático	145
5.5	Resultados y discusión	148

5.5.1	Determinación del estrés hídrico mediante modelos de clasificación	151
5.5.2	Determinación del estado hídrico mediante modelos de regresión	155
5.6	Conclusiones	158
5.7	Referencias	159
Apéndice A		163
Abreviaturas utilizadas		163

ÍNDICE DE FIGURAS

Figura 1. Circuito integrado MBA-on-CMOS, Fuente: Bardalen et al. (2024)...	55
Figura 2. Unidad periódica de la estructura MIMIM, Fuente: Li et al. (2024)....	56
Figura 3. Sensor sólido enfriado (FLIR), Fuente: Li et al. (2024)	57
Figura 4. Efecto fotoeléctrico, Fuente: Li et al. (2024).....	57
Figura 5. Representación de la cámara térmica.....	82
Figura 6. Esquema de conexión.....	85
Figura 7. Ensamblado y conexión de los componentes: (a) ensamblado, (b) vista inferior, (c) vista superior.	85
Figura 8. Diagrama de funcionamiento de la cámara térmica.	88
Figura 9. Vista superior (a), inferior (b), de la cámara montada en el RPAS. ..	89
Figura 10. Zona de estudio de vuelos fotogramétricos con el RPAS.	90
Figura 11. Configuración de vuelo en QGroundControl.	91
Figura 12. Cámara tipo pinza.	92
Figura 13. a) Imagen RGB, b) Imagen térmica en falso color y c) Imagen térmica interpolada en falso color.....	93
Figura 14. Imagen térmica fusionada en falso color.....	94
Figura 15. Temperaturas obtenidas con las imágenes térmicas y con el porómetro Licor LI-600.....	97
Figura 16. Zona de estudio de vuelos fotogramétricos con el RPAS.	108
Figura 17. Vista superior (a), inferior (b), de la cámara térmica montada.	109
Figura 18. a) Imagen RGB (640 x 480), b) Espacio de color YCrCb.....	114
Figura 19. a) Canal Cr del espacio de color YCrCb, b) Histograma del canal Y	115
Figura 20. Imagen binaria filtrada obtenida del canal Cr y método de Otsu...	115
Figura 21. a). Imagen térmica final (falso color), b) Histograma de la temperatura de la imagen térmica final.	118

Figura 22. Zona de estudio de vuelos fotogramétricos con el RPAS.	137
Figura 23. Vista superior (a), inferior (b), de la cámara montada en el RPAS.	138
Figura 24. a) porómetro de estado estacionario LI-COR LI-1600, b) Cámara tipo pinza	139
Figura 25. a) Sensores Watermark 200SS, b) Datalogger implementado con paneles solares, c) Sensores colocados a 20 y 40 cm de profundidad.	140
Figura 26. Curvas de retención de humedad a 20 y 40 cm de profundidad... ..	142
Figura 27. Temperatura promedio del dosel y contenido de humedad del suelo	148
Figura 28. Transpiración vs Conductancia estomática, obtenida con el porómetro licor li-1600.....	149
Figura 29. Transpiración vs radiación solar, obtenida con el porómetro licor li-1600	150
Figura 30. Transpiración vs Humedad relativa obtenida con el porómetro licor li-1600.....	151
Figura 31. Matriz de contingencia del estrés calculado (ks) vs Agrupamiento K-medias, a) 20 cm y b) 40cm.....	152
Figura 32. Agrupamientos para K-means generado (a: 20 cm, c: 40 cm); Agrupamientos reales por estrés con base en el déficit hídrico (Ks) (b: 20 cm, d: 40 cm).....	153
Figura 33. Curvas de pérdida y precisión de los modelos: a) RF, b) XGB, c) SVM y d) RL.	155
Figura 34. Curvas de pérdida y precisión de los modelos: a) RF, b) XGB, c) SVM y d) RL.	158

ÍNDICE DE CUADROS

Cuadro 1. Prácticas de Agricultura Climáticamente Inteligente (ACI).	24
Cuadro 2. Clasificación de las metodologías de monitoreo del estado hídrico. 34	
Cuadro 3. Tipos de RPAS y características.	49
Cuadro 4. Trabajos de determinación de estrés hídrico utilizando modelos de aprendizaje.	63
Cuadro 5. Especificaciones del porómetro LI-COR LI-1600 para la medición de temperatura de las hojas.	91
Cuadro 6. Resolución de la cámara térmica desarrollada.....	95
Cuadro 7. Aumento de resolución con los métodos de interpolación.....	112
Cuadro 8. Imágenes térmicas originales e interpoladas.	112
Cuadro 9. Fusión de superficies: dosel y suelo.....	117
Cuadro 10. Fusión de imágenes térmicas y RGB	118
Cuadro 11. Modelos utilizados para el mejoramiento de imágenes	120
Cuadro 12. Métricas de evaluación.....	124
Cuadro 13. imágenes mejoras mediante FG, JBU y JBR e histogramas.....	125
Cuadro 14. Métricas de desempeño de los 3 modelos y de la fusión RGB-térmica.	127
Cuadro 15. Especificaciones principales del LI-COR LI-1600.....	139
Cuadro 16. Características físicas del suelo.	142
Cuadro 17. Métricas de desempeño para: agotamiento de humedad % (Ag) y déficit de agua (Dr) a 40 Y 20 cm.	156

RESUMEN GENERAL

DETERMINACIÓN DEL ESTADO HÍDRICO DEL MAÍZ MEDIANTE MODELOS DE APRENDIZAJE AUTOMÁTICO Y SUPER RESOLUCIÓN EN IMÁGENES TÉRMICAS

La medición de la temperatura del dosel mediante imágenes térmicas infrarrojas es una herramienta confiable para estimar el estrés hídrico, su uso se ve limitado por el alto costo y baja resolución de los sensores. En este estudio, se desarrolló una cámara térmica basada en el sensor MLX90640 (32×24 píxeles) y el microcontrolador Teensy 3.6, con tarjeta microSD, instalada a un RPAS y evaluada sobre un cultivo de maíz (*Zea mays L.*), comparando sus mediciones con un porómetro LI-COR LI-1600 (± 0.5 °C). Las imágenes se mejoraron mediante interpolación bicúbica y se fusionaron con imágenes RGB para obtener una resolución de 640×480 píxeles, mostrando una variación de temperatura promedio de $\Delta T = 0.57$ °C respecto al sensor de referencia. Posteriormente, se aplicaron técnicas de superresolución guiada, integrando la información radiométrica térmica con el detalle estructural de las imágenes RGB. Las imágenes se redimensionaron, se segmentó el dosel en el espacio de color YCrCb mediante el canal Cr y el umbral de Otsu, generando una máscara binaria del follaje. La fusión con el canal Y se realizó mediante alineamiento por Correlación Mejorada, implementando tres modelos de fusión: Refinamiento Bilateral Conjunto (JBR), Aumento de Resolución Bilateral Conjunto y Filtrado Guiado, siendo JBR el más robusto al preservar la fidelidad radiométrica y coherencia estructural. Con las imágenes mejoradas, se implementaron modelos de aprendizaje automático para predecir el estado hídrico, utilizando radiación solar, humedad relativa, temperatura del dosel y mediciones de humedad del suelo a 20 y 40 cm de profundidad. Los modelos de regresión evaluados fueron: Bosque Aleatorio (RF), Potenciación del Gradiente Extrema (XGB), Máquina de Soporte Vectorial, Redes Neuronales Artificiales y Regresión Multivariada Lineal. El modelo que mejores resultados obtuvo en la estimación del estrés hídrico fue RF con $R^2 = 0.97$, MAE = 0.37; RMSE = 1.18 y XGB con $R^2 = 0.96$, MAE = 1.51; RMSE = 0.31, por lo que la integración de los RPAS con sensores térmicos y el análisis inteligente de datos puede ser una opción viable para caracterizar la variabilidad del estado hídrico del maíz.

Palabras clave: Imágenes térmicas; Superresolución; Estrés hídrico; Aprendizaje automático; Agricultura climáticamente inteligente.

GENERAL ABSTRACT

DETERMINATION OF MAIZE WATER STATUS USING MACHINE LEARNING MODELS AND SUPER-RESOLUTION THERMAL IMAGING

Measuring canopy temperature through infrared thermal imaging is a reliable tool for estimating water stress; however, its use is limited by the high cost and low resolution of the sensors. In this study, a thermal camera was developed using an MLX90640 sensor (32 × 24 pixels) and a Teensy 3.6 microcontroller with a microSD card. The system was mounted on an RPAS and evaluated over a maize (*Zea mays L.*) crop, comparing its measurements with those obtained from a LI-COR LI-1600 porometer (± 0.5 °C). The thermal images were enhanced using bicubic interpolation and fused with RGB images to obtain a resolution of 640 × 480 pixels, showing an average temperature variation of $\Delta T = 0.57$ °C with respect to the reference sensor. Subsequently, guided super-resolution techniques were applied, to integrate the thermal radiometric information with the structural details of the RGB images. The images were resized, the canopy was segmented in the YCrCb color space using the Cr channel and the Otsu threshold, generating a binary foliage mask. The fusion with the Y channel was performed using Enhanced Correlation alignment, implementing three fusion models: Joint Bilateral Refinement (JBR), Joint Bilateral Resolution Enhancement, and Guided Filtering, with JBR being the most robust in preserving radiometric fidelity and structural coherence. With the enhanced images, machine learning models were implemented to predict water status, using solar radiation, relative humidity, canopy temperature, and soil moisture measurements at depths of 20 and 40 cm. The regression models evaluated were: Random Forest (RF), Extreme Gradient Boosting (XGB), Support Vector Machine, Artificial Neural Network, and Multiple Linear Regression. The model that achieved the best performance in estimating water stress were RF with $R^2 = 0.97$, MAE = 0.37; RMSE = 1.18 and XGB with $R^2 = 0.96$, MAE = 1.51; RMSE = 0.31. These results suggest that integrating RPAS with thermal sensors and intelligent data analysis can be a viable approach to characterize the spatial variability of maize water status.

Keywords: Thermal imaging; Super-resolution; Water stress; Machine learning; Climate-smart agriculture.

1. INTRODUCCIÓN GENERAL

1.1 Introducción

Se estima que la población mundial alcance los 9 mil millones de personas para 2050 significa que la producción de alimentos debería aumentar en un 70 %, con una demanda de agua estimada del 40 % para 2030, (Chen et al., 2023;M. Wang et al., 2024). El reto de aumentar la sostenibilidad y la eficiencia en el uso de los recursos en los sistemas agrícolas se produce en un escenario complejo, marcado por la creciente demanda de alimentos, mayores estándares de mercado y una alta incertidumbre sobre el agua de riego disponible (Berríos et al., 2024; Ouma et al., 2024).

La demanda de agua dulce va en aumento debido al rápido crecimiento de la población mundial, además el calentamiento global y el cambio climático provocan una grave amenaza para el uso del agua, la seguridad alimentaria y el desarrollo sostenible (Abioye et al., 2022; Aziz et al., 2022). La gestión de los recursos hídricos es fundamental para las operaciones sostenibles, particularmente en la agricultura, debido a que representa alrededor del 70 % de la explotación mundial de agua dulce, utilizada para regar el 25 % de las tierras de cultivo del mundo (Bwambale et al., 2022; Brar et al., 2022; Zhou et al., 2021).

El agua utilizada en el riego representa el principal consumidor de recursos hídricos y su gestión es muy importante. En la agricultura, la escasez de agua se convierte en un gran problema debido a que los recursos hídricos son limitados, el agua en el riego no puede reducirse sin poner en riesgo los rendimientos de producción. La tierra en la que se cultivan los alimentos es limitada, lo que significa que los sistemas de cultivos agrícolas deben utilizar los recursos de agua y tierra disponibles de manera eficiente para alimentar a la población(Jiménez et al., 2022).

Es fundamental comprender los mecanismos, estrategias y metodologías que pueden mejorar la eficiencia y sostenibilidad en el uso del agua, para prevenir las crisis de escasez futuras, aumentar la producción de alimento y dar como

resultado un ahorro significativo de agua y un mayor rendimiento (Bwambale et al., 2022; Abioye et al., 2022).

El riego de precisión permite obtener una eficiencia óptima en el uso del agua de riego y minimizar los impactos ambientales. El riego de precisión implica el conocimiento sobre los sistemas de riego, la variación espacial y temporal del suelo, las variables climáticas cambiantes, la fenología de los cultivos y sus necesidades, para tomar mejores decisiones, con el potencial de contribuir a lograr un alto ahorro de agua y un mejor rendimiento (Jiménez et al., 2022).

La eficiencia del riego podría mejorar mediante la adopción de la programación científica del riego, el proceso de investigar la cantidad, la ubicación y el momento óptimo de la aplicación de agua para lograr el rendimiento y la calidad de los cultivos requeridos, al disminuir los posibles efectos adversos sobre el medio ambiente, como la lixiviación de nutrientes por debajo de la zona de las raíces de las plantas y maximizar la conservación del agua (Aziz et al., 2022).

Existen formas para mejorar la eficiencia en el uso del agua a través de sistemas de riego inteligentes, con la implementación de tecnologías de comunicación inalámbrica, sistemas de monitoreo y estrategias de control avanzadas para una programación óptima de riego (Bwambale et al., 2022).

Las tecnologías digitales como sensores remotos (IOT) /virtuales e inteligencia artificial permiten una gestión eficiente y sostenible de cultivos, con respecto a la utilización de recursos hídricos (Brar et al., 2022). El Internet de las cosas , se está aprovechando para la implementación de planes operativos y/o estrategias de control avanzadas, logrando un mejor seguimiento y control en la agricultura, ajustan la distribución y el mejor control en los distritos de riego, reduciendo la mano de obra (Jiménez et al., 2022; Abioye et al., 2022).

Algunos métodos para monitorear el estrés hídrico de los cultivos se basan en la medición de la humedad del suelo, la tasa fotosintética y las características del cultivo (altura del cultivo y el índice de área foliar), sin embargo, las medidas tradicionales requieren mucho tiempo y mano de obra, son laboriosos y en

algunos casos son destructivos para las plantas. Debido a que estas mediciones a menudo se limitan a una pequeña porción del campo, los resultados pueden no ser representativos de las necesidades reales de agua de los cultivos o de las condiciones generales de humedad (Noguera et al., 2020).

La temperatura del dosel se ha reconocido desde hace mucho tiempo como un indicador del estado hídrico de las plantas. La temperatura es una de las variables ambientales más importantes que afectan los procesos fisiológicos de las plantas, incluida la transpiración, el potencial hídrico de las hojas y la tasa fotosintética (Gheysari et al., 2021) .

Con un suministro de agua adecuado, puede aumentar la conductancia de los estomas y mejorar el enfriamiento por evaporación de las hojas que transpiran (Gheysari et al., 2021). Sin embargo, con estrés hídrico se reduce la conductancia estomática de la hoja y la tasa de transpiración y en consecuencia, aumenta la temperatura de la hoja (dosel). Estos cambios sutiles en la temperatura del dosel, se pueden medir con una cámara infrarroja térmica, que genera una imagen de temperatura utilizando la radiación de onda larga emitida (Noguera et al., 2020).

Los métodos de teledetección se han consolidado como herramientas clave, al posibilitar la identificación de la variabilidad del estrés hídrico en escalas espaciales y temporales amplias, incluso antes de que cualquier daño visible se haga evidente (Wu et al., 2023). En los últimos años, los rápidos avances en los sistemas aéreos no tripulados (RPAS) han impulsado el uso de imágenes aéreas, proporcionando adquisición de datos a altas resoluciones espaciales, espectrales y temporales (Sagan et al., 2019).

La accesibilidad a las imágenes térmicas infrarrojas mediante la utilización de RPAS ofrece una alternativa rápida y confiable para detectar y cuantificar el estrés hídrico de los cultivos (Zhou et al., 2021). Con el desarrollo de la tecnología medir la temperatura del dosel para diagnosticar el déficit hídrico de los cultivos tiene aplicaciones más prometedoras que la mayoría de otros métodos (Bo et al., 2023).

Las técnicas de visión artificial, integradas con algoritmos de aprendizaje profundo y la utilización de imágenes infrarrojas térmicas, se han convertido en un método sólido para la evaluación rápida y no destructiva del estado hídrico de los cultivos (Jin et al., 2024). Los módulos de aprendizaje profundo tienen potentes capacidades de adaptación y aprendizaje de diferentes funciones de modelos de los sistemas. Los métodos de aprendizaje automático que hasta ahora se han utilizado para la identificación de tipos de estrés hídrico en los cultivos incluyen redes neuronales artificiales, máquinas de vectores de soporte vectorial y clasificación de bosques aleatorios (Asadi & Shamsoddini, 2024).

Se requiere innovación en el reconocimiento del estrés hídrico de los cultivos, que sea rápido y no destructivo a lo largo de la temporada de crecimiento para disminuir el daño en la producción, la pérdida de rendimiento de semillas y la optimización del uso del agua (Bijanzadeh et al., 2022; Zhou et al., 2021).

Debido a lo anterior, esta investigación se enfocó en la determinación del estado hídrico en cultivo de maíz mediante aprendizaje automático aplicado a imágenes infrarrojas térmicas, mejoradas mediante técnicas de superresolución, con el fin de optimizar el uso del agua, reducir pérdidas de rendimiento y ofrecer un método eficiente y no destructivo para el monitoreo del estrés hídrico

1.2 Objetivos

1.2.1 Objetivo general

Determinar el estado hídrico del cultivo de maíz mediante modelos de aprendizaje automático e imágenes infrarrojas térmicas mejoradas mediante super resolución para hacer más eficiente el manejo del agua.

1.2.2 Objetivos específicos

- Desarrollar un sistema de cámara térmica por medio de sensores infrarrojos para medir la temperatura del dosel de las plantas a distancia.
- Implementar algoritmos de enfoque panorámico (pansharpening) para mejorar la resolución espacial de las imágenes infrarrojas térmicas georreferenciadas obtenidas con un RPAS mediante la superposición de imágenes RGB.
- Evaluar algoritmos de super resolución (pansharpening) utilizados en imágenes infrarrojas térmicas de baja resolución espacial utilizando imágenes de mayor resolución de una cámara térmica comercial.
- Evaluar los modelos de aprendizaje de inteligencia artificial para el cálculo de estado hídrico correlacionándolo con la temperatura del cultivo, humedad del suelo y las características agroclimáticas.

2. REVISIÓN DE LITERATURA

2.1 Agricultura climáticamente inteligente

Uno de los principales factores que están modificando el ambiente es el cambio climático, resultado de las emisiones de gases de efecto invernadero, altera las variables climáticas y modifica la composición física y química de la atmósfera (Ahmed et al., 2025; Noriega-Navarrete et al., 2022). Este fenómeno representa un desafío creciente para la agricultura: el aumento de la frecuencia de eventos extremos y las altas temperaturas se han convertido en factores cada vez más críticos que limitan la producción de cultivos (Schlubach, 2021) . Entre los desastres naturales, la sequía destaca como una de las amenazas más severas, poniendo en riesgo ecosistemas frágiles, poblaciones humanas y el desarrollo económico (Ahmed et al., 2025; Lai et al., 2018).

En México se prevé una disminución en la cantidad y distribución de las precipitaciones, un incremento en la temperatura media y una mayor frecuencia e intensidad de eventos extremos como sequías y ciclones tropicales, lo que impacta directamente la productividad de cultivos como el maíz al aumentar la evapotranspiración, la demanda hídrica y prolongar los grados día de desarrollo (Noriega-Navarrete et al., 2022). Según modelos climáticos globales que emplean el índice de precipitación estandarizada y evapotranspiración (SPEI), antes del 2100 se espera un aumento tanto en la frecuencia como en la severidad de las sequías (Yao et al., 2022).

La agricultura es cada vez más vulnerable a la variabilidad climática, reflejada en el aumento de las temperaturas, la alteración de los patrones de precipitación y la mayor frecuencia de fenómenos meteorológicos extremos, como inundaciones y sequías, lo que plantea dudas sobre su sostenibilidad a largo plazo. Al mismo tiempo, el sector agrícola contribuye de forma significativa a la degradación ambiental. Ante la creciente urgencia de mitigar estos impactos, se vuelve fundamental adoptar enfoques integrados hacia una agricultura sostenible (Musa & Ariff Lim, 2025). En este contexto, resulta crucial implementar prácticas de

adaptación y mitigación frente a los efectos adversos del cambio climático (Baffour-Ata, Guodaar, et al., 2025; Ahmed et al., 2025).

La agricultura climáticamente inteligente (ACI) es un enfoque integral que busca aumentar la productividad agrícola, fortalecer la capacidad de adaptación y reducir el impacto negativo del cambio climático, con el fin de garantizar la seguridad alimentaria y mejorar los medios de vida de los agricultores (Cortes et al., 2025; Ahmed et al., 2025). Su propósito se sustenta en un enfoque de triple beneficio: (i) incrementar la producción de alimentos de manera sostenible, (ii) aumentar la resiliencia frente a los impactos climáticos y (iii) disminuir la intensidad de las emisiones de gases de efecto invernadero (Cortes et al., 2025; Ahmed et al., 2025; Baffour-Ata, Guodaar, et al., 2025).

La ACI busca producir más alimentos de mejor calidad sin agotar los recursos naturales. Muchas de las prácticas actualmente clasificadas como climáticamente inteligentes han sido empleadas históricamente por agricultores de distintas regiones, impulsadas por la necesidad de optimizar el uso de recursos y gestionar de forma adecuada los nutrientes del suelo. Estas prácticas tradicionales sentaron las bases de sistemas agrícolas sostenibles mucho antes de que se definieran los marcos conceptuales modernos de la ACI (Baffour-Ata, et al., 2025).

Entre las principales prácticas agrícolas climáticamente inteligentes se incluyen: la adopción de sistemas de riego eficientes, la diversificación de cultivos resilientes al clima, las técnicas de agricultura de conservación, la gestión integrada de la fertilidad del suelo, la agroforestería, la agricultura de precisión y la mejora en la gestión ganadera. Estas estrategias favorecen la fertilidad del suelo y contribuyen a aumentar el rendimiento agrícola, permitiendo a los cultivos resistir fenómenos meteorológicos extremos, la escasez de agua y las condiciones cambiantes de producción. De este modo, se estabilizan tanto los rendimientos como los ingresos frente a la variabilidad climática. Asimismo, prácticas como el acolchado orgánico, el compostaje y el cultivo de carbono

ayudan a secuestrar carbono en el suelo y a reducir la huella de carbono de la agricultura (Baffour-Ata, et al., 2025; Ahmed et al., 2025)

Es fundamental reconocer que la implementación de la ACI debe adaptarse a los contextos socioeconómicos, ambientales y climáticos locales. Este enfoque se alinea con compromisos internacionales, como los Objetivos de Desarrollo Sostenible y el Acuerdo de París, contribuyendo a metas globales de mejor producción, mayor sostenibilidad ambiental y mejores medios de vida rurales. Así, la ACI no solo favorece la adaptación de la agricultura a climas cambiantes, sino que también fortalece la seguridad alimentaria y la protección de los ecosistemas (Baffour-Ata, et al., 2025).

Se estima que para la década de 2050 la población mundial alcanzará los 9 mil millones de personas, lo que exigirá un aumento de la producción de alimentos de hasta un 70 %. Ante este desafío, resulta esencial que las prácticas agrícolas sean climáticamente inteligentes y que los agricultores gestionen sus explotaciones con mayor precisión para garantizar una producción sostenible (Billah et al., 2025).

Al aprovechar los servicios ecosistémicos, la agricultura climáticamente inteligente promueve sistemas agrícolas más eficientes y adaptativos. Este enfoque transformador no solo redefine las prácticas productivas, sino que también desempeña un papel crucial en la seguridad alimentaria frente a los retos del cambio climático (Musa & Ariff Lim, 2025)

Gancone et al. (2021) destacan que la ACI contribuye a mejorar la eficiencia en el uso de recursos y puede ayudar a alcanzar la neutralidad de emisiones para 2050. En esta misma línea, Ariani et al. (2018) proyectan que la implementación de la ACI podría reducir las emisiones de gases de efecto invernadero entre un 7 % y un 23 % del potencial de calentamiento global. Además, señalan que puede aumentar la productividad agrícola entre 0.7 y 1.9 toneladas por hectárea, con una tasa de retorno de la inversión superior a 2, lo que la hace ambientalmente sostenible y económicamente viable, generando ganancias potenciales entre 42 y 129 %.

En regiones con estrés hídrico, los agricultores no dependen de un solo cultivo; por el contrario, incrementan la diversificación productiva, lo que reduce las pérdidas por plagas y estabiliza los rendimientos. Otro componente clave de la ACI es la gestión del agua, que incluye la recolección de lluvia para el riego de cultivos comerciales, práctica que mitiga los efectos de los choques climáticos. Asimismo, la gestión de la fertilidad del suelo es una práctica central de la ACI. Esta abarca el uso de estiércol, fertilizantes orgánicos, aplicación eficiente de fertilizantes inorgánicos y técnicas de control de erosión, que en conjunto mejoran la productividad y la salud del suelo (Ahmed et al., 2025).

La ACI representa una intervención innovadora para fortalecer los medios de vida y los sistemas alimentarios de pequeños agricultores, especialmente en áreas propensas a sequías (Baffour-Ata, Mensah, et al., 2025; Ahmed et al., 2025). Su implementación permite aumentar la productividad agrícola, preservar el medio ambiente y adaptarse a la variabilidad climática, contribuyendo así a la seguridad alimentaria global (Ahmed et al., 2025).

En definitiva, las intervenciones de ACI son esenciales para mejorar la productividad y resiliencia a largo plazo, al mismo tiempo que promueven una agricultura sostenible. Esta última, entendida como un enfoque holístico, prioriza la salud de los ecosistemas y garantiza la seguridad alimentaria para las generaciones futuras (Musa & Ariff Lim, 2025). La FAO (2019) define la sostenibilidad agrícola a través de tres dimensiones interrelacionadas: económica (productividad de la tierra, rentabilidad y resiliencia), ambiental (salud del suelo, uso eficiente del agua, biodiversidad) y social (empleo, seguridad alimentaria, tenencia de la tierra), lo que refleja el carácter multifacético del desarrollo sostenible en la agricultura. A continuación, el Cuadro 1 se muestra las prácticas de Agricultura Climáticamente Inteligente en categorías.

Cuadro 1. Prácticas de Agricultura Climáticamente Inteligente (ACI).

Categoría	Práctica	Objetivo principal	Impacto esperado (productivo, ambiental y social)
Manejo del suelo y conservación	Agricultura de conservación	Mantener la cobertura del suelo y reducir la labranza	Menor erosión, mayor materia orgánica en el suelo y retención de agua
	Acolchado orgánico / compostaje	Mejorar fertilidad y humedad del suelo	Menor erosión y mejora de la estructura del suelo
	Cultivos de cobertura	Proteger y enriquecer el suelo	Aumenta el nitrógeno en el suelo y biodiversidad, evita las malezas
	Rotación de cultivos con leguminosas	Aumentar nitrógeno y reducir plagas	Menor uso de fertilizantes y mayor fertilidad
Producción y genética	Variedades tolerantes al estrés	Resistencia a sequía, calor, salinidad	Mayor resiliencia y estabilidad de rendimientos
	Variedades de alto rendimiento	Incrementar la productividad	Mayor producción sin expansión de tierras
	Cambio del calendario de cultivos	Ajustar fechas de siembra a cambios climáticos	Mayor adaptación a lluvias irregulares
Gestión del agua	Recolección de agua de lluvia	Captar agua para riego en épocas secas	Mayor disponibilidad de agua y menor presión sobre acuíferos
	Humectación y secado alternativos (AWD)	Reducir uso de agua en arroz y cultivos de alta demanda hídrica	Menor consumo de agua y emisiones de metano
	Riego suplementario	Apoyar cultivos en momentos críticos	Mayor rendimiento y menor pérdidas por sequía
	Riego de precisión (sensores, goteo)	Optimizar el uso del agua	Menor consumo de agua y mayor eficiencia

Manejo de plagas y nutrientes	Manejo integrado de plagas (MIP)	Controlar plagas con mínimo uso de químicos	Menor uso de pesticidas y mayor biodiversidad
	Pesticidas orgánicos / biofertilizantes	Sustituir agroquímicos sintéticos	Disminuye la contaminación y mejora la salud del suelo
	Uso equilibrado de agroquímicos	Aplicar fertilizantes de manera racional	Disminuye las emisiones de N ₂ O, y contaminación de agua
	Agricultura de precisión / agricultura electrónica	Uso de sensores, drones y SIG	Mejora la eficiencia de insumos y disminuye costos
Organización social y economía	Seguro de cosechas	Proteger ingresos ante eventos climáticos	Mejora la estabilidad económica
	Marketing cooperativo	Mejorar comercialización colectiva	Mayores ingresos y poder de negociación
	Formación de grupos de agricultores	Fortalecer capacidades y acceso a tecnología	Genera adopción de innovaciones
	Desarrollo de organizaciones de agricultores	Promover representación y financiamiento	Mayor acceso a créditos y gestión comunitaria
	Aceptar préstamos/créditos	Financiar tecnologías de adaptación	Mayor inversión en riego y semillas mejoradas
	Migración / trabajos fuera de la explotación	Diversificar ingresos ante sequías	Mejor resiliencia económica
Diversificación y sistemas integrados	Sistema agrícola integrado	Combinar cultivos, ganadería y pesca	Mayores ingresos, menor riesgo climático
	Cultivos en el límite del dique/gher	Aprovechar bordes de estanques	Mayor seguridad alimentaria

Jardinería casera	Producción de alimentos para autoconsumo	Mayor seguridad alimentaria, ↓ gasto
Agroforestería	Integrar árboles con cultivos y ganado	Mayor captura de carbono, ↑ biodiversidad
Producción acuapónica	Integrar peces y vegetales en circuito cerrado	Mayor eficiencia del agua, ↑ ingresos

Fuente: Elaboración propia.

2.2 Riego en la agricultura

El riego es una práctica agrícola esencial que consiste en la aplicación artificial de agua al suelo, necesaria para el crecimiento y desarrollo de las plantas (Abioye et al., 2022a). En los métodos convencionales, el riego se aplica de manera uniforme, sin considerar la variabilidad del campo ni las necesidades específicas de agua de cada cultivo (Jiménez et al., 2022). Esto reduce la eficiencia del uso del agua, provocando en ocasiones exceso de riego en algunas zonas y déficit hídrico en otras (Abioye et al., 2022a).

Las técnicas tradicionales como el riego por inundación o aspersión aérea suelen generar desperdicio de agua y distribución desigual, dificultando la absorción óptima por las raíces, aumentando los costos de riego y reduciendo la productividad (Chen et al., 2023).

El riego de precisión integra tecnologías de información, comunicación y control para optimizar el uso de los recursos hídricos y minimizar el impacto ambiental. Este enfoque considera la variación espacial y temporal del suelo, las propiedades hidráulicas, la respuesta de las plantas al déficit de agua y las condiciones climáticas cambiantes, permitiendo tomar decisiones que maximizan el ahorro de agua y el rendimiento de los cultivos (Abioye et al., 2022a).

Los sistemas comerciales de riego automatizado suelen programarse mediante intervalos de tiempo predefinidos, basándose en el conocimiento empírico del usuario sobre los cultivos, el suelo y el clima. Algunos agricultores emplean programación basada en la humedad del suelo o en parámetros climáticos (Bwambale et al., 2022).

El estrés hídrico también puede presentarse mediante riego deficitario regulado, en el que los cultivos reciben menos agua de la necesaria para reemplazar completamente la pérdida por transpiración (M. Wang et al., 2024). Este enfoque estratégico busca maximizar la eficiencia en el uso del agua durante etapas críticas del crecimiento, asegurando un desarrollo saludable de los cultivos y reduciendo el suministro en periodos menos críticos para ahorrar recursos hídricos (Jiao et al., 2024; Ouma et al., 2024). El RDI permite asignar los recursos

hídricos limitados únicamente en los momentos más críticos del ciclo de crecimiento, optimizando el uso del agua sin comprometer el rendimiento de los cultivos (M. Wang et al., 2024).

A nivel mundial, la superficie de cultivo bajo riego alcanzó 292 millones de hectáreas en 2021, lo que representa alrededor del 20 % de las tierras cultivadas y genera más del 40 % de la producción alimentaria global (Chukalla et al., 2025). El sector agrícola es el mayor consumidor de agua potable, con el 70 % de las extracciones mundiales destinadas a riego en la agricultura (FAO, 2024).

En México, la superficie equipada con infraestructura de riego asciende a cerca de 10.1 millones de hectáreas, de las cuales 7.3 millones corresponden a superficie efectiva regada, incluyendo los distritos y unidades de riego, este territorio irrigado representa alrededor del 35 % de la superficie agrícola nacional y su contribución supera el 50 % de la producción (CONAGUA, 2023).

En cuanto al volumen de agua, las extracciones totales anuales en México alcanzaron 37 800 millones de metros cúbicos de agua en el periodo 2020–2021, con el sector agrícola responsable del 74 % del total, equivalente a 28 000 millones de m³ destinados al riego (FAO, 2025). Según la FAO (2023), la tecnificación y digitalización del riego pueden reducir las extracciones entre 10-25 %, mejorando simultáneamente la productividad del agua y mitigando la sobreexplotación de acuíferos.

2.3 Estrés hídrico en cultivos agrícolas

A nivel global, los patrones de precipitación están cambiando como consecuencia del cambio climático, provocando que regiones que históricamente no requerían riego ahora necesiten suministro adicional de agua (M. Wang et al., 2024). Estas modificaciones, junto con el aumento de la temperatura, incrementan la evapotranspiración de los cultivos y extienden sus periodos de riego, generando una mayor demanda de agua disponible (Ouma et al., 2024; Berríos et al., 2024).

En muchas regiones, el agua proporcionada por la lluvia es ocasional, lo que produce déficits hídricos que limitan la productividad agrícola y afectan los

procesos fisiológicos y rutas metabólicas esenciales para el crecimiento y desarrollo de las plantas (Stagno et al., 2024; Gebeyhu & Markos, 2023). Así mismo, la frecuencia y gravedad de estos déficits han aumentado significativamente debido al cambio climático (Mondol et al., 2022).

El estrés hídrico en plantas se refiere a la situación en la que una planta no tiene suficiente agua disponible para sus necesidades fisiológicas. Esto puede deberse a la falta de lluvia, suelos secos, o a que la demanda de agua de la planta es mayor que la que puede absorber. Es un desequilibrio entre la transpiración (pérdida de agua por la planta) y la absorción de agua por las raíces (Luna-Flores et al., 2012).

La creciente necesidad de mejorar la eficiencia en el uso del agua en la agricultura de riego ha motivado la investigación en este campo, dada la importancia del sector agrícola como consumidor de agua y la intensificación de los periodos de escasez hídrica. Para aumentar la productividad de los cultivos, es fundamental monitorear con precisión las condiciones del suelo y del clima, y programar el riego de manera que satisfaga de forma óptima la demanda hídrica de las plantas (Bwambale et al., 2022).

2.4 Daños ocasionados por estrés hídrico.

La intensidad y duración del estrés hídrico determinan los efectos sobre el crecimiento de las plantas y su capacidad de adaptación. Entre los principales impactos se incluyen la reducción de altura, tamaño de tallo y raíces, área foliar, peso foliar específico y biomasa total, así como una menor eficiencia en el uso del agua debido a alteraciones en la evapotranspiración (Luna-Flores et al., 2012).

La disponibilidad de agua está directamente relacionada con el rendimiento de los cultivos; déficits moderados a severos pueden reducir significativamente la producción (Mondol et al., 2022). Aunque un déficit de riego moderado es admisible, estudios han reportado que cuando el agua de riego se reduce entre 40 y 50 %, el impacto en el rendimiento si varía significativamente en la producción (Chen et al., 2023).

Durante la etapa de plántula, las plantas son más vulnerables al estrés hídrico debido a un sistema radicular aún inmaduro, lo que puede comprometer su establecimiento e incluso provocar mortalidad (Seleiman et al., 2021; Zhao et al., 2020) . Durante el período vegetativo, los síntomas incluyen disminución de altura, marchitamiento de hojas y reducción del número y área foliar. La menor altura se relaciona con una expansión celular limitada, desprendimiento de hojas y mitosis deteriorada bajo sequía (Yang et al., 2021).

El estrés hídrico también afecta la fisiología de las plantas, reduciendo la evapotranspiración, la biomasa acumulada y el rendimiento, además de generar cambios estructurales en las hojas, como menor área foliar, mayor grosor y densidad del tejido foliar (Wu et al., 2023). A nivel bioquímico, la limitación de agua conduce a la sobreproducción de especies reactivas de oxígeno (*ROS*), como el peróxido de hidrógeno ($H_2 O_2$) y los radicales aniónicos superóxidos (O_2^-), lo que resulta en una inhibición del crecimiento, disminuciones en las funciones fotosintéticas, peroxidación lipídica y mayor frecuencia de procesos de muerte celular programada (Sun et al., 2020).

El estrés hídrico también afecta la respiración, que refleja el metabolismo general de la planta; los datos disponibles muestran variaciones desde inhibición hasta estimulación según las condiciones de estrés, mientras que la tasa neta de asimilación de CO_2 y la conductancia estomática disminuyen significativamente bajo déficit gradual de agua (Noguera et al., 2020).

Estudios han reportado que la altura de plantas de lirio, maíz, caña y arroz disminuye de manera significativa bajo condiciones de estrés hídrico. Las hojas, como principales órganos de asimilación y transpiración, presentan adaptaciones morfológicas frente a la sequía, tales como reducción del área foliar, mayor grosor y densidad del tejido foliar, lo que refleja directamente el grado de escasez de agua (Yang et al., 2021).

Por ejemplo, Sah et al. (2020) demostraron que el estrés hídrico durante la etapa inicial de crecimiento del maíz (*Zea mays*) reduce significativamente el rendimiento. De manera similar, Jin et al. (2020) reportaron que el maíz es

particularmente sensible al déficit hídrico en las primeras fases de crecimiento, y que la sequía durante el período vegetativo afecta negativamente el rendimiento. En contraste, un suministro adecuado de agua mejora la tasa máxima de crecimiento del índice de área foliar, la altura y el desarrollo general del maíz, en comparación con dosis menores de riego (Yang et al., 2023).

Un estudio realizado por Jiao et al. (2024) encontró que en situaciones del maíz donde hay déficits severos durante la etapa vegetativa, déficits leves durante la etapa reproductiva, o déficits moderados en ambas etapas, genera que la evapotranspiración del cultivo (ET_c) disminuya, reduciendo significativamente el rendimiento. Los déficits severos (40% ET_c) redujeron significativamente el índice de área foliar y la acumulación de materia seca (MS), lo que resultó en una disminución significativa de la producción.

En trigo de invierno (*Triticum aestivum* L.), Zeng et al. (2023) demostraron que déficits hídricos graves y frecuentes, especialmente durante las fases previas a la floración, provocan reducciones de rendimiento del 55-60 % en comparación con condiciones de riego suficiente.

En algodón (*Gossypium* spp.), estudios sobre diferentes estrategias de siembra y emergencias hídricas mostraron que mayores cantidades de agua para las plántulas (2021: 67.5–112.5 mm; 2022: 6–15 mm) y alta frecuencia de riego incrementaron la acumulación de materia seca y los indicadores de crecimiento, mejorando el rendimiento promedio entre 8.6 y 16.4 % en comparación con tratamientos de baja frecuencia (J. Ma et al., 2024).

Adet et al. (2024) demostró que en cacao (*Theobroma cacao*), el bajo rendimiento se puede mitigar parcialmente con riego y aplicación de potasio, aumentando significativamente la producción en la cosecha principal (77 %), especialmente en el número de vainas por árbol.

En cultivos leñosos, reducciones moderadas del 20-30 % en agua de riego generalmente no afectan el rendimiento y pueden incrementar la productividad del agua (WP) entre 0-30 %, mientras que déficits del 40-50 % muestran

variaciones significativas según la especie, con incrementos de WP de hasta 50 % en algunos casos. Sin embargo, reducciones mayores afectan considerablemente el rendimiento y limitan la eficiencia del agua (M. Wang et al., 2024).

En berenjena (*Solanum melongena*), un riego adecuado incrementa la calidad del fruto, aumentando la humedad, el pH y el contenido de cenizas, y reduciendo los sólidos solubles totales, mientras que el almidón como reserva de carbohidratos se ve beneficiado con mayores niveles de riego (Ouma et al., 2024).

En café (*Coffea arabica* L.), Ramirez-Builes et al. (2024) reportan que al evaluar las influencias de diferentes proporciones de nitrógeno N, Amonio $NH_4^+{}^N$ y nitrato $NO_3^-{}^N$ en café y su interacción con los niveles hídricos del suelo en condiciones controladas, demostró claramente que el estrés hídrico reduce significativamente la acumulación de biomasa, la tasa de fotosíntesis, el contenido de clorofila y la absorción de nutrientes.

Stagno et al. (2024) reportaron que en tratamientos de riego de control al 100% de evapotranspiración del cultivo (ET_c), comparados con riego deficitario sostenido subterráneo y riego deficitario regulado en huertos de naranjos (*Citrus sinensis*), no se presentaron reducción del rendimiento, pero aun así la nutrición mineral de los árboles si se vio afectada por los tratamientos de riego; la concentración de elementos en las hojas estuvo generalmente en el rango óptimo; sólo el potasio mostró valores por debajo de las concentraciones foliares recomendadas.

En conjunto, estos estudios destacan que el estrés hídrico afecta el crecimiento, la fisiología y la productividad de los cultivos, y que estrategias de riego adecuadas, especialmente en etapas críticas, son esenciales para optimizar el rendimiento y la eficiencia del uso del agua.

2.5 Determinación del estado hídrico de cultivos y contenido de agua en el suelo

Existen diversos métodos para monitorear el estrés hídrico en los cultivos, los cuales se basan en mediciones de la humedad del suelo, la tasa fotosintética y características del cultivo, como la altura y el índice de área foliar. Sin embargo, la mayoría de estos enfoques son laboriosos, requieren mucho tiempo y, en algunos casos, pueden ser destructivos para las plantas. Además, dado que estas mediciones suelen limitarse a parcelas reducidas del campo, los resultados obtenidos podrían no ser representativos de las necesidades hídricas reales del cultivo o de las condiciones generales de humedad suelo (Bo et al., 2023).

La estimación de las necesidades de agua en cultivos de riego también puede realizarse a partir de la evapotranspiración del cultivo (ET_c), y de métodos basados en el balance hídrico del suelo (Pereira et al., 2020). Este enfoque normalmente utiliza sensores de humedad del suelo para calcular déficits hídricos y combina esta información con mediciones de la tasa fotosintética y características del cultivo, como altura y índice de área foliar, permitiendo que los sistemas de riego suministren agua de manera precisa y eficiente (Ouma et al., 2024; Bo et al., 2023). Otros métodos incluyen la medición del potencial hídrico xilemático o foliar, así como técnicas convencionales como tensiómetros, psicrómetros o determinaciones de la conductancia estomática (Noguera et al., 2020b).

El porómetro es una herramienta eficiente y valiosa para medir la conductancia estomática. Sin embargo, una desventaja significativa de este tipo de herramienta es que solo se mide un pequeño número de hojas por árbol, lo que potencialmente pasa por alto tendencias más amplias en toda la planta o cultivo, aun así, la medición de la conductancia estomática (g_{sw}) proporciona un indicador del estado hídrico de la planta y refleja el grado de apertura estomática, que se ajusta en respuesta a los niveles de estrés de la planta. Comprender la relación entre la conductancia estomática y factores ambientales como la temperatura, radiación solar, la concentración atmosférica de CO_2 , la humedad

relativa y el contenido de humedad del suelo permite estrategias de gestión más sostenidas para mejorar la productividad del cultivo, ya que está directamente relacionada con la capacidad de una planta para regular la pérdida de agua a través de los estomas y en consecuencia, su eficiencia en el uso del agua (Guimarães et al., 2024).

El índice de estrés hídrico de los cultivos (CWSI), basado en la temperatura del dosel, constituye una herramienta útil para cuantificar el estado hídrico, detectar la aparición de estrés, predecir el rendimiento y planificar la programación del riego en diversos cultivos (Bo et al., 2023).

En conjunto, estas metodologías permiten ajustar tanto la cantidad como el momento de aplicación del riego, optimizando el uso del agua y la energía, mejorando la respuesta de los cultivos y aumentando la rentabilidad agrícola, al tiempo que se incrementa la sostenibilidad ambiental de las prácticas de riego (García Petillo, 2008). La programación del riego puede basarse en estimaciones del balance hídrico del suelo, la evapotranspiración de los cultivos (ET_c), el contenido de agua del suelo, el estado hídrico de las plantas, el potencial hídrico del suelo, o la temperatura del dosel mediante termometría infrarroja (García Petillo, 2008). Otros enfoques emplean mediciones directas del crecimiento de órganos vegetales mediante dendrómetros, combinados con sensores de flujo de savia basados en el método del pulso de calor, para determinar el momento y la intensidad con la que la disponibilidad de agua limita la transpiración del cultivo (López López et al., 2009a). A continuación, se muestra las metodologías antes mencionadas (Cuadro 2).

Cuadro 2. Clasificación de las metodologías de monitoreo del estado hídrico.

Metodologías para evaluar el estado hídrico de los cultivos		
Contenido de agua	Potencial hídrico	Medidas indirectas del estado hídrico
Contenido relativo de agua	- Potencial hídrico foliar - Potencial xilemático	- Temperatura de la cubierta (Índices de estrés hídrico)

-
- | | |
|--|---|
| <ul style="list-style-type: none">• Psicrometría de termocupla• Método de coloración de Shardakov | <ul style="list-style-type: none">• Conductancia estomática• Flujo de savia• Cavitación• Efecto Doppler• Dendrometría |
|--|---|
-

Fuente: Elaboración propia.

2.6 Índices de estrés hídrico utilizando temperatura del cultivo

Con el avance de la tecnología de detección remota, se han propuesto múltiples métricas para monitorear las condiciones de crecimiento de los cultivos, predecir el rendimiento y caracterizar el entorno en el que se desarrollan (Ji et al., 2021). Para la evaluación de la sequía agrícola se han utilizado diferentes índices, como el índice de déficit hídrico del suelo, el índice de humedad del suelo y el índice de déficit hídrico del suelo modificado, los cuales han demostrado utilidad para controlar eficazmente los efectos de la sequía durante el ciclo de cultivo (Yao et al., 2022).

En el monitoreo agrícola con imágenes térmicas los métodos más empleados se basan en el cálculo de índices de temperatura del dosel, tales como el índice de estrés hídrico del cultivo (CWSI), los grados por encima del índice no estresado (DANS), el grado por encima del umbral del dosel (DACT) y el índice relativo de temperatura del dosel (NRCT), todos ellos derivados de los valores de temperatura del dosel (Wu et al., 2023).

Los índices de estrés que usan la temperatura del dosel se calculan a partir de la temperatura registrada al mediodía, momento en el que los cultivos son más propensos a experimentar condiciones de estrés hídrico. Sin embargo, Kullberg et al. (2017) reportaron una alta variabilidad espacio-temporal en la temperatura del dosel, lo que sugiere que las mediciones al mediodía pueden tener limitaciones específicas. Asimismo, otros estudios evidencian que la variación de la temperatura del dosel está directamente relacionada con la intensidad y duración de la radiación solar (Wu et al., 2023).

La temperatura del cultivo constituye una fuente de información valiosa para la evaluación del estado hídrico de la planta. No obstante, con frecuencia se requiere establecer relaciones entre los indicadores térmicos y otros parámetros fisiológicos, los cuales no siempre presentan suficiente robustez, especialmente en condiciones de campo, donde intervienen múltiples factores ambientales (temperatura del aire, radiación solar, ángulo de incidencia de la radiación,

velocidad del viento y humedad relativa) y morfológicos (García-Tejero et al., 2018).

De los diferentes índices, el CWSI y el índice de conductancia estomática relativa (IG) son los más empleados y han sido validados en distintos cultivos. Sin embargo, ambos requieren pruebas adicionales y ajustes metodológicos para su implementación con sensores térmicos tanto terrestres como aéreos (García-Tejero et al., 2018).

El índice CWSI derivado de la temperatura del dosel se ha aplicado exitosamente para diagnosticar el estado hídrico de las plantas, evaluar la humedad del suelo y definir estrategias de programación del riego en cultivos como maíz, pimiento, algodón, trigo y vid (Wu et al., 2023; Shao et al., 2023). Por su parte, DANS y DACT también han mostrado un buen desempeño en el monitoreo del estado hídrico en girasol y maíz, contribuyendo a mejorar la toma de decisiones en riego (Kganyago et al., 2024). Además, Kullberg et al. (2017) compararon cuatro índices de temperatura y concluyeron que los índices con menores requerimientos de datos, como DANS y DACT, ofrecen una alta sensibilidad al estrés hídrico y presentan errores cuadráticos medios (RMSE) reducidos en la estimación de la evapotranspiración, con un rendimiento comparable al de enfoques más complejos y demandantes de datos, como el CWSI (Wu et al., 2023; Kganyago et al., 2024).

2.6.1 Índice de estrés hídrico de cultivos

El índice de estrés hídrico del cultivo (CWSI) es un indicador derivado de detección remota en el espectro infrarrojo, ampliamente utilizado por su alta precisión, bajo costo y rapidez de aplicación. Su fundamento se basa en que la transpiración foliar enfría el dosel; cuando la humedad del suelo disminuye, la conductancia estomática se reduce, disminuye la transpiración y, en consecuencia, la temperatura del dosel aumentará (Bijanzadeh et al., 2022).

El CWSI se ha aplicado con éxito para cuantificar el déficit hídrico en diversos cultivos como vid, olivo, trigo, patata, algodón y almendro (Tunca et al., 2023). Este índice se calcula a partir de la temperatura del dosel, la temperatura del aire

y el déficit de presión de vapor, y se considera un método eficaz para la programación del riego en campo abierto. (López López et al., 2009a).

Jackson et al. (2020), definen al CWSI como la diferencia entre la temperatura del aire (T_a) y del dosel vegetal del cultivo (T_c) normalizado para la demanda evaporativa, determinado por medio de un límite inferior (cultivo en que el dosel transpira a su velocidad potencial con los estomas totalmente abiertos) y un límite superior (dosel que no transpira con los estomas completamente cerrados).

Idso et al. (1981) propusieron un método empírico al observar una relación lineal entre la temperatura del dosel y el déficit de presión de vapor, estableciendo la siguiente ecuación (Wu et al., 2023):

$$CWSI = \frac{(T_c - T_a)_m - (T_c - T_a)_{li}}{(T_c - T_a)_{ls} - (T_c - T_a)_{li}}$$

Donde:

- T_c : Temperatura dosel del cultivo.
- T_a : Temperatura del aire. El subíndice m denota la diferencia medida entre las dos temperaturas.
- m: diferencia medida en condiciones reales de campo.
- li: límite inferior (cuando la transpiración es máxima).
- ls: límite superior (cuando la transpiración es mínima).

El CWSI varíe entre 0 a 1 cuando las plantas van de una condición bien regada a una condición totalmente estresada. Puesto que no es normalmente factible medir simultáneamente la temperatura del cultivo sin estrés y un cultivo con estrés, los valores del límite inferior y superior de un dosel se pueden calcular mediante el análisis de balance de energía en la superficie (López López et al., 2009a).

Otra representación similar, en donde el CWSI se define entre las temperaturas límites superiores e inferiores, T_{dry} y T_{wet} , que representan una hoja en estado

de no transpiración y una hoja en estado completamente transpirando, respectivamente (Wu et al., 2023), y se observa en la siguiente ecuación:

$$CWSI = \frac{T_C(h) - T_{wet}(h)}{T_{dry}(h) - T_{wet}(h)}$$

Donde:

- $T_C(h)$: Temperatura del dosel del arroz extraída de las imágenes térmicas.
- $T_{wet}(h)$: Temperatura media de la superficie de referencia húmeda (Luan et al., 2021), que puede sustituir a la temperatura de referencia en condiciones de no estrés hídrico y puede medirse pulverizando agua sobre las hojas de tres plantas aproximadamente 1 min antes de tomar la imagen.
- $T_{dry}(h)$: Límite superior de la temperatura del dosel cuando los estomas están completamente cerrados y cesa la transpiración, estimado agregando 5 °C a la temperatura promedio del aire (Irmak et al., 2000 , Luan et al., 2021).
- $T_{air}(h)$: Temperatura promedio del aire en un momento específico, registrado por una estación meteorológica, y 'h' representa los puntos de tiempo de la prueba, a diferentes horarios.

El índice CWSI, normaliza la diferencia entre temperatura del dosel y temperatura del aire, se ha utilizado como criterio de programación del riego y diagnóstico del estado hídrico (Gonzalez-Dugo & Zarco-Tejada, 2024). Estudios recientes han mostrado que los valores de condiciones favorables de riego (nivel bajo de estrés hídrico) se encuentran en rangos de 0.26 a 0.38 para etapas tempranas y 0.27-0.32 durante la floración, para un cultivo de trigo, lo cual indica que mientras el CWSI permanezca por debajo de dichos valores la producción no se ve negativamente afectada (He et al., 2024). Por otro lado, otros trabajos encuentran que un valor de $CWSI \geq 0.35$ puede marcar el inicio de reducción significativa de rendimiento, por lo que se recomienda que la programación de riego se active antes de alcanzar ese umbral (Kumari et al., 2024). Adicionalmente, en un ensayo de quinua en zonas áridas se estableció que un CWSI en el rango de 0.38-0.61

se generaba el riego (Mendoza-Márquez et al., 2025). Aunque el índice teórico va de 0 (sin estrés) a 1 (estrés máximo), los trabajos recientes han identificado rangos operativos específicos del cultivo, la etapa fenológica y la condición ambiental permiten definir umbrales óptimos para este índice.

2.6.2 Índice de conductancia estomática relativa

El índice de conductancia estomática relativa (IG), tiene una relación directa con la conducción estomática y el estrés hídrico calculado utilizando la temperatura del dosel, que se utilizan comúnmente para monitorear las condiciones de estrés hídrico de los cultivos. IG tiene una relación directa con la conducción estomática y el estrés hídrico calculado utilizando la temperatura del dosel (Gag et al., 2015). Vincula la eficiencia del uso de la radiación (RUE) y el cambio en el área del dosel iluminado por el sol y sombreado inducido por el estrés hídrico, puede ser más útil que otros índices que se utilizan, actualmente, para la caracterización de los cultivos (Banerjee & Krishnan, 2020).

$$IG = \frac{T_{dry} - T_C}{T_C - T_{wet}}$$

Donde:

- T_C = Temperatura del cultivo.
- T_{dry} = Temperatura del cultivo recubierta con agua.
- T_{wet} = Temperatura del cultivo recubierta con vaselina, temperaturas foliares de referencia, que simulan circunstancias máximas y mínimas de transpiración foliar bajo las condiciones ambientales expuestas.

En general, los índices de estrés como el CWSI se relacionan positivamente con la condición de estrés hídrico del cultivo y el IG se relaciona directamente con la conductancia estomática (Jones y Sirault, 2014).

El índice IG, ha sido promovido como una herramienta práctica para estimar el estado de apertura estomática bajo variabilidad hídrica, al relacionarse inversamente con la temperatura del dosel y directamente con la transpiración (Trenti et al., 2021). En condiciones de plena apertura estomática (riego

adecuado, sin restricción hídrica) se observa que IG tiende hacia valores más altos, próximos a 1, mientras que en estados de fuerte cierre estomático (estrés hídrico severo) el índice cae hacia valores cercanos a 0, estudios con vid mostraron una caída significativa de IG bajo estrés hídrico moderado-alto (Trenti et al., 2021). De este modo, aunque no se reportan umbrales universales de IG aplicables a todos los cultivos, los estudios recientes sugieren que un $IG > 0.75$ puede ser indicativo de conductancia estomática prácticamente “libre”, y un $IG < 0.25$ indica un estado de cierre estomático que puede comprometer la transpiración y el intercambio gaseoso del cultivo (Violet-Chabrand & Lawson, 2020).

2.6.3 Grados por encima del umbral no estresado y grados por encima del umbral del dosel

El grado de estrés hídrico DANS y DACT se puede calcular comparando la temperatura del dosel de los cultivos regados saturados con la de los cultivos regados no saturados. Con base en este principio, Taghvaeian et al., (2014) propusieron el grado por encima de las condiciones no estresadas (DANS). Jonge et al. (2015) tuvieron como objetivo minimizar el impacto del clima y el tiempo de prueba en la aplicación DANS, como resultado, propusieron el concepto de grados por encima del umbral del dosel (DACT), estos índices se calculan utilizando las siguientes ecuaciones:

$$DANS(h) = T_C(h) - T_{cNS}(h)(^{\circ}C)$$

$$DACT(h) = MAX[0, T_C(h) - T_{cNS}(h)](^{\circ}C)$$

Donde:

- $T_C(h)$: Temperatura del dosel extraída de la imagen térmica,
- $T_{cNS}(h)$: Temperatura del dosel en condiciones sin estrés, que es la temperatura del dosel bajo riego a 100% de su evapotranspiración, y
- h : Puntos temporales de la prueba, las horas del día de toma de datos del estudio.

Los valores del índice DANS suelen ubicarse entre 0 °C y 6 °C, donde valores cercanos a cero indican vegetación en condiciones óptimas de hidratación, mientras que valores superiores a 4 °C reflejan estrés hídrico significativo, asociado al cierre estomático y reducción de la transpiración (Jackson, R. D., et al., 1981).

Por su parte, el índice DACT presenta rangos típicos entre 0 °C y 8 °C, siendo valores bajos indicativos de cobertura vegetal densa y activa, y valores por encima de 6 °C asociados a suelos desnudos, fallas de germinación o zonas de baja biomasa. Estos umbrales térmicos se establecen mediante análisis de imágenes satelitales calibradas y segmentación espectral (NDVI, SAVI), y deben ajustarse según el tipo de cultivo, etapa fenológica y condiciones climáticas locales. La validación de estos índices se realiza con datos de campo, sensores de humedad foliar y estaciones meteorológicas, permitiendo su integración en mapas de diagnóstico para riego de precisión y manejo agronómico (Gutiérrez-Mora et al., 2025).

2.6.4 Temperatura relativa normalizada del dosel

Para cuantificar el estado hídrico y el grado de estrés del cultivo, Elsayed et al. (2017) normalizaron la temperatura del dosel medida en campo y propusieron la Temperatura Relativa Normalizada del Dosel (NRCT), la cual se calcula de la siguiente manera:

$$NRCT = \frac{T_C(h) - T_{\min}(h)}{T_{\max}(h) - T_{\min}(h)}$$

Donde:

- $T_C(h)$: Temperatura del dosel extraída de la imagen térmica.
- $T_{\min}(h)$: Temperatura más baja del dosel probada en el experimento de campo.
- $T_{\max}(h)$: Temperatura más alta probada en el experimento de campo.
- H : puntos Temporales de la prueba, las horas del día de toma de datos del estudio.

Aunque no se establecen umbrales universales, los autores señalan que valores de NRCT cercanos a cero (o negativos, bajo condiciones de alta transpiración) pueden interpretarse como ausencia de estrés; por el contrario, valores más altos, en rangos de 0.1 a 0.3 aumentados respecto al cultivo bien irrigado en ese experimento fueron asociados con estrés hídrico moderado (Gao et al., 2024).

Los valores bajos de NRCT corresponden a situaciones de mínimo estrés hídrico, donde la transpiración y la apertura estomática son óptimas; en contraste, valores más altos indican estrés hídrico moderado a severo, reflejado en menor transpiración y mayor calentamiento del dosel. Estudios realizados en lechuga han reportado rangos de NRCT entre aproximadamente 0.10–0.24 para condiciones de baja restricción hídrica, mientras que en situaciones de déficit de riego los valores alcanzaron 0.33–0.56, evidenciando la sensibilidad del índice a la disponibilidad de agua (Cheng et al., 2023). Si bien estos rangos son específicos para lechuga, reflejan la tendencia general de que un aumento de NRCT se correlaciona con estrés hídrico creciente.

2.6.5 Velocidad relativa de la temperatura del dosel

La transpiración de los cultivos varía según las diferentes condiciones hídricas, lo que genera diferencias en la temperatura del dosel. Sin embargo, en las pruebas de campo es difícil garantizar que todas las áreas de estudio presenten las mismas condiciones de radiación solar (Gu et al., 2020). Los cielos nublados pueden afectar los resultados de las mediciones e impedir una determinación precisa del estado hídrico del cultivo.

La capacidad del dosel para transpirar y responder al estrés ambiental puede cuantificarse comparando la tasa de cambio de la temperatura del dosel respecto a la temperatura atmosférica en distintos momentos del día (Wu et al., 2023).

Con base en este principio, autores como Maes y Steppe (2012) y Still et al. (2021) propusieron la corrección mediante la Velocidad Relativa de la Temperatura del Dosel (RCTV), la cual se calcula mediante la siguiente ecuación:

$$RCTV(h) = \frac{T_{C1}(h) - T_{C2}(h)}{T_{air1}(h) - T_{air2}(h)}$$

Donde:

- $T_{C1}(h)$ y $T_{air1}(h)$: Temperaturas promedio del aire y del dosel, respectivamente, en el momento 1.
- $T_{C1}(h)$ y $T_{air1}(h)$: Temperaturas promedio del aire y del dosel, respectivamente, en el momento 2. Considerando que la temperatura del dosel muestra variabilidad temporal.
- Momento 1: Corresponde al primer registro temporal de las temperaturas del dosel y del aire durante un mismo día o periodo de observación.
- Momento 2 : Corresponde a un segundo registro temporal posterior (varias horas después del momento 1, en el mismo día). Se selecciona en horas de máxima radiación solar o temperatura ambiente, cuando el cultivo comienza a experimentar mayor demanda evaporativa o posible estrés hídrico.

El RCTV cuantifica la tasa de cambio temporal de la temperatura del dosel respecto a una referencia atmosférica o térmica, reflejando la dinámica del intercambio de calor entre planta y ambiente (Wu et al., 2023). Valores de RCTV cercanos a 0 se asocian con cultivos bien irrigados y alta actividad de transpiración, donde el dosel mantiene una temperatura estable o incluso decreciente durante el periodo diurno. En cambio, incrementos en RCTV hacia valores de 0.3–0.5 indican estrés hídrico moderado, atribuible a una reducción parcial de la transpiración y a un calentamiento progresivo del dosel. Cuando el índice supera 0.5, se considera que el cultivo entra en condición de estrés severo, caracterizada por cierre estomático y pérdida de capacidad de enfriamiento (Shi et al., 2022; Zhao et al., 2024).

2.6.6 Índice sombreado de luz solar normalizado

El área del dosel del cultivo bajo condiciones de iluminación natural se compone de dos fracciones: una iluminada directamente por el sol y otra en sombra. La proporción relativa de estas áreas depende tanto del desarrollo fenológico del cultivo como del nivel de estrés hídrico al que esté expuesto. La cantidad de radiación solar interceptada por cada fracción condiciona la fotosíntesis y la

acumulación de biomasa, lo que, a su vez, determina la eficiencia en el uso de la radiación (RUE). A partir de imágenes térmicas y visibles, las fracciones iluminadas y sombreadas del dosel se clasificaron para el desarrollo del Índice Sombreado de Luz Solar Normalizado (NSSI) bajo diferentes condiciones de estrés hídrico, como se relaciona a continuación (Banerjee & Krishnan, 2020):

$$NSSI = \frac{SLCA - SHCA}{SLCA + SHCA}$$

Donde:

- SLCA: Área del dosel iluminada por el sol.
- SHCA: Área del dosel sombreada.

El NSSI se calcula en diferentes etapas de crecimiento del cultivo bajo diferentes tratamientos de estrés hídrico. NSSI es similar a NDVI, un índice espectral muy conocido. Pero en lugar de la reflectancia en NIR y la banda roja, se utiliza el componente de área del dosel iluminado y sombreado del cultivo, a partir de imágenes (térmicas y visibles) para determinar el NSSI en diferentes condiciones de estrés hídrico (Banerjee & Krishnan, 2020)& Krishnan, 2020).

El Índice NSSI constituye una herramienta para evaluar la proporción relativa entre áreas del dosel expuestas a radiación solar directa y zonas en sombra, varía teóricamente entre -1 a 1 (Banerjee & Krishnan, 2020). En condiciones de riego óptimo o sin estrés, el dosel mantiene una cobertura densa y homogénea que genera mayor superficie sombreada, resultando en valores de NSSI de -0.1 a 0.2 . A medida que se reduce la disponibilidad de agua y el cultivo entra en estrés moderado, el índice se incrementa, alcanzando valores en torno de 0.3 – 0.5 , lo que refleja menor cobertura y una proporción creciente de hojas expuestas a radiación directa. En situaciones de estrés hídrico severo, el dosel se fragmenta, aumenta la reflectancia solar y disminuye la transpiración, elevando el NSSI a valores superiores de 0.6 – 0.8 , con correlaciones negativas ($r^2 = 0.9$) respecto a la eficiencia en el uso de la radiación solar (Banerjee & Krishnan, 2020; Wang et al., 2023).

2.6.7 Índice de sequedad de temperatura-vegetación

El Índice de Sequedad Temperatura-Vegetación (TVDI), es un índice que combina la temperatura de la superficie con un índice de vegetación, desarrollado para estimar el estado de humedad (o sequedad) del sistema suelo-planta. Este índice no discrimina entre diferentes tipos de cobertura vegetal (cultivos, pasturas, monte), sino que representa el déficit hídrico de la vegetación presente. En áreas con cobertura escasa o nula (suelo desnudo o siembras incipientes), el TVDI refleja el contenido hídrico de la capa superficial del suelo (aproximadamente 5–10 cm de profundidad) (Carrasco-Benavides et al., 2022; Rodigheri et al., 2024).

$$\text{TVDI} = \frac{T_C - T_{C_{\min}}}{T_{C_{\max}} - T_{C_{\min}}}$$

Donde:

- T_C : Temperatura (en Kelvin) observada para un píxel dado.
- $T_{C_{\min}}$: Mínima temperatura de superficie en el triángulo y define el límite húmedo.
- $T_{C_{\max}}$: Valor máximo de temperatura de la superficie correspondiente bajo el mismo valor de VI.

En general, un TVDI cercano a 0 representa máxima humedad o ausencia de estrés hídrico, mientras que valores próximos a 1 corresponden a condiciones de sequía severa. Las categorías comúnmente utilizadas en representaciones gráficas sitúan los intervalos 0–0.1 como muy húmedo, 0.1–0.2 húmedo, 0.6–0.8 seco y 0.8–1 muy seco, siendo los valores intermedios 0.2–0.6 considerados como condiciones normales o de sequía leve (Carrasco-Benavides et al., 2022; Rodigheri et al., 2024). Los valores bajos de TVDI indican que el cultivo dispone de buena humedad en el suelo y mantiene una transpiración activa, mientras que los valores altos señalan una marcada restricción hídrica, asociada a la disminución de la evaporación y cierre estomático (Yuan et al., 2023; Przeździecki et al., 2023).

La estimación del estrés hídrico a partir de índices generados por la temperatura del dosel se integra con las tecnologías de teledetección aérea, particularmente con el uso de RPAS equipados con cámaras térmicas. Estos sistemas permiten obtener mapas de temperatura de alta resolución espacial, lo que facilita calcular índices térmicos como CWSI, NRCT o TVDI, que reflejan el estado hídrico en tiempo real. De este modo, la combinación de índices basados en temperatura del dosel y plataformas aéreas no tripuladas constituye una herramienta eficiente y precisa para el monitoreo del estrés hídrico, optimizando las decisiones de riego en agricultura de precisión.

2.7 Drones en el monitoreo agrícola para determinación del riego

La agricultura climáticamente inteligente representa una evolución hacia sistemas productivos más eficientes, sostenibles y tecnológicamente integrados (Sakka et al., 2025). Esta perspectiva impulsa la automatización y el análisis avanzado de datos, permitiendo una monitorización continua del estado de los cultivos, detección temprana de anomalías y toma de decisiones basada en información precisa y en tiempo real. Dentro de esta revolución tecnológica, los vehículos aéreos no tripulados (RPAS), se han consolidado como herramientas clave en la agricultura de precisión, gracias a su capacidad para adquirir información detallada y georreferenciada del campo agrícola (Sharma et al., 2025; Silva et al., 2024).

Los RPAS destacan por su flexibilidad de vuelo, simplicidad operativa y bajo costo, características que los posicionan por encima de plataformas satelitales o aeronaves tripuladas. Estas ventajas permiten obtener datos con alta resolución espacial y temporal, fundamentales para el diagnóstico preciso de variables agronómicas. Los RPAS están equipados con sensores multiespectrales, hiperespectrales, térmicos o RGB, que permiten capturar información sobre la estructura del dosel, la reflectancia espectral y la distribución de la temperatura superficial, lo que contribuye en la estimación de parámetros como el estado hídrico, la nutrición nitrogenada o el momento óptimo de fertilización (Yang et al., 2025).

La integración de los RPAS equipados con sensores y el análisis inteligente de grandes volúmenes de datos, ha facilitado la detección de estrés abiótico y biótico, la identificación de plagas o enfermedades y la estimación de rendimientos (Sharma et al., 2025).

La inteligencia artificial, sistemas de monitoreo remoto y teledetección mediante RPAS ha impulsado plataformas avanzadas para la gestión inteligente de cultivos, donde los drones se comunican con sensores terrestres y sistemas de riego automatizados para ajustar dinámicamente las condiciones de cultivo (Sharma et al., 2025). Aunque estas tecnologías ofrecen beneficios significativos, su aplicación en grandes extensiones agrícolas aún enfrenta desafíos como la variabilidad ambiental, las diferencias fenológicas, los efectos de píxeles mixtos. La visión por computadora y modelos predictivos basados en aprendizaje automático y profundo está reduciendo estas limitaciones, consolidando a los RPAS como herramientas clave en la agricultura climáticamente inteligente (Yang et al., 2025).

Las cámaras térmicas radiométricas desempeñan un papel fundamental al permitir obtener con precisión la temperatura del dosel y derivar índices como CWSI, NRCT o TVDI para evaluar el estrés hídrico (Yang et al., 2025). Los RPAS comerciales se han popularizado en teledetección agrícola por su accesibilidad y capacidad de integrar sensores avanzados, destacando cámaras térmicas con resoluciones de 320×256 y 640×512 píxeles, velocidades de 30 fps y medición radiométrica por píxel, lo que posibilita análisis cuantitativos en campo (Agrawal & Arafat, 2024).

Estudios recientes confirman que estas plataformas permiten monitorear con alta resolución espacial y temporal la condición hídrica del cultivo, superando las limitaciones de los métodos tradicionales de muestreo. En el Cuadro 3 se presentan los diferentes RPAS disponibles en el mercado, junto con sus respectivas cámaras y especificaciones.

Cuadro 3. Tipos de RPAS y características.

Marca / modelo	Sensor (tipo Resolución)	Radiométrico (temperatura por píxel)	Rango de precio (\$USD)	Características
DJI Mavic 3 Classic (RGB)	Hasselblad 4/3 CMOS RGB 20 Mega pixeles	No (no térmico)	999.–2,500.	RGB alta resolución fotogrametría / mapeo visual. (vuelo 46 min)h
DJI Mavic 3 Thermal (Mavic 3T / M3T)	Cámara térmica LWIR integrada (Boson/FLIR-based) 640 × 512 pixeles	Sí (capacidad radiométrica / mapas térmicos en variantes comerciales).	4,000. – 9,000.	Térmico radiométrico integrado + cámaras visuales/zoom; orientado a inspección y mapeo térmico. (vuelo 45 min)
DJI Mavic 3 Multispectral (Mavic 3M)	Multispectral RGB RGB 20 MP bandas: G / R / RedEdge / NIR: 5Mp	No (multispectral = reflectancia; no temperatura)	6,000.– 11,000.	Diseñado para agricultura: NDVI, RE, mapas de vigor; compacto y portátil. (vuelo 43 min)
DJI Matrice 300 RTK + Zenmuse H20T	Zenmuse H20T (microbolómetroVOx; paquete multi-sensor con térmico) 640×512 pixeles	Sí (radiométrico, calibrado)	Plataforma H20T: 14,000. Matrice: 25,000.	LWIR radiométrico + zoom visual + wide + laser rangefinder (multi-sensor). (vuelo 40 min)
DJI (FLIR) Zenmuse XT2 / XT series	FLIR Tau / Boson based thermal gimbal	Sí (versión radiométrica disponible)	6,000. (solo cámara)	LWIR radiométrico; dual visible + térmico. (vuelo 40 min)
Autel EVO II Dual 640T (Enterprise V3)	Sensor térmico (basado en FLIR/Autel) Opciones: 640×512 320×256	Sí (medición de temperatura / mapas térmicos)	4,000 – 6,000.	LWIR radiométrico integrado; opción “Dual” (visual + térmico). (vuelo 40 min)

pixeles				
Parrot ANAFI	FLIR Boson 320 LWIR 320×256 pixeles	Sí (algunas versiones admiten modos radiométricos o spot temp.)	4,000 – 8,000	LWIR (Boson 320) + zoom óptico 32× en visual; compacto y ligero. (vuelo 32 min)
FLIR Vue / TZ20 (cámara)	FLIR Boson / dual-Boson options; TZ20 = Térmica-zoom opciones: 320×256 640×512 pixeles	Sí (radiométrico disponible en variantes pro)	Cámara 3,500 – 12,000 (según zoom)	LWIR; TZ20 ofrece capacidades de zoom térmico (hasta 20×). (vuelo 40 min)
MicaSense RedEdge-MX (cámara)	Multiespectral multiespectrales 1.6 Mp	No (no es térmico; provee reflectancia calibrada)	Cámara 5,000.	Bands: blue, green, red, red-edge, NIR diseñado para NDVI, RE.
Parrot Sequoia (cámara)	Multiespectral: 1,2MP. RGB de 16MP	No (no térmico)	Cámara 3,000.	Green, Red, Red-edge, NIR + RGB + sunshine sensor. (vuelo 30 min)

Fuente: Elaboración propia.

Las ventajas de disponer de una cámara térmica diseñada para la determinación del estrés hídrico incluyen: una mayor cobertura superficial del cultivo en comparación con mediciones manuales puntuales, lo que mejora la representatividad y permite gestionar la heterogeneidad; la capacidad de realizar monitoreos frecuentes, lo que da mayor oportunidad de tomar decisiones de riego oportunas; la fusión de datos térmicos con otras modalidades de sensor que permite mejorar la estimación del contenido de agua en el suelo y del estado hídrico del cultivo (Guan & Grote, 2024).

Por lo tanto, el desarrollo de una cámara térmica para agricultura de precisión responde a la necesidad de superar limitaciones tecnológicas actuales: diferencias de resolución espacial, coste elevado de sensores radiométricos, calibración radiométrica, y variabilidad de las condiciones ambientales que afectan la medición de temperatura del dosel. Al diseñar un sistema térmico de bajo coste, calibrado, y optimizado para vuelo con drones, se puede habilitar una herramienta operativa para estimar el estado hídrico con alta fidelidad, incrementar la eficiencia del agua y reducir daños por estrés hídrico en el cultivo (Ndlovu et al., 2024).

2.8 Cámaras térmicas

La medición de temperatura mediante métodos tradicionales, como termopares o pirómetros puntuales, puede no ofrecer una visión completa de las propiedades térmicas de un objeto. Estos instrumentos no proporcionan la resolución ni la velocidad necesarias para caracterizar de forma integral aplicaciones térmicas dinámicas. En contraste, las cámaras infrarrojas capturan miles de puntos de medición térmica a alta velocidad, lo que permite visualizar con precisión dónde se genera el calor y cómo evoluciona en el tiempo. Con la cámara de infrarrojos adecuada, es posible obtener mediciones confiables y de alta resolución (ElSheikh et al., 2023).

Actualmente, se utilizan principalmente dos tipos de cámaras térmicas infrarrojas: cámaras refrigeradas basadas en recuento de fotones, de alto rendimiento, y cámaras no refrigeradas, más económicas, basadas en microbolómetros. En el contexto de los sistemas fotoeléctricos infrarrojos multibanda aerotransportados, existen dos consideraciones clave: primero, debido a las restricciones de espacio y potencia en plataformas aéreas, los sistemas deben diseñarse de manera extremadamente compacta; segundo, los instrumentos ópticos del canal IR presentan una alta emisividad, lo que genera radiación parásita interna que influye de manera significativa en la señal recibida por el plano focal infrarrojo (IRFPA) (Dong et al., 2023).

Las cámaras térmicas infrarrojas constituyen una tecnología avanzada capaz de detectar la radiación térmica emitida pasivamente por los objetos para formar una imagen (Jiang et al., 2023). Todo cuerpo con una temperatura superior al cero absoluto (0 K) emite energía en la región del espectro infrarrojo, la cual es imperceptible al ojo humano. No obstante, la tecnología de imagen térmica convierte dicha radiación, de distintas intensidades, en representaciones visuales sin requerir fuentes de iluminación externas. Esta característica permite mantener un desempeño robusto bajo diversas condiciones de luz y clima. Sin embargo, las imágenes infrarrojas presentan limitaciones inherentes, como la escasa

definición de texturas y la falta de información estructural o de contorno del objetivo (Lee et al., 2023; Yuan et al., 2024).

La radiación infrarroja de onda larga se ubica en el rango de 7 a 14 μm , mientras que la luz visible se encuentra entre 390 y 780 nm del espectro electromagnético. Gracias a esta diferencia espectral, los sensores infrarrojos pueden operar en condiciones adversas como humo, niebla o neblina, resultando particularmente útiles en escenarios donde los sensores ópticos visibles se ven limitados. No obstante, los arreglos de plano focal infrarrojo (IRFPA) de alta resolución siguen siendo costosos, y los sensores no refrigerados generan imágenes de baja resolución, muy por debajo de la definición alcanzada por las cámaras RGB de alta resolución (Zhang et al., 2023; Raimundo et al., 2021; Cascarano et al., 2020).

Cada tipo de cámara, refrigerada o no refrigerada, se emplea en función de la banda espectral IR en la que alcanza un mejor desempeño. La mayoría de los detectores no cubren el rango completo de radiación infrarroja correspondiente a las longitudes de onda largas. Por ello, la selección del detector debe realizarse considerando tanto su sensibilidad como su respuesta espectral. En aplicaciones de teledetección, la cámara debe ser capaz de registrar la radiación infrarroja del objetivo a través de la atmósfera, lo que implica que los detectores cuenten con curvas de respuesta adaptadas a las ventanas de baja atenuación atmosférica (Raimundo, Prieto, et al., 2021).

Las cámaras térmicas infrarrojas refrigeradas tienen un uso extendido en teledetección debido a su alta precisión. No obstante, presentan limitaciones asociadas a su tamaño, peso y consumo energético, lo que restringe su integración en vehículos aéreos no tripulados (RPAS) de pequeñas dimensiones. En contraste, las cámaras térmicas no refrigeradas, aunque más ligeras y económicas, presentan inconvenientes relacionados con la menor sensibilidad y precisión de los microbolómetros respecto a los sistemas refrigerados (Gomes et al., 2019).

En particular, las cámaras térmicas no refrigeradas con microbolómetros TEC-less (sin refrigeración termoeléctrica) no estabilizan el sensor a una temperatura constante, lo que provoca variaciones en la respuesta del dispositivo según la temperatura interna de la cámara. Este comportamiento debe considerarse en los modelos de calibración. Asimismo, aunque las cámaras no refrigeradas radiométricas ofrecen resultados útiles en aplicaciones de teledetección, suelen incorporar ruido en las imágenes derivado de errores del sistema de detección o de las condiciones ambientales. Por lo tanto, resulta indispensable realizar procesos de calibración adecuados para garantizar la fiabilidad de los datos obtenidos (Gomes et al., 2019).

2.8.1 Cámaras térmicas de microbolómetro

Las cámaras térmicas de microbolómetro disponen de un sensor térmico que al recibir la radiación infrarroja se calienta y cambia su resistencia eléctrica. Además, la ventaja de estos sensores es que pueden trabajar a temperatura ambiente y no necesitan refrigeración, por lo que son más económicas en comparación con las refrigeradas. Los conjuntos de microbolómetros, es decir, conjuntos de píxeles de microescala que detectan la temperatura mediante cambios de resistencia, han demostrado ser una base eficaz para la instrumentación de imágenes en tiempo real en frecuencias infrarrojas y de terahercios (Bolakris & Vazouras, 2024).

Los microbolómetros son arreglos de rectángulos pequeños apoyados en pequeñas patas que los aíslan térmicamente. Estos rectángulos, contruidos de óxido de vanadio o silicio amorfo, cambian su resistencia eléctrica a la incidencia de luz IR. Los microbolómetros son calentados directamente por la energía de los rayos infrarrojos de la banda larga de 8 a 12 micrómetros. La temperatura causa una variación de la resistencia proporcional a la energía IR recibida. Estos cambios son medidos y procesados para formar la imagen de la cámara (Bardalen et al., 2024).

Recientemente, se han vuelto ampliamente disponibles cámaras térmicas de bajo costo dirigidas al rango de infrarrojos de onda larga (LWIR) (8–14 μm), basadas

en conjuntos de microbolómetros (MBA) no refrigerado. El MBA normalmente se fabrica en un circuito de lectura CMOS (ROIC) de silicio (Bardalen et al., 2024). Y algunos conjuntos FPA se encuentran en dos tamaños: de 320x240 píxeles y más económico, de 160x120 píxeles, además de que se está trabajando en dispositivos de 640x480 píxeles (Bardalen et al., 2024). En la Figura 1 se muestra un boceto conceptual simplificado de un chip MBA-on-CMOS limitado (Bardalen et al., 2024).




Figura 1. Circuito integrado MBA-on-CMOS, Fuente: Bardalen et al. (2024).

Los píxeles de estas cámaras se fabrican con materiales cuya resistencia varía de manera significativa con la temperatura, siendo el óxido de vanadio y el silicio amorfo los más empleados. La energía térmica absorbida provoca el calentamiento o enfriamiento del píxel, y la variación de resistencia resultante se traduce en valores de temperatura del objetivo mediante un proceso de calibración (Bardalen et al., 2024).

Por otra parte, el concepto de microbolómetro integrado (MA), basado en estructuras multicapa de diferentes tamaños y con selectividad de polarización, constituye una línea de desarrollo reciente. En la Figura 2 se presenta una unidad periódica de la estructura absorbente bicapa (MIMIM), compuesta por una placa posterior de oro, una capa espaciadora continua de silicio y una capa dieléctrica discreta intercalada entre dos capas de nanotiras metálicas. La capa inferior se denomina “nanotiras de primera capa” y la superior “nanotiras de segunda capa”.

Esta asimetría estructural confiere a la arquitectura MIMIM la capacidad de absorber selectivamente la polarización transversal magnética (TM), mientras refleja la polarización transversal eléctrica (TE). La energía óptica absorbida se convierte en calor mediante la absorción de portadores libres en las nanoestructuras metálicas, lo que incrementa la temperatura de los microbolómetros subyacentes (J. Li et al., 2024).




Figura 2. Unidad periódica de la estructura MIMIM, Fuente: Li et al. (2024)

2.8.2 Cámaras térmicas de estado sólido enfriado.

La mayoría de las cámaras térmicas refrigeradas comercializadas actualmente utilizan un detector elaborado con antimoniuro de indio (InSb). Las cámaras refrigeradas funcionan realizando un recuento de los fotones de energía en una banda de onda específica, típicamente en la banda de IR de onda media de alrededor de 3-5 μm . Los fotones golpean los píxeles y se convierten en electrones que se almacenan en un capacitor de integración. El píxel se obtura electrónicamente abriendo o acortando el capacitor de integración (Figura 3) (Li et al., 2024).




Figura 3. Sensor sólido enfriado (FLIR), Fuente: Li et al. (2024)

Las cámaras que utilizan sensores refrigerados requieren un tiempo de enfriamiento antes de entrar en operación, si bien son más costosas, ofrecen mejor calidad de imagen que las no enfriadas (Prado, 2008). Los tiempos de integración típicos para objetos entre -20 y 350 °C con una cámara FLIR van de unos 6 ms a unos 50 μ s en función del modelo de cámara. Estos tiempos de integración cortos hacen posible medir con precisión objetos en movimiento (Li et al., 2024). Las cámaras están basadas en el efecto fotoeléctrico, son semiconductores que expuestos a la luz IR producen variación de corriente proporcional a la cantidad de luz recibida. Un esquema de funcionamiento se muestra en la Figura 4.




Figura 4. Efecto fotoeléctrico, Fuente: Li et al. (2024)

Los electrones son excitados por la luz IR pasando a la banda de conducción, lo cual genera un cambio en la conductividad, voltaje o corriente eléctrica del circuito. Dado que a temperatura ambiente los electrones pueden ser excitados y pasar a la banda de conducción, generando ruido, estos detectores deben enfriarse a temperaturas criogénicas, que de acuerdo al material con el que están contruidos, esa temperatura puede variar, siendo el rango típico de 4 a 110°K (Prado, 2008).

2.9 Super resolución y pansharpening en imágenes térmicas

El uso de cámaras térmicas con sensores sensibles a la radiación infrarroja de onda larga se ha incrementado significativamente en los últimos años. Sin embargo, a diferencia de los sensores del espectro visible (RGB), la resolución espacial de los sensores térmicos incluso en los modelos de cámaras térmicas más avanzados rara vez supera el rango de los megapíxeles (Raimundo, Medina, et al., 2021).

En teledetección, la resolución espacial suele diseñarse en equilibrio con otros parámetros, como la resolución espectral, el ancho de franja y la relación señal/ruido. Esto genera una demanda constante de métodos que permitan incrementar la resolución espacial de imágenes adquiridas de manera remota. En este contexto, la superresolución multisensor se presenta como una técnica eficaz para mejorar imágenes de baja resolución mediante su fusión con otras de alta resolución obtenidas con sensores complementarios (Yokoya, 2017).

El pansharpening es el enfoque más común de superresolución multisensor, una imagen multiespectral de baja resolución se fusiona con una imagen pancromática de alta resolución, produciendo una imagen combinada con mayor detalle espacial y coherencia espectral. Este método se ha consolidado en teledetección satelital, con múltiples algoritmos desarrollados a lo largo de tres décadas. Entre los más representativos destacan los métodos de sustitución de componentes, análisis multirresolución, enfoques geoestadísticos basados en kriging y, más recientemente, los métodos basados en representación dispersa (Yokoya, 2017).

Los métodos de super resolución pueden clasificarse en tres categorías: basados en interpolación, en reconstrucción y en aprendizaje. Los primeros (interpolación bilineal o bicúbica) son simples y rápidos, pero pueden generar distorsiones (ruido, bordes pixelados, pérdida de nitidez) en zonas con abundante información de alta frecuencia, por lo que no reproducen bien los detalles finos. Los métodos basados en reconstrucción incorporan conocimiento previo para resolver iterativamente una función objetivo, incluyendo algoritmos como la proyección sobre conjuntos convexos, la retroproyección iterativa y el máximo a posteriori (Zhang et al., 2020).

El desarrollo del aprendizaje profundo ha revolucionado la superresolución. Los modelos basados en redes neuronales convolucionales, como SRCNN (Dong, 2016), VDSR, FSRCNN, SRResNet o EDSR, han superado a los enfoques clásicos debido a su capacidad para aprender relaciones no lineales entre pares de imágenes de baja y alta resolución. Estas redes permiten reconstruir detalles finos y mejorar la percepción visual, con aplicaciones tanto en imágenes RGB como térmicas (Zhang et al., 2020; Zou et al., 2023). Variantes recientes, como CycleGAN-ResNet, PlantSR o el Deep Compendium Model (DCM), se han adaptado a la teledetección agrícola y a sensores térmicos, enfrentando desafíos como la alineación precisa entre modalidades y la preservación radiométrica (Rivadeneira et al., 2022).

En paralelo, el pansharpening hiperespectral busca mejorar la resolución espacial de imágenes hiperespectrales mediante la integración con imágenes de alta resolución, manteniendo la coherencia espectral (Zini et al., 2024; Han et al., 2024). Aunque los resultados recientes son prometedores, persisten limitaciones relacionadas con la disponibilidad de datos de entrenamiento y la complejidad de la adquisición simultánea de imágenes multiespectral y pancromática (Feng et al., 2024).

La mejora de la resolución térmica es especialmente desafiante, ya que pueden existir múltiples reconstrucciones alta resolución posibles para una misma imagen térmica baja resolución. No obstante, los avances recientes en visión

artificial y aprendizaje automático han permitido obtener resultados cada vez más precisos (Yun et al., 2024).

2.10 Modelos de aprendizaje automático para determinar el estado hídrico con imágenes térmicas

Las técnicas de visión artificial, integradas con algoritmos de aprendizaje automático, se han consolidado como un método robusto para la evaluación rápida y no destructiva del estado hídrico de los cultivos, un aspecto crucial en el sector agrícola debido a la importancia del agua como recurso (Jin et al., 2024). El aprendizaje automático (ML) se ha aplicado de manera creciente en diversas áreas, incluyendo el mejoramiento vegetal y la predicción de niveles de tolerancia a la sequía (Verslype et al., 2023).

Entre los métodos de ML más empleados para la identificación y clasificación de cultivos se encuentran las redes neuronales artificiales (RNA), las máquinas de soporte vectorial (SVM) y los bosques aleatorios (RF) (Asadi & Shamsoddini, 2024). Estos modelos se enmarcan en dos grandes categorías: aprendizaje automático tradicional (ML), que incluye algoritmos como RNA, SVM y RF; y aprendizaje profundo (DL), caracterizado por arquitecturas más complejas capaces de aprender representaciones jerárquicas directamente a partir de los datos, reduciendo así la necesidad de ingeniería de características (Chang et al., 2025).

Las Redes Neuronales Artificiales (RNA), tienen una arquitectura que le permite a cada neurona realiza cálculos de ponderación y sesgo sobre la información que recibe y luego la pasa a la siguiente capa ajustando los pesos neuronales. Este proceso permite a la red capturar relaciones no lineales complejas entre variables. Para generar neuronas se conectan a las de la siguiente capa con un peso determinado y, en cada neurona, la suma ponderada de las variables de entrada se transforma en un valor de salida a través de una función de activación (Pagano et al., 2025).

Las máquinas de soporte vectorial (SVM) son métodos de aprendizaje supervisado basados en funciones kernel, ampliamente utilizados en regresión y

clasificación por su capacidad de generalización y precisión. Han mostrado aplicaciones exitosas en agricultura, hidrología, meteorología y estudios ambientales (Chang et al., 2025).

Un Bosque Aleatorio es una colección de árboles aleatorios, específicamente, los Árboles de Decisión son algoritmos de Aprendizaje Automático (ML) que suelen elegirse por la simplicidad de su enfoque y representación visual: a partir del conjunto completo de características, cada rama del árbol selecciona una característica e intenta clasificar el punto de datos con respecto a las clases objetivo. Si la clasificación es posible, la rama termina en una hoja etiquetada por una clase específica o una distribución de probabilidad entre las clases. Si la clasificación aún no es posible, la rama continúa a una nueva rama con una nueva característica (Pagano et al., 2025).

En contraste, los modelos de aprendizaje profundo (DL), como las redes neuronales convolucionales, las redes de memoria a largo plazo y las unidades recurrentes cerradas, poseen capas más profundas que les permiten procesar grandes volúmenes de datos con alta precisión. Estos modelos han mostrado un desempeño superior al de los algoritmos de ML tradicionales, aunque presentan limitaciones importantes: requieren conjuntos de datos masivos, alta capacidad de cómputo, elevados costos y carecen de interpretabilidad, lo que restringe su aplicación directa en la toma de decisiones de riego (Chang et al., 2025; Jin et al., 2024).

El aprendizaje profundo es un subcampo del aprendizaje automático, cuyo objetivo es explorar varios niveles de representaciones distribuidas a partir de los datos de entrada. Un sistema de red de aprendizaje profundo tiene un espacio similar al de una red neuronal, excepto que busca superar las deficiencias de las redes neuronales. Algunas de las desventajas de las redes neuronales son su largo tiempo de ejecución, especialmente cuando se trabaja con imágenes grandes, la gran cantidad de parámetros de red y el sobreajuste. Por lo tanto, los métodos de aprendizaje profundo se desarrollaron con una mayor cantidad de capas intermedias y pueden aprender funcionalidades de nivel superior y

conceptos más abstractos a partir de los datos de entrada (Asadi & Shamsoddini, 2024).

Las redes neuronales convolucionales (CNN) se encuentran entre los principales métodos de aprendizaje profundo en los que se entrenan múltiples capas de manera óptima y desempeñan un papel importante en la investigación de clasificación de imágenes. El método CNN es popular para trabajar con características de alta dimensión, realizar operaciones de aprendizaje jerárquico y permitir la extracción automática de características. Este método aplica una operación de convolución a los píxeles de la imagen y crea una nueva característica, que se puede aplicar a capas en diferentes escenarios y es altamente generalizable (Asadi & Shamsoddini, 2024).

Melo et al., (2022), recopilaron imágenes térmicas de caña de azúcar y utilizaron un modelo de aprendizaje profundo para evaluar el déficit hídrico de la caña de azúcar. El modelo funcionó en la clasificación no destructiva del estrés hídrico de las plantas en comparación con la evaluación manual. Chandel et al. (2022) utilizaron cinco modelos de aprendizaje profundo para utilizar imágenes térmicas infrarrojas e imágenes RGB de trigo de invierno para la detección no destructiva del estrés hídrico. Los resultados muestran que la red ResNet50 es superior a otros modelos, con una precisión de discriminación del 96.9 y 98.4% bajo entrada de imagen térmica y RGB, respectivamente.

Rajwade et al. (2023) utilizaron el modelo de aprendizaje profundo para identificar el estrés hídrico basándose en imágenes infrarrojas visibles y térmicas del maíz, los resultados experimentales muestran que la precisión máxima del modelo DarkNet53 para el reconocimiento de estrés hídrico de imágenes RGB e infrarrojas térmicas es del 94.1 y 99.6%, respectivamente. A continuación, se muestra metodologías actuales sobre el uso de la inteligencia artificial y los modelos de aprendizaje automático para la determinación del estado hídrico en cultivos (Cuadro 4).

Cuadro 4. Trabajos de determinación de estrés hídrico utilizando modelos de aprendizaje.

Referencia (Título)	Modelos utilizados	Cultivo	Sensor / Rango de temperatura	Modelo con mejor desempeño	Principales resultados / hallazgos
Atencia-Payares et al., <i>Assessing Plant Water Status</i> (2025)	ML(RF,MSV), segmentación CNN/U-Net	Viñedo	Térmico & multispectral (canopy Tc comparada con medidas in-situ)	RF / deep segmentation (U-Net++)	Alta correlación entre índices térmicos RPAS y estado hídrico del viñedo; mejor rendimiento al combinar bandas térmicas + VNIR.
Pires et al., <i>Scalable thermal imaging and processing framework...</i> (2025)	U-Net++ (canopy segmentación) + pipelines de calibración	Viñedo	Termal (UAV)	U-Net++ (afinado)	Framework para segmentación y estimación de temperatura de dosel en imágenes térmicas inclinadas; mejora en la extracción de Tc confiable.
Liu et al., <i>Assimilating UAV observations and crop model simulations...</i> (2025)	Integración ML + modelos de cultivo (asimilación)	Varios	Multimodal (TIR + VNIR)	Modelos híbridos (asimilación + ML)	Propuesta de asimilación, modelo para monitoreo CWS; mejora en predicción de estrés frente a modelos empíricos.
Choi et al., <i>Application of multimodal data fusion and explainable AI...</i> (2025)	Multimodal fusion + XAI (RF, XGBoost, SHAP)	Maíz	Térmico + multispectral	RF / XGBoost (explicables)	Demuestra utilidad de fusión térmica + optica y XAI para entregar mapas accionables para riego.
Subeesh et al., <i>Water stress diagnosis in maize using CS-KELM</i> (2025)	CS-KELM (Cuckoo Search + KELM)	Maíz	Temperatura de dosel (tiempo real)	CS-KELM $R^2 = 0.93$	Diagnóstico rápido y preciso para riego de precisión (optimización de parámetros con búsqueda metaheurística).
Jin et al., <i>Application of deep learning based on thermal images...</i> (2024)	VGG16, ResNet-18, MobileNetV3, DenseNet-201, CSPdarknet53	Algodón	Termografía (20–40 °C)	MobileNetV3 Exactitud > 95 %	MobileNetV3 destacó en clasificación de niveles de estrés en algodón con termografía.

Dong et al., <i>Crop water stress detection based on UAV remote sensing systems</i> (review/analysis) (2024)	Revisión: RF, SVR, CNN, pansharpening, fusión	Varios	TIR + multiespectral	(revisión)	Revisión aplicada sobre sistemas RPAS: enfatiza fusión multisensor y calibración radiométrica para CWSI.
Bounoua et al., <i>ConvLSTM vs CNN-LSTM — water stress forecasting</i> (2024)	ConvLSTM, CNN-LSTM	Sistemas frutales	Serie temporales multiespectrales + térmicas	ConvLSTM $R^2 = 0.91$	ConvLSTM mejor captura dependencias espacio-temporales en predicción de estrés hídrico.
Kapari et al., <i>Comparing Machine Learning Algorithms for Estimating the CWSI</i> (2024)	Random Forest, SVR, ANN, etc.	Maíz / trigo	Multiespectral + térmico	RF $R^2 = 0.85$	RF robusto para estimar CWSI usando combinaciones de índices multiespectrales y TIR; importancia de red de variables (red edge, NIR, TIR).
Patra et al., <i>Explainable ViT + SVM for drought stress identification</i> (2024)	Vision Transformer (ViT) + SVM / ViT end-to-end	Papa	RGB + térmica (15–33 °C)	ViT + SVM Exactitud = 97 %	ViT + SVM ofrece alta precisión y mapas de atención explicativos para zonas de estrés.
Yadav et al., <i>Evaluation of CWSI of wheat using ML</i> (2024)	SVR, RF, ANN, MLR	Trigo	CWSI derivado de térmica (20–38 °C)	SVR RMSE = 0.05	SVR superó a otros modelos en estimación del CWSI para trigo en condiciones semiáridas.
Shao et al., <i>Prediction of maize crop coefficient from UAV multisensor...</i> (2023)	LR, PR, ER, RF, RFR, SVR, DNN	Maíz	Termografía + multiespectral (18–35 °C)	SVR y DNN $R^2 = 0.90$	Buena predicción del coeficiente de cultivo (Kc) a partir de sensores UAV; mejora programación del riego.
Wu et al., <i>Combining ML & multi-temporal temperature indices to estimate rice water status</i> (2023)	Random Forest, regresiones	Arroz	Índices de temperatura (22–38 °C)	Random Forest $R^2 = 0.78–0.88$ (según variable)	Serie temporales de temperatura + RF permitieron estimación precisa del estado hídrico del arroz.

Lu et al., <i>Observation with UAV thermal infrared imagery</i> (2022)	Varios (índices térmicos, regresiones)	Múltiples	Termografía alta resolución	Correlaciones con SWP / CWSI	Estimación de CWSI, transpiración rate y patrones espaciotemporales con termografía aérea.
Duarte-Carvajalino et al., <i>Estimation of water stress in potato using hyperspectral & thermal</i> (2021)	RF, MLP, CNN, SVM, XGBoost, AdaBoost	Papa	Hiperespectral + térmico (15–35 °C)	XGBoost $R^2 = 0.92$	Combinar hiperespectral y térmico mejora detección y cuantificación del estrés hídrico en papa.

Fuente: Elaboración propia.

En los últimos años, la estimación del estado hídrico del maíz ha evolucionado hacia enfoques integrados que combinan sensores térmicos en RPAS, técnicas de fusión de imágenes y modelos de aprendizaje automático, lo que ha permitido una caracterización más precisa y dinámica del estrés hídrico. La temperatura del dosel se ha consolidado como un indicador directo del estado fisiológico del cultivo (Zhang et al., 2019), y estudios recientes confirman que la combinación de imágenes térmicas con datos multiespectrales o RGB mejora sustancialmente la estimación de índices como el CWSI (Kapari et al., 2024).

En el ámbito agrícola, las cámaras termográficas se han consolidado como herramientas clave para la medición no invasiva de la temperatura del dosel, un parámetro estrechamente vinculado con el estado hídrico y fisiológico de los cultivos (Yun et al., 2024; Oz et al., 2025). Asimismo, el uso de vehículos aéreos no tripulados (RPAS) ha potenciado la obtención de imágenes térmicas, RGB y multiespectrales con alta resolución espacial y temporal, incluso en condiciones ambientales adversas (Wang et al., 2025; Marzahn et al., 2020).

Las revisiones más recientes también subrayan la importancia de garantizar una calibración radiométrica adecuada, una segmentación precisa del dosel con el fin de asegurar la comparabilidad y utilidad de las mediciones térmicas en la gestión del riego (Sharma et al., 2025). En este contexto, la superresolución térmica, implementada mediante algoritmos de fusión o técnicas de aprendizaje profundo, emerge como una herramienta eficaz para aumentar el detalle espacial de las imágenes térmicas, manteniendo la coherencia radiométrica y mejorando la detección de variaciones en la temperatura del dosel (Oz et al., 2025). La integración de estas imágenes de alta resolución con modelos de aprendizaje automático ha mostrado resultados prometedores en la predicción del estado hídrico.

Actualmente, la tendencia en teledetección agrícola se orienta hacia la fusión de datos (térmicos, RGB, multiespectrales y meteorológicos), la aplicabilidad de los modelos ML DL y la asimilación con modelos de cultivo, con el objetivo de

desarrollar sistemas automatizados y predictivos de riego de precisión (Dong, 2024).

La termografía infrarroja ofrece la ventaja de obtener mediciones sin contacto y generar mapas térmicos basados en la radiación emitida bajo el supuesto de cuerpo gris. Los avances recientes en sensores más sensibles y algoritmos de superresolución han ampliado su aplicabilidad en la teledetección agrícola (Marini et al., 2021). No obstante, la limitada resolución espacial de las cámaras térmicas sigue condicionando la precisión del análisis, restringiendo la diferenciación de órganos individuales y la modelación biofísica de alta fidelidad (Yun et al., 2024).

En este marco, la presente tesis se orienta a optimizar la estimación del estado hídrico del maíz mediante la integración de técnicas de superresolución térmica y aprendizaje automático, contribuyendo al desarrollo de metodologías innovadoras para la gestión sostenible del agua en la agricultura de precisión.

2.11 Bibliografía

- Abioye, E. A., Hensel, O., Esau, T. J., Elijah, O., Abidin, M. S. Z., Ayobami, A. S., Yerima, O., & Nasirahmadi, A. (2022). Precision Irrigation Management Using Machine Learning and Digital Farming Solutions. In *AgriEngineering* (Vol. 4, Issue 1, pp. 70–103). MDPI. <https://doi.org/10.3390/agriengineering4010006>
- Adet, L., Rozendaal, D. M. A., Tapi, A., Zuidema, P. A., Vaast, P., & Anten, N. P. R. (2024). Negative effects of water deficit on cocoa tree yield are partially mitigated by irrigation and potassium application. *Agricultural Water Management*, 296. <https://doi.org/10.1016/j.agwat.2024.108789>
- Ahmed, J. M., Haji, J., Jaleta, M., & Jemal, K. (2025). Drought and consumption impacts of climate-smart-agricultural practices adoption in drought prone area of Eastern Hararghe, Ethiopia. *Agricultural Water Management*, 318. <https://doi.org/10.1016/j.agwat.2025.109681>

- Asadi, B., & Shamsoddini, A. (2024). Crop mapping through a hybrid machine learning and deep learning method. *Remote Sensing Applications: Society and Environment*, 33. <https://doi.org/10.1016/j.rsase.2023.101090>
- Aziz, M., Khan, M., Anjum, N., Sultan, M., Shamshiri, R. R., Ibrahim, S. M., Balasundram, S. K., & Aleem, M. (2022). Scientific Irrigation Scheduling for Sustainable Production in Olive Groves. *Agriculture (Switzerland)*, 12(4). <https://doi.org/10.3390/agriculture12040564>
- Baffour-Ata, F., Guodaar, L., Atiah, W. A., & Larbi, R. N. M. (2025). Adoption of Climate-Smart Agriculture Among Smallholder Cashew Farmers in Jaman North, Ghana: Interventions, Determinants, and Barriers. *World Development Sustainability*, 100256. <https://doi.org/10.1016/j.wds.2025.100256>
- Baffour-Ata, F., Mensah, S. C., Kuutiero, R. P., Opoku, D. A., Agboto-Seguin, C. S., Sonful, E. A., Darkoh, C. A. P., Oteng, N. D., & Darkwah, E. (2025). Assessing climate-smart agricultural practices and socioeconomic determinants in Atwima Kwanwoma District, Ghana. *Scientific African*, 29. <https://doi.org/10.1016/j.sciaf.2025.e02916>
- Banerjee, K., & Krishnan, P. (2020). Normalized Sunlit Shaded Index (NSSI) for characterizing the moisture stress in wheat crop using classified thermal and visible images. *Ecological Indicators*, 110. <https://doi.org/10.1016/j.ecolind.2019.105947>
- Bardalen, E., Bouchouri, A., Akram, M. N., & Nguyen, H. V. (2024). Black Silicon as Anti-Reflective Structure for Infrared Imaging Applications. *Nanomaterials*, 14(1). <https://doi.org/10.3390/nano14010020>
- Berríos, P., Temnani, A., Zapata-García, S., Sánchez-Navarro, V., Zornoza, R., & Pérez-Pastor, A. (2024). Diversified cropping systems effect on the water status of mandarin trees under deficit irrigation: Citrus water status in diversified cropping systems. *Scientia Horticulturae*, 326. <https://doi.org/10.1016/j.scienta.2023.112724>

- Bijanzadeh, E., Moosavi, S. M., & Bahadori, F. (2022). Quantifying water stress of safflower (*Carthamus tinctorius* L.) cultivars by crop water stress index under different irrigation regimes. *Heliyon*, 8(3). <https://doi.org/10.1016/j.heliyon.2022.e09010>
- Billah, M. M., Rahman, M. M., Mahimairaja, S., Lal, A., Srinivasulu, A., & Naidu, R. (2025). Constraints and prospects of adoption of climate smart agriculture interventions: Implication for farm sustainability. *Climate Smart Agriculture*, 2(3), 100066. <https://doi.org/10.1016/j.csag.2025.100066>
- Bo, L., Guan, H., & Mao, X. (2023). Diagnosing crop water status based on canopy temperature as a function of film mulching and deficit irrigation. *Field Crops Research*, 304. <https://doi.org/10.1016/j.fcr.2023.109154>
- Bolaklis, C., & Vazouras, C. N. (2024). Absorption by a Layered Microbolometer Pixel's Active Element. *Computation*, 12(5). <https://doi.org/10.3390/computation12050108>
- Brar, A. S., Kaur, K., Sindhu, V. K., Tsolakis, N., & Srail, J. S. (2022). Sustainable water use through multiple cropping systems and precision irrigation. *Journal of Cleaner Production*, 333. <https://doi.org/10.1016/j.jclepro.2021.130117>
- Bwambale, E., Abagale, F. K., & Anornu, G. K. (2022). Smart irrigation monitoring and control strategies for improving water use efficiency in precision agriculture: A review. In *Agricultural Water Management* (Vol. 260). Elsevier B.V. <https://doi.org/10.1016/j.agwat.2021.107324>
- Carrasco-Benavides, M., Gonzalez Viejo, C., Tongson, E., Baffico-Hernández, A., Ávila-Sánchez, C., Mora, M., & Fuentes, S. (2022). Water status estimation of cherry trees using infrared thermal imagery coupled with supervised machine learning modeling. *Computers and Electronics in Agriculture*, 200. <https://doi.org/10.1016/j.compag.2022.107256>
- Chang, Y., Zhang, C., Huang, J., Chang, H., Wang, C., & Huo, Z. (2025). *Machine Learning for Reference Crop Evapotranspiration Modeling: A State-of-the-Art Review and Future Directions*. <https://doi.org/10.3390/agronomy>

- Chen, Y., Zhang, J. H., Chen, M. X., Zhu, F. Y., & Song, T. (2023). Optimizing water conservation and utilization with a regulated deficit irrigation strategy in woody crops: A review. In *Agricultural Water Management* (Vol. 289). Elsevier B.V. <https://doi.org/10.1016/j.agwat.2023.108523>
- Cortes, J. R., Benitez, I. B., Baldoza, B. J. S., Pardillo, C. A. R., Auxtero, K. M. A., Badec, K. P., & Varela, D. A. B. (2025). Climate-smart aquaculture: Innovations and challenges in mitigating climate change impacts on fisheries and coastal agriculture. In *Aquaculture and Fisheries*. KeAi Communications Co. <https://doi.org/10.1016/j.aaf.2025.08.009>
- Dong, M., Shen, H., Jia, P., Sun, Y., Liang, C., Zhang, F., & Hou, J. (2023). Calibration Method for Airborne Infrared Optical Systems in a Non-Thermal Equilibrium State. *Sensors*, 23(14). <https://doi.org/10.3390/s23146326>
- Elsayed, S., Elhoweity, M., Ibrahim, H. H., Dewir, Y. H., Migdadi, H. M., & Schmidhalter, U. (2017). Thermal imaging and passive reflectance sensing to estimate the water status and grain yield of wheat under different irrigation regimes. *Agricultural Water Management*, 189, 98–110. <https://doi.org/10.1016/j.agwat.2017.05.001>
- ElSheikh, A., Abu-Nabah, B. A., Hamdan, M. O., & Tian, G. Y. (2023). Infrared Camera Geometric Calibration: A Review and a Precise Thermal Radiation Checkerboard Target. *Sensors*, 23(7). <https://doi.org/10.3390/s23073479>
- García Petillo, M. (2008). Manejo del riego: uso de instrumentos de medición de agua del suelo y del estado hídrico de los cultivos, presentación de casos de estudio incluso en riego deficitario. *Jornadas Sobre "Ambiente y Riegos: Modernización y Ambientalidad"*, 1–19.
- García-Tejero, I. F., Gutiérrez-Gordillo, S., Ortega-Arévalo, C., Iglesias-Contreras, M., Moreno, J. M., Souza-Ferreira, L., & Durán-Zuazo, V. H. (2018). Thermal imaging to monitor the crop-water status in almonds by using the non-water stress baselines. *Scientia Horticulturae*, 238, 91–97. <https://doi.org/10.1016/j.scienta.2018.04.045>

- Gebeyhu, B., & Markos, G. (2023). Assessment of soil mulching field management, and deficit irrigation effect on productivity of watermelon varieties, and AquaCrop model validation. *Heliyon*, 9(11). <https://doi.org/10.1016/j.heliyon.2023.e21632>
- Gheysari, M., Pirnajmedin, F., Movahedrad, H., Majidi, M. M., & Zareian, M. J. (2021). Crop yield and irrigation water productivity of silage maize under two water stress strategies in semi-arid environment: Two different pot and field experiments. *Agricultural Water Management*, 255. <https://doi.org/10.1016/j.agwat.2021.106999>
- Gomes, K. R., Lopez, D., Ortega, J. F., Ballesteros, R., Poblete, T., & Moreno, M. A. (2017, September 28). CALIBRACIÓN DE CÁMARAS TÉRMICAS NO REFRIGERADAS EMBARCADAS EN UAVs PARA APLICACIONES AGRONÓMICAS. <https://doi.org/10.7127/iv-inovagri-meeting-2017-res0240343>
- Ji, Z., Pan, Y., & Li, N. (2021). Integrating the temperature vegetation dryness index and meteorology parameters to dynamically predict crop yield with fixed date intervals using an integral regression model. *Ecological Modelling*, 455(May), 109651. <https://doi.org/10.1016/j.ecolmodel.2021.109651>
- Jiao, F., Ding, R., Du, T., Kang, J., Tong, L., Gao, J., & Shao, J. (2024). Multi-growth stage regulated deficit irrigation improves maize water productivity in an arid region of China. *Agricultural Water Management*, 297, 108827. <https://doi.org/10.1016/j.agwat.2024.108827>
- Jiménez, A. F., Cárdenas, P. F., & Jiménez, F. (2022). Intelligent IoT-multiagent precision irrigation approach for improving water use efficiency in irrigation systems at farm and district scales. *Computers and Electronics in Agriculture*, 192. <https://doi.org/10.1016/j.compag.2021.106635>
- Jin, K., Zhang, J., Wang, Z., Zhang, J., Liu, N., Li, M., & Ma, Z. (2024). Application of deep learning based on thermal images to identify the water stress in

- cotton under film-mulched drip irrigation. *Agricultural Water Management*, 299. <https://doi.org/10.1016/j.agwat.2024.108901>
- Kganyago, M., Adjorlolo, C., Mhangara, P., & Tsoeleng, L. (2024). Optical remote sensing of crop biophysical and biochemical parameters: An overview of advances in sensor technologies and machine learning algorithms for precision agriculture. In *Computers and Electronics in Agriculture* (Vol. 218). Elsevier B.V. <https://doi.org/10.1016/j.compag.2024.108730>
- Li, J., Li, J., & Yi, F. (2024). Particle Swarm Optimization of Multilayer Multi-Sized Metamaterial Absorber for Long-Wave Infrared Polarimetric Imaging. *Micromachines*, 15(3). <https://doi.org/10.3390/mi15030319>
- López López, R., Arteaga Ramírez, R., Alberto Vázquez Peña, M., López Cruz, I., & Sánchez Cohen, I. (2009). Índice de Estrés Hídrico Como un Indicador del Momento de Riego en Cultivos Agrícolas * Water Stress Index as an Indicator of Irrigation Timing in Agricultural Crops. *Agricultura Técnica En México*, 35, 97–111.
- Luis Noriega-Navarrete Raquel Salazar-Moreno, J., & Lorenzo López-Cruz, I. (2022). *Revisión: modelos de crecimiento y rendimiento de maíz en escenarios de cambio climático*. <https://www.scopus.com>
- Luna-Flores, w, Estrada-Medina, H., Jiménez-Osornio, J. J., & Pinzón-López, L. L. (2012). EFECTO DEL ESTRÉS HÍDRICO SOBRE EL CRECIMIENTO Y EFICIENCIA DEL USO DEL AGUA EN PLÁNTULAS. *Terra Latinoamericana*, 30, 343-353.
- Ma, J., Ding, Y., Zhang, J., Bai, Y., Cui, B., Hao, X., Zheng, M., Ding, B., & Yang, S. (2024). Impact of “Dry Sowing and Wet Emergence” Water Regulation on Physiological Growth Characteristics and Water Productivity of Cotton Fields in Southern Xinjiang Province. *Agronomy*, 14(4), 734. <https://doi.org/10.3390/agronomy14040734>
- Melo, L. L. de, Melo, V. G. M. L. de, Marques, P. A. A., Frizzone, J. A., Coelho, R. D., Romero, R. A. F., & Barros, T. H. da S. (2022). Deep learning for

- identification of water deficits in sugarcane based on thermal images. *Agricultural Water Management*, 272. <https://doi.org/10.1016/j.agwat.2022.107820>
- Mondol, M. A. H., Zhu, X., Dunkerley, D., & Henley, B. J. (2022). Changing occurrence of crop water surplus or deficit and the impact of irrigation: An analysis highlighting consequences for rice production in Bangladesh. *Agricultural Water Management*, 269. <https://doi.org/10.1016/j.agwat.2022.107695>
- Musa, S. F. P. D., & Ariff Lim, S. (2025). Revitalising agriculture through climate change mitigation: a systematic literature review on smart technologies and sustainable practices. *International Journal of Climate Change Strategies and Management*, 17(1), 483–501. <https://doi.org/10.1108/IJCCSM-05-2024-0071>
- Noguera, M., Millán, B., Pérez-Paredes, J. J., Ponce, J. M., Aquino, A., & Andújar, J. M. (2020). A new low-cost device based on thermal infrared sensors for olive tree canopy temperature measurement and water status monitoring. *Remote Sensing*, 12(4). <https://doi.org/10.3390/rs12040723>
- Ouma, G., Wanyama, J., Kabenge, I., Jjagwe, J., Diana, M., & Muyonga, J. (2024). Assessing the effect of deficit drip irrigation regimes on crop performance of eggplant. *Scientia Horticulturae*, 325. <https://doi.org/10.1016/j.scienta.2023.112648>
- Pagano, A., Amato, F., Ippolito, M., De Caro, D., & Croce, D. (2025). A machine learning framework to estimate crop coefficient dynamics of citrus orchards. *Computers and Electronics in Agriculture*, 238. <https://doi.org/10.1016/j.compag.2025.110797>
- Prado, C. (2008). Cámaras térmicas. *RNDS, Revista Negocios de Seguridad*, , 36, 128–144.
- Ramirez-Builes, V. H., Küsters, J., Thiele, E., & Lopez-Ruiz, J. C. (2024). Physiological and Agronomical Response of Coffee to Different Nitrogen

- Forms with and without Water Stress. *Plants*, 13(10), 1387.
<https://doi.org/10.3390/plants13101387>
- Rodigheri, G., Fontana, D. C., da Luz, L. B., Dalmago, G. A., Schirmbeck, L. W., Schirmbeck, J., de Gouvêa, J. A., & da Cunha, G. R. (2024). TVDI-based water stress coefficient to estimate net primary productivity in soybean areas. *Ecological Modelling*, 490. <https://doi.org/10.1016/j.ecolmodel.2024.110636>
- Sagan, V., Maimaitijiang, M., Sidike, P., Eblimit, K., Peterson, K. T., Hartling, S., Esposito, F., Khanal, K., Newcomb, M., Pauli, D., Ward, R., Fritschi, F., Shakoor, N., & Mockler, T. (2019). UAV-based high resolution thermal imaging for vegetation monitoring, and plant phenotyping using ICI 8640 P, FLIR Vue Pro R 640, and thermomap cameras. *Remote Sensing*, 11(3). <https://doi.org/10.3390/rs11030330>
- Schlubach, J. (2021). Downscaling model in agriculture in Western Uzbekistan climatic trends and growth potential along field crops physiological tolerance to low and high temperatures. *Heliyon*, 7(5), e07028. <https://doi.org/10.1016/j.heliyon.2021.e07028>
- Seleiman, M. F., Al-Suhaibani, N., Ali, N., Akmal, M., Alotaibi, M., Refay, Y., Dindaroglu, T., Haleem Abdul-Wajid, H., & Leonardo Battaglia, M. (2021). *plants Drought Stress Impacts on Plants and Different Approaches to Alleviate Its Adverse Effects*. <https://doi.org/10.3390/plants>
- Shao, G., Han, W., Zhang, H., Zhang, L., Wang, Y., & Zhang, Y. (2023). Prediction of maize crop coefficient from UAV multisensor remote sensing using machine learning methods. *Agricultural Water Management*, 276. <https://doi.org/10.1016/j.agwat.2022.108064>
- Stagno, F., Brambilla, M., Roccuzzo, G., & Assirelli, A. (2024). Water Use Efficiency in a Deficit-Irrigated Orange Orchard. *Horticulturae*, 10(5), 498. <https://doi.org/10.3390/horticulturae10050498>

- Sun, Y., Wang, C., Chen, H. Y. H., & Ruan, H. (2020). Response of plants to water stress: A meta-analysis. In *Frontiers in Plant Science* (Vol. 11). Frontiers Media S.A. <https://doi.org/10.3389/fpls.2020.00978>
- Verslype, N. I., Nascimento, A. C. A. do, Musser, R. dos S., Caldas, R. M. de S., Martins, L. S. S., & Leão, P. C. de S. (2023). Drought tolerance classification of grapevine rootstock by machine learning for the São Francisco Valley. *Smart Agricultural Technology*, 4. <https://doi.org/10.1016/j.atech.2023.100192>
- Wang, M., Shi, W., Kamran, M., Chang, S., Jia, Q., & Hou, F. (2024). Effects of intercropping and regulated deficit irrigation on the yield, water and land resource utilization, and economic benefits of forage maize in arid region of Northwest China. *Agricultural Water Management*, 298. <https://doi.org/10.1016/j.agwat.2024.108876>
- Wu, Y., Jiang, J., Zhang, X., Zhang, J., Cao, Q., Tian, Y., Zhu, Y., Cao, W., & Liu, X. (2023). Combining machine learning algorithm and multi-temporal temperature indices to estimate the water status of rice. *Agricultural Water Management*, 289. <https://doi.org/10.1016/j.agwat.2023.108521>
- Yang, C., Zhang, W., Gu, H., Liu, A., Guo, Q., Chen, Y., Lu, J., Ren, T., Cong, R., Lu, Z., Zhang, Y., Liao, S., & Li, X. (2023). Field, plant, to leaf: A meta-analysis on crop water use efficiency response to potassium fertilization. *Journal of Hydrology*, 621. <https://doi.org/10.1016/j.jhydrol.2023.129578>
- Yang, X., Lu, M., Wang, Y., Wang, Y., Liu, Z., & Chen, S. (2021). Response mechanism of plants to drought stress. In *Horticulturae* (Vol. 7, Issue 3). MDPI AG. <https://doi.org/10.3390/horticulturae7030050>
- Yao, N., Li, Y., Liu, Q., Zhang, S., Chen, X., Ji, Y., Liu, F., Pulatov, A., & Feng, P. (2022). Response of wheat and maize growth-yields to meteorological and agricultural droughts based on standardized precipitation evapotranspiration indexes and soil moisture deficit indexes. *Agricultural Water Management*, 266(February). <https://doi.org/10.1016/j.agwat.2022.107566>

- Zeng, R., Lin, X., Welch, S. M., Yang, S., Huang, N., Sassenrath, G. F., & Yao, F. (2023). Impact of water deficit and irrigation management on winter wheat yield in China. *Agricultural Water Management*, 287. <https://doi.org/10.1016/j.agwat.2023.108431>
- Zhao, W., Liu, L., Shen, Q., Yang, J., Han, X., Tian, F., & Wu, J. (2020). Effects of water stress on photosynthesis, yield, and water use efficiency in winter wheat. *Water (Switzerland)*, 12(8). <https://doi.org/10.3390/W12082127>
- Zhou, Z., Majeed, Y., Diverres Naranjo, G., & Gambacorta, E. M. T. (2021). Assessment for crop water stress with infrared thermal imagery in precision agriculture: A review and future prospects for deep learning applications. In *Computers and Electronics in Agriculture* (Vol. 182). Elsevier B.V. <https://doi.org/10.1016/j.compag.2021.106019>

3. DESARROLLO DE CÁMARA TÉRMICA PARA RPAS UTILIZADA EN EL MONITOREO DEL ESTADO HÍDRICO DE CULTIVOS

MI. Juan J. Pérez-Paredes¹.

Dr. Gilberto de J. López-Canteñs^{2*}.

Dr. Ramón Arteaga-Ramírez³

Dr. Eugenio Romantchik-Kriuchkova²

Dr. Juan Carlos Olguín Rojas²

Dr. Ronald Ernesto Ontiveros-Capurata⁴

¹Universidad Autónoma Chapingo, Posgrado en Ingeniería Agrícola y Uso Integral del Agua. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

²Universidad Autónoma Chapingo, Departamento de Ingeniería Mecánica Agrícola. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

³Universidad Autónoma Chapingo, Departamento de Irrigación. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

⁴Instituto Mexicano de Tecnología del Agua, Paseo Cuauhnáhuac 8532 Colonia Progreso C.P. 62550 Jiutepec, Morelos, México.

Autor de correspondencia: alelopez10@hotmail.com

3.1 Resumen.

El monitoreo de cultivos y la evaluación del estado hídrico son fundamentales para optimizar el uso del agua y promover una producción agrícola sostenible. La medición de la temperatura del dosel mediante imágenes térmicas se ha consolidado como una técnica confiable para estimar el estado hídrico de las plantas; sin embargo, su adopción se ve limitada por el alto costo de las cámaras térmicas y los sistemas aéreos no tripulados (RPAS). Debido a lo anterior, se desarrolló una cámara térmica de bajo costo basada en el sensor infrarrojo MLX90640 de 32 x 24 pixeles y el microcontrolador Teensy 3.6, con capacidad

de almacenamiento en una tarjeta microSD. El dispositivo fue integrado en un RPAS y evaluado en un cultivo de maíz, comparando sus mediciones con un porómetro LI-COR LI-1600 (precisión ± 0.5 °C). Las imágenes térmicas fueron mejoradas mediante interpolación bicúbica y fusionadas con imágenes RGB para obtener imágenes con resolución de 640×480 píxeles que se procesaron y segmentaron apoyándose en imágenes binarias para aislar los píxeles correspondientes a la temperatura del dosel del cultivo. Posteriormente se compraron los valores de temperatura de las imágenes térmicas y el porómetro LI-COR LI-1600 en cada sitio de muestreo, con la Raíz del Error Cuadrático Medio (RMSE) de 0.74°C . Los resultados demuestran que la cámara térmica desarrollada ofrece una precisión adecuada, bajo costo (135 USD) y alta representatividad espacial, posicionándose como una herramienta prometedora para la monitorización térmica del dosel en aplicaciones de agricultura de precisión y gestión eficiente del recurso hídrico.

Palabras clave: Cámara térmica, sensores infrarrojos, temperatura del dosel, estrés hídrico, RPAS.

3.2 Abstract.

Crop monitoring and the assessment of water status are essential for optimizing water use and promoting sustainable agricultural production. Canopy temperature measurement through thermal imaging has become a reliable technique for estimating plant water status; however, its adoption is limited by the high cost of thermal cameras and unmanned aerial systems (UAS). Therefore, a low-cost thermal camera was developed based on the MLX90640 infrared sensor (32×24 pixels) and the Teensy 3.6 microcontroller, featuring data storage on a microSD card. The device was integrated into a UAS and evaluated in a maize crop, with its measurements compared to those obtained using a LI-COR LI-1600 porometer (accuracy ± 0.5 °C). Thermal images were enhanced using bicubic interpolation and fused with RGB images to generate 640×480 pixel images, which were processed and segmented using binary masks to isolate canopy temperature pixels. Subsequently, canopy temperature values from the thermal images and the LI-COR LI-1600 porometer were compared at each sampling site, yielding a Root Mean Square Error (RMSE) of 0.74 °C. The results demonstrate that the developed thermal camera provides adequate accuracy, low cost (135 USD), and high spatial representativeness, making it a promising tool for canopy thermal monitoring in precision agriculture and efficient water resource management applications.

Key words: Thermal camera, infrared sensors, canopy temperature, water stress, UAV.

3.3 Introducción.

La agricultura de precisión y el riego inteligente son estrategias clave para optimizar el uso de los recursos hídricos, al permitir una aplicación controlada de agua en el momento, cantidad y lugar adecuado, favoreciendo una producción agrícola sostenible (Bwambale et al., 2022; Jiménez et al., 2022). El monitoreo del estado hídrico de los cultivos es esencial para mantener la productividad y la calidad, ya que indicadores fiables de estrés hídrico no solo describen la disponibilidad de agua en las plantas, sino que también permiten predecir los efectos del riego deficitario en el rendimiento (Noguera et al., 2020; Abioye et al., 2022).

La eficiencia en el uso del agua se logra mediante la integración de un manejo agronómico adecuado con tecnologías de alta precisión que facilitan el seguimiento de parámetros fisiológicos durante todo el ciclo de cultivo (Melo et al., 2022; Jiménez et al., 2022). No obstante, los métodos convencionales como tensiómetros, psicrómetros o mediciones de conductancia estomática y potencial hídrico presentan limitaciones por su costo, necesidad de personal especializado y baja escalabilidad (Ouma et al., 2024; Bo et al., 2023). Por ello, se requieren optimizar y mejorar las técnicas para el reconocimiento de estrés hídrico, que respalden la gestión del riego de precisión, disminuyendo el daño de la producción y la pérdida de rendimiento (Bijanzadeh et al., 2022b).

En este contexto, estudios han demostrado que la temperatura del dosel de las plantas se puede utilizar para detectar niveles moderados a severos de estrés hídrico en los cultivos (Gheysari et al., 2021; García-Tejero et al., 2018; Bo et al., 2023).

La relación entre la temperatura de las hojas y la regulación estomática establece que cuando un cultivo posee un suministro de agua adecuado aumenta la conductancia estomática y por lo tanto mejora la transpiración de las hojas generando una disminución de temperatura debido al enfriamiento por la evaporación del agua, ya que al perderse agua a través de los estomas se reduce

la temperatura (Gheysari et al., 2021). Por otro lado, las plantas con un déficit hídrico reducen la conductancia estomática de la hoja y la tasa de transpiración, en consecuencia, aumenta la temperatura del dosel, ya que no se produce disipación de calor por evaporación, alterando el balance energético de la planta (Noguera et al., 2020; Sagan et al., 2019).

Por lo anterior, la temperatura de las hojas que transpiran debe ser cercana a la temperatura del aire, mientras que en el caso de las estresadas debe ser mayor. Este es el supuesto que permite estimar el estrés hídrico a través de la temperatura del dosel (Bijanzadeh et al., 2022; López López et al., 2009).

La obtención de imágenes radiométricas infrarrojas constituye una herramienta valiosa en aplicaciones de teledetección para la agricultura de precisión, ya que permite el monitoreo del riego, la evaluación del estado fisiológico de los cultivos y la estimación del rendimiento. En este contexto, las cámaras IR no radiométricas, no refrigeradas y de bajo costo han emergido como alternativas viables para nuevas implementaciones en la gestión agrícola (Paciolla et al., 2025).

Las cámaras infrarrojas, permiten medir cambios sutiles en la temperatura del dosel mediante la radiación de onda larga emitida (Sagan et al., 2019). Su implementación en vehículos aéreos no tripulados (RPAS) posibilita la obtención de mapas espaciales y temporales con alta resolución (Wu et al., 2023; García-Tejero et al., 2018). Permitiendo comprender con mayor precisión la variabilidad de las condiciones hídricas y fisiológicas de los cultivos, así como de las características del suelo (Oz et al., 2025; Wu et al., 2023) .

Actualmente se distinguen dos tecnologías principales: las cámaras refrigeradas (FLIR) de alta precisión radiométrica, pero con elevado costo, peso y consumo energético que limitan su integración en plataformas aéreas ligeras; y las no refrigeradas (microbolómetros), más económicas, ligeras y adaptadas al uso agrícola, aunque con menor sensibilidad y exactitud (Dong et al., 2023; Oz et al., 2025; Gomes et al., 2017).

En el contexto de los sistemas fotoeléctricos infrarrojos multibanda aerotransportados, existen dos consideraciones. En primer lugar, debido a las limitaciones de espacio y potencia en la plataforma aérea, estos sistemas están diseñados para ser extremadamente compactos. En segundo lugar, el instrumento óptico dentro del canal IR exhibe una alta emisividad, lo que resulta en una importante radiación parásita interna que influye en gran medida en la señal de radiación recibida por el conjunto de plano focal infrarrojo (Dong et al., 2023).

El uso de cámaras termográficas de bajo costo puede reducir las barreras para la introducción de la termografía en la investigación y la producción agrícola (Yun et al., 2024) . Si bien el costo, la resolución de las cámaras y la precisión de vuelo de los RPAS siguen siendo factores limitantes, los sensores de matriz infrarroja han permitido mejorar la precisión de las mediciones hasta 0.5 °C y reducir significativamente los costos (Noguera et al., 2020).

Cada tipo de cámara refrigerada o no refrigerada se selecciona en función de la banda infrarroja (IR) en la cual alcanza un mejor desempeño. La mayoría de los detectores no cubre el rango IR completo (aproximadamente 900 a 1400 μm , correspondiente a las ondas largas). Por ello, la elección del detector depende de la aplicación específica, considerando tanto su respuesta a la longitud de onda como su sensibilidad. Además, en aplicaciones de teledetección, los detectores deben estar adaptados a la ventana de baja atenuación atmosférica para garantizar la fiabilidad de las mediciones.

En este contexto, el presente trabajo tiene como objetivo desarrollar una cámara térmica de bajo costo basada en un microcontrolador Teensy 3.6 y un sensor infrarrojo MLX90640 de 768 píxeles para el sensado del estrés hídrico en cultivos agrícolas. El sistema se integró en una plataforma RPAS para adquirir información georreferenciada de la temperatura del dosel y evaluar el estado hídrico de los cultivos, aportando una herramienta accesible para la gestión de riego de precisión.

3.4 Materiales y métodos.

Se desarrolló un dispositivo de cámara térmica de bajo costo para la medición de la temperatura del dosel de cultivos agrícolas y la monitorización del estado hídrico (Figura 5). El sistema se basa en un sensor infrarrojo MLX90640 de SparkFun, una matriz térmica de 32×24 píxeles (768 píxeles en total), que permite obtener información de temperatura de superficies a partir de la radiación térmica emitida por los objetos en función de su emisividad

El sensor infrarrojo MLX90640 corresponde a una termopila de tipo transductor electrónico que convierte la energía térmica en una señal eléctrica, operando bajo el principio de que todo cuerpo emite radiación térmica en la región del infrarrojo lejano (Elsayed et al., 2017; Paciolla et al., 2025).

Para el procesamiento de datos se empleó la placa de desarrollo Teensy 3.6, equipada con un procesador de 32 bits a 180 MHz, pines digitales con capacidad de interrupción y tolerancia de 3.3 V, además de conectividad USB. El microcontrolador fue programado en el entorno Arduino IDE con el complemento Teensyduino, lo que permitió calcular los valores correspondientes a los 768 píxeles del sensor MLX90640 y almacenar la información de temperatura en una tarjeta microSD, aprovechando el zócalo incorporado en la placa.




Figura 5. Representación de la cámara térmica.

3.4.1 Sensor infrarrojo térmico IR MLX90640

El sensor térmico infrarrojo de bajo costo seleccionado corresponde al circuito integrado MLX90640 (Melexis™). Este dispositivo fue elegido debido a su bajo costo y a que consiste en una matriz totalmente calibrada de 32×24 píxeles, capaz de realizar mediciones de temperatura remotas sin contacto, con resolución de 16 bits y con un rango de operación, de -40 a $85\text{ }^{\circ}\text{C}$, resultando adecuado para aplicaciones agrícolas

El sensor MLX90640 está conformado por 768 unidades de termopila, cada una integrada por múltiples termopares conectados en serie. Un termopar genera un voltaje proporcional a la diferencia de temperatura entre el punto de unión relacionado con la radiación IR del objeto observado y el punto de referencia de medición. La conexión en serie de estos termopares forma una termopila, lo que incrementa la magnitud de la señal y reduce el error en la detección de los pequeños voltajes generados (en el rango de milivoltios). Además, el sensor integra un amplificador de bajo ruido estabilizado por chopper y un convertidor analógico-digital de 16 bits, lo que permite digitalizar la señal térmica de manera precisa y eficiente.

El sensor está encapsulado en un paquete TO-39 de cuatro conductores, que contiene dos chips: el sensor infrarrojo térmico con su hardware de acondicionamiento de señal asociado, y un chip de memoria de solo lectura programable y borrable eléctricamente (EEPROM), utilizado para almacenar los datos de calibración (Noguera et al., 2020).

Existen dos configuraciones de campo de visión: $55^{\circ} \times 45^{\circ}$ y $110^{\circ} \times 75^{\circ}$ para el sensor MLX90640. Para este estudio se seleccionó la primera opción ($55^{\circ} \times 45^{\circ}$), dado que ofrece una captura más precisa de la zona central del dosel a una altura de vuelo de 10 m, evitando la distorsión geométrica asociada a lentes de gran angular (ojo de pez). Con esta configuración, el área de medición corresponde aproximadamente a 5m (horizontal) $\times$ 3.2m (vertical), con un tamaño de píxel de 29.4 cm/píxel.

3.4.2 Conexiones y diagrama electrónico

El circuito electrónico fue diseñado para garantizar la correcta alimentación y funcionamiento de la cámara térmica, cumpliendo con los requerimientos de voltaje y consumo de corriente de los dispositivos empleados: microcontrolador Teensy 3.6 (100 mA), sensor MLX90640 (23 mA) y diodos emisores de luz (leds, 10 mA).

El diagrama electrónico (Figura 6) muestra la alimentación y operación del sistema, que inicia con una batería LiPo de 4 celdas con un voltaje nominal de 14.8 V, encargada de suministrar energía a la controladora de vuelo. El voltaje de la batería se regula mediante un circuito eliminador universal de batería, que proporciona una salida de 5 V con una capacidad de hasta 4 A

El sistema de la cámara térmica integra un regulador Mini560, encargado de reducir el voltaje de entrada de 5 V a 3.7 V con una corriente máxima de 1 A, para alimentar al Teensy 3.6. Adicionalmente, se implementaron diodos 1N4007 en la salida con el fin de proteger el circuito frente a picos de corriente, voltajes inversos y reducir el ruido eléctrico presente en la señal principal.

El microcontrolador Teensy 3.6 suministra 3.3 V al sensor MLX90640 y controla dos LEDs indicadores: uno se enciende al establecerse la comunicación serial entre el microcontrolador y el sensor, mientras que el segundo parpadea cada vez que se realiza la captura de una imagen térmica.

Para la comunicación, los puertos SDA y SCL del sensor MLX90640 se conectaron a los pines 46 y 45 del Teensy 3.6, respectivamente, permitiendo la transferencia de datos mediante el protocolo I2C. El controlador y el sensor se comunican a través del bus I2C, el cual accede a la memoria interna donde se almacenan las lecturas de los sensores IR y PTAT (Noguera et al., 2020).

Por último, el puerto AUX OUT 1 (pin 51) de la controladora de vuelo Pixhawk 2.4.8 fue configurado para activar la cámara. Este puerto emite una señal PWM

de 1900 μ s durante 0.3 segundos al pin 30 del Teensy 3.6, lo que desencadena la captura de la información térmica y su almacenamiento en la tarjeta microSD.




Figura 6. Esquema de conexión.

Los componentes fueron integrados y soldados conforme al diagrama de conexión (Figura 6), en una caja protectora de plástico con dimensiones de 7 cm de largo, 4.8 cm de ancho y 2.3 cm de alto (Figura 7).




Figura 7. Ensamblado y conexión de los componentes: (a) ensamblado, (b) vista inferior, (c) vista superior.

3.4.3 Programación

El programa utilizado en la placa controladora del dispositivo fue desarrollado en el entorno de Arduino IDE (versión 1.8.12). Para la lectura del sensor y el almacenamiento de datos, se estableció la siguiente rutina:

Inicialización general: En esta etapa se configuran todos los elementos del dispositivo, incluyendo la tasa de transmisión a 9600 baudios y la asignación de puertos para la comunicación entre los diferentes componentes.

Inicialización de la tarjeta SD: Se verifica la presencia de la tarjeta en la ranura correspondiente. Posteriormente, se examinan los archivos existentes para determinar el último nombre de carpeta y se genera una nueva carpeta donde se almacenarán los datos adquiridos.

Lectura de datos de calibración del sensor: Se accede a los registros que contienen la información de calibración definida en el proceso de fabricación, incluyendo los valores de offset y pendiente de cada píxel. Estos datos se cargan en la memoria RAM del microcontrolador para agilizar el cálculo de corrección.

Lectura de registros de temperatura: Los datos brutos de temperatura obtenidos por el sensor IR se almacenan en la RAM del MLX90640. El controlador accede a dichos valores para cada píxel, así como a la temperatura interna del chip a través del registro PTAT, mediante comunicación I2C.

Corrección de temperatura: Los datos de temperatura sin procesar son corregidos para estimar los valores reales de la temperatura del dosel. Este procedimiento se desarrolla en tres pasos principales, descritos en la Datasheet del sensor MLX90640 (Melexis, 2019) y que son detallados a continuación:

1. **Corrección de la sensibilidad por píxel:** Los datos brutos de temperatura se operan junto con los valores de calibración almacenados para normalizar la respuesta del sensor y obtener $T_{O(i,j)}$, la temperatura correspondiente a cada píxel con la siguiente ecuación:

$$T_{O(i,j)} = \sqrt[4]{\frac{V_{IR(i,j)_COMPENSATED}}{\alpha_{(i,j)}} + (T_a + 273.15)^4} - 273.15$$

Donde:

- $\alpha_{(i,j)}$: Coeficiente de sensibilidad de cada píxel calculado a partir de los datos almacenados en la EEPROM.
 - T_a : Corrección por temperatura ambiente.
 - $V_{IR(i,j)_COMPENSATED}$: Señal IR compensada libre de ruido.
2. Corrección de la temperatura ambiente: La temperatura del sensor (temperatura ambiente) afecta las mediciones. Para corregir esto, el MLX90640 incluye un sensor PTAT para ajustar los valores de temperatura IR. La ecuación que calcula la temperatura ambiente se describe a continuación:

$$T_a = \frac{-K_{T1} + \sqrt{K_{T1}^2 - 4K_{T2}(V_{TH}(25) - PTAT_data)}}{2K_{T2}} + 25$$

Donde:

- K_{T1} y K_{T2} y V_{TH} : Constantes (fijadas durante la calibración en fábrica) almacenadas en la EEPROM del MLX90640 (definidas por el fabricante),
 - $PTAT_data$: Valor medido por el sensor de temperatura en chip.
3. Corrección de emisividad: El dispositivo mide la radiación térmica de un objetivo y estima su temperatura como la de un cuerpo negro. La emisividad corrige la medición considerando que el objeto en estudio no es un emisor de cuerpo negro perfecto. La emisividad se estableció en 0.98, ya que se ha reportado que este valor induce errores inferiores a 1 °C al medir la cobertura vegetal de diferentes cultivos hortícolas (Noguera et al., 2020).

$$V_{IR(i,j)_COMPENSATED} = \frac{V_{IR(i,j)_TGC_COMP}}{\varepsilon}$$

Donde:

- ε : Emisividad
- $V_{IR(i,j)_{TGC_COMP}}$: Valor térmico del píxel tras el proceso de compensación de sensibilidad y o set del píxel, tal y como se describe en la ficha técnica del MLX90640.

Captura de imagen: En la función de bucle del programa se adquieren las mediciones de temperatura proporcionadas por el sensor MLX90640. Posteriormente, se aplican las correcciones correspondientes según los tres pasos previamente descritos. Los datos se almacenan únicamente cuando se detecta un pulso PWM de 1900 μ s; en caso contrario, el sistema continúa actualizando las mediciones en tiempo real. Los registros se guardan en archivos de texto con extensión “.txt”, enumerados de manera secuencial ascendente. La Figura 5 ilustra la rutina completa, detallando las funciones ejecutadas por el microprocesador Teensy 3.6 y el sensor MLX90640.




Figura 8. Diagrama de funcionamiento de la cámara térmica.

3.4.4 Montaje en el Sistema de Aeronave Pilotada a Distancia (RPAS) y configuración de captura.

En este estudio se empleó un RPAS de tipo cuadricóptero equipado con una controladora de vuelo Pixhawk 2.4.8, la cual permite la ejecución de vuelos autónomos para la adquisición de imágenes georreferenciadas mediante GPS. La cámara térmica se montó en la parte frontal del vehículo aéreo (Figura 9), acompañada de una cámara RGB para la obtención de información complementaria sobre el estado del cultivo.




Figura 9. Vista superior (a), inferior (b), de la cámara montada en el RPAS.

Se programó la controladora de vuelo Pixhawk del RPAS con la versión ArduPilot 3.6.11 y se configuró mediante el software Mission Planner 3.75. Para la adquisición de datos, se asignó el disparador de la cámara al servo 10 del obturador del gimbal, estableciendo un pulso de 1900 μ s para activación y 1500 μ s para desactivación, con una duración de 0.3 s. Para la captura manual de imágenes se utilizó el canal 7 del radiocontrol, configurando el parámetro “CH7_OPT” con un valor de 9.

3.4.5 Evaluación de la Cámara térmica

Para la evaluación de la cámara térmica se realizaron 18 vuelos entre los meses de julio y septiembre del 2024, en un horario comprendido entre las 12:00 a.m. y las 2:30 p.m, en tres parcelas sembradas con maíz con una superficie de 0.8 Ha cada una (Figura 10), en el campo experimental “Ranchito”, de la Universidad

Autónoma Chapingo, en Texcoco, Estado de México, ubicado en las coordenadas: 19°49'72" N y -98°85'72" O.




Figura 10. Zona de estudio de vuelos fotogramétricos con el RPAS.

El software de planificación de misiones utilizado en el RPAS fue QGroundControl (Figura 11), el cual permitió configurar la velocidad de vuelo, la altura, la distancia entre líneas de vuelo, así como el traslape frontal y lateral de las imágenes. La velocidad de vuelo se estableció en 1.5 m/s, con un traslape frontal y lateral del 70%, a una altura de 10 m sobre el cultivo.



Figura 11. Configuración de vuelo en QGroundControl.

Adicionalmente se utilizó como referencia el porómetro LI-COR, Modelo LI-1600, de estado estacionario, diseñado para medir la conductancia estomática de hojas vivas, entre otros parámetros relacionados con la transpiración, la micro capacidad de intercambio de vapor de agua, radiación solar, humedad relativa y la temperatura del dosel de las plantas.

El sensor de temperatura de las hojas de las plantas del porómetro LI-1600 es un termopar de contacto ubicado en la cámara de medición tipo pinza (Figura 12), diseñado para estar en contacto directo con lo foliar para registrar la temperatura real de la hoja durante la medición de conductancia estomática. La cámara de medición también incorpora un sensor independiente para la temperatura interna de la cámara tipo pinza, que permite controlar y corregir los gradientes térmicos entre el aire de la cámara y la superficie foliar. En Cuadro 5 se presenta las especificaciones del porómetro para la medición de temperatura.

Cuadro 5. Especificaciones del porómetro LI-COR LI-1600 para la medición de temperatura de las hojas.

Parámetro	Rango de medición	Resolución	Exactitud
Temperatura de la hoja (Leaf Temperature)	0 – 64 °C	0.1 °C	± 0.5 °C
Temperatura del aire dentro de la cámara (Cuvette Temperature)	0 – 51 °C	0.2 °C	± 0.5 °C

Fuente: LI-COR, (1993)

El instrumento se utilizó para medir la temperatura del dosel del cultivo de maíz en alrededor de 40 sitios de muestreos por día (Figura 12), seguidamente se utilizó el RPAS para la adquisición de imágenes térmicas y RGB mediante vuelos autónomos.



Figura 12. Cámara tipo pinza.

3.4.6 Generación de imágenes térmicas y segmentación de la temperatura del dosel

Los archivos con extensión .txt fueron convertidos a imágenes en formato TIF mediante un script desarrollado en C++ y ejecutado en MATLAB 2021. Este procedimiento permitió procesar carpetas con archivos .txt que contenían 768 datos de temperatura cada uno, generando imágenes térmicas de 32×24 píxeles. La georreferenciación de las imágenes se realizó utilizando las coordenadas GPS correspondientes a los puntos de captura (waypoints) del plan de vuelo. Para asociar la información espacial a cada imagen, se empleó la librería ExifTool, un software de código abierto diseñado para la escritura de metadatos en archivos de imagen, asegurando la correcta vinculación entre la posición geográfica y las imágenes térmicas.

Adicionalmente, se adquirieron imágenes RGB (Figura 13a), mediante una cámara Firefly 8S de gran angular (90°), con el propósito de complementar la información térmica y permitir su comparación directa. Además, para optimizar la

resolución espacial, las imágenes térmicas iniciales (Figura 13b), fueron sometidas a un proceso de interpolación bicúbica y vecino más cercano, alcanzando una resolución de 640×480 píxeles (Figura 13c). Este procedimiento mejoró la calidad visual, y facilitó la fusión de imágenes térmicas con las imágenes RGB, lo que permitió una segmentación más precisa de la temperatura del dosel y del suelo.




Figura 13. a) Imagen RGB, b) Imagen térmica en falso color y c) Imagen térmica interpolada en falso color.

Generación de imágenes fusionadas:

Se generó una imagen final mediante la fusión de la información de la imagen térmica mejorada (Figura 13c) y con la luminancia del canal Y del espacio de color YCbCr, transformado de la imagen RGB. Este proceso se aplicó de manera diferenciada según la clasificación de cada región

- Regiones correspondientes al follaje: La luminancia moduló el rango de temperatura asignado a la planta, permitiendo conservar la variabilidad radiométrica capturada por la cámara térmica.
- Regiones correspondientes al suelo: Se utilizó directamente el rango térmico de esta categoría.

Este procedimiento permitió integrar de manera eficiente la información radiométrica de la cámara térmica con el contraste estructural proporcionado por las imágenes RGB, asegurando una estimación más confiable y precisa de la temperatura del dosel del cultivo de maíz y una diferenciación clara entre los valores correspondientes a cultivo y suelo

A partir de las nuevas imágenes, fusionadas térmica-RGB (Figura 14), se llevó a cabo la segmentación de los píxeles correspondientes al dosel del cultivo, con el fin de aislar las áreas asociadas a la temperatura foliar. Los valores obtenidos fueron extraídos y analizados para cada imagen correspondiente a las plantas de maíz en las que se realizaron mediciones directas de temperatura mediante el sensor LI-COR LI-1600, con el propósito de establecer una comparación entre ambos conjuntos de datos.




Figura 14. Imagen térmica fusionada en falso color.

3.5 Resultados y discusión

3.5.1 Caracterización de la cámara térmica desarrollada.

El circuito diseñado alimentó correctamente el sistema, proporcionando los niveles de corriente y voltaje requeridos, además de incluir protecciones contra corrientes inversas y picos de voltaje que pudieran dañar tanto al microcontrolador como al sensor. La programación implementada en el microcontrolador garantizó que, al recibir un pulso PWM superior a 1600 μ s, el sistema almacenara de manera automática los datos de temperatura correspondientes a los 768 píxeles del sensor en un archivo con extensión “.txt”. Cada archivo fue guardado en la tarjeta microSD dentro de una carpeta nueva, numerada de forma ascendente, lo que evitó la sobreescritura de archivos o carpetas y permitió un almacenamiento ordenado y confiable.

La resolución espacial de la cámara se determinó aplicando el teorema de Pitágoras, considerando la altura de vuelo y el ángulo de visión del sensor ($55^\circ \times 35^\circ$). De esta manera, se calcularon los valores de la distancia de muestreo en tierra (GSD) a diferentes alturas, los cuales se presentan en el Cuadro 6. Estos valores permiten establecer la relación entre la altura de operación y la resolución espacial alcanzada, lo que resulta crítico para definir la escala de análisis de la temperatura del dosel y del suelo.

Cuadro 6. Resolución de la cámara térmica desarrollada.

Altura (m)	largo (m)	ancho (m)	largo pixel (cm)	ancho pixel (cm)	Área (cm) ²	GSD (cm/pixel)
5	5.2	3.2	16.3	13.1	213.7	14.7
6	6.2	3.8	19.5	15.8	307.8	17.6
7	7.3	4.4	22.8	18.4	418.9	20.6
8	8.3	5.0	26.0	21.0	547.1	23.5
9	9.4	5.7	29.3	23.6	692.4	26.5
10	10.4	6.3	32.5	26.3	854.9	29.4
11	11.5	6.9	35.8	28.9	1034.4	32.3
12	12.5	7.6	39.0	31.5	1231.0	35.3
13	13.5	8.2	42.3	34.2	1444.7	38.2
14	14.6	8.8	45.5	36.8	1675.5	41.2
15	15.6	9.5	48.8	39.4	1923.4	44.1
16	16.7	10.1	52.1	42.0	2188.5	47.0
17	17.7	10.7	55.3	44.7	2470.6	50.0
18	18.7	11.4	58.6	47.3	2769.8	52.9
19	19.8	12.0	61.8	49.9	3086.1	55.9
20	20.8	12.6	65.1	52.5	3419.5	58.8

Fuente: Elaboración propia

El costo de materiales del dispositivo es de 135 USD (considerando únicamente los componentes electrónicos), tiene un valor significativamente inferior al de las cámaras térmicas comerciales con especificaciones similares. Por ejemplo, la FLIR ONE Edge Pro, diseñada para drones y con una resolución de 60×60 píxeles, tiene un costo aproximado de 450 USD, mientras que la FLIR Vue Pro R, con una resolución de 640×512 píxeles, alcanza un costo cercano a 5,000 USD (Noguera et al., 2020).

3.5.2 Imágenes térmicas.

Las imágenes térmicas generadas a partir del sensor MLX90640 permitieron identificar de manera confiable los valores de temperatura del cultivo. La interpolación bicúbica y vecino más cercano aplicada mejoró la resolución de 32x24 a 640x480 píxeles, lo que posibilitó la fusión con las imágenes RGB, integrando información estructural y mejorando la interpretación espacial de los datos. En particular, la transformación de las imágenes RGB al espacio de color YCbCr y la aplicación del método autoajustativo de Otsu sobre el canal Cr lograron una separación efectiva entre dosel y suelo. La máscara optimizada eliminó ruido y generó segmentaciones consistentes en las imágenes analizadas. Estos resultados coinciden con los reportados por Kamath et al, (2022) quienes destacan la utilidad del canal Cr para discriminar vegetación del fondo en plantas.

A partir del promedio de temperatura los valores de los 25 píxeles segmentados en las imágenes térmicas fusionadas, en donde se realizaron las mediciones con el porómetro LI-COR LI-1600, se calculó la Raíz del Error Cuadrático Medio (RMSE)= 0.74 °C y el Error Absoluto Medio (MAE)=0.57°C, lo cual confirma la consistencia de las mediciones obtenidas entre ambos métodos, además se elaboró la gráfica comparativa de temperaturas (Figura 15).




Figura 15. Temperaturas obtenidas con las imágenes térmicas y con el porómetro Licor LI-600

Los valores más altos de diferencia ($\Delta T > 1.4$ °C) se registraron en fechas del 15/09/2024 (1.6 °C) y el 20/07/2024 (1.48 °C), los cuales se asocian a variaciones ambientales registradas durante las mediciones, como fue el caso de cambios en la radiación incidente por nubosidad, que influyen en la temperatura del dosel. En contraste, los días 19/07/2024 (0.11 °C), 24/07/2024 (0.07 °C), 23/08/2024 (0.11 °C) y 10/08/2024 (0.01 °C) presentaron las menores diferencias entre ambos métodos, lo que refleja condiciones atmosféricas estables y una radiación solar uniforme durante el muestreo.

En términos generales, las temperaturas promedio del dosel registradas fueron de 27.71 °C para el porómetro LI-COR LI-1600 y de 27.20 °C para las imágenes térmicas. Los valores máximos fueron de 30.73 y 31.92 °C, respectivamente, mientras que los mínimos fueron de 24.15 y 23.09 °C.

3.6 Conclusiones

Se desarrolló una cámara térmica, basada en un microcontrolador Teensy 3.6 y un sensor infrarrojo MLX90640 de 768 píxeles, capaz de integrarse en

plataformas RPAS para el monitoreo de la temperatura del dosel en cultivos agrícolas. El peso total del dispositivo de 50 g lo convierte en una alternativa ligera y versátil, adecuada para su implementación en RPAS de pequeño y mediano tamaño sin afectar de forma significativa la autonomía de vuelo.

La metodología implementada permitió la obtención de imágenes térmicas georreferenciadas y su fusión mediante super resolución con información RGB, mejoró notablemente la resolución espacial y facilitó la segmentación precisa de las áreas de interés. Demostrando un alto nivel de confiabilidad al compararse con el porómetro LI-COR LI-1600, obteniendo un RMSE = 0.74°C y un MAE = 0.57°C , lo que respalda su precisión en la estimación de la temperatura foliar del cultivo de maíz.

En conjunto, la cámara térmica para el RPAS presenta una óptima relación entre resolución, peso, costo y tamaño, consolidándose como una herramienta accesible, eficiente y escalable para la adquisición de información térmica en agricultura de precisión, y como una alternativa viable frente a los sistemas comerciales de alto costo utilizados para la medición de la temperatura del dosel en cultivos agrícolas, para la evaluación del estrés hídrico.

3.7 Referencias

- Abioye, E. A., Hensel, O., Esau, T. J., Elijah, O., Abidin, M. S. Z., Ayobami, A. S., Yerima, O., & Nasirahmadi, A. (2022). Precision Irrigation Management Using Machine Learning and Digital Farming Solutions. In *AgriEngineering* (Vol. 4, Issue 1, pp. 70–103). MDPI. <https://doi.org/10.3390/agriengineering4010006>
- Bijanzadeh, E., Moosavi, S. M., & Bahadori, F. (2022). Quantifying water stress of safflower (*Carthamus tinctorius* L.) cultivars by crop water stress index under different irrigation regimes. *Heliyon*, 8(3). <https://doi.org/10.1016/j.heliyon.2022.e09010>
- Bo, L., Guan, H., & Mao, X. (2023). Diagnosing crop water status based on canopy temperature as a function of film mulching and deficit irrigation. *Field Crops Research*, 304. <https://doi.org/10.1016/j.fcr.2023.109154>

- Bolakakis, C., & Vazouras, C. N. (2024). Absorption by a Layered Microbolometer Pixel's Active Element. *Computation*, 12(5).
<https://doi.org/10.3390/computation12050108>
- Bwambale, E., Abagale, F. K., & Anornu, G. K. (2022). Smart irrigation monitoring and control strategies for improving water use efficiency in precision agriculture: A review. In *Agricultural Water Management* (Vol. 260). Elsevier B.V.
<https://doi.org/10.1016/j.agwat.2021.107324>
- Dong, M., Shen, H., Jia, P., Sun, Y., Liang, C., Zhang, F., & Hou, J. (2023). Calibration Method for Airborne Infrared Optical Systems in a Non-Thermal Equilibrium State. *Sensors*, 23(14). <https://doi.org/10.3390/s23146326>
- Elsayed, S., Elhoweity, M., Ibrahim, H. H., Dewir, Y. H., Migdadi, H. M., & Schmidhalter, U. (2017). Thermal imaging and passive reflectance sensing to estimate the water status and grain yield of wheat under different irrigation regimes. *Agricultural Water Management*, 189, 98–110.
<https://doi.org/10.1016/j.agwat.2017.05.001>
- García-Tejero, I. F., Gutiérrez-Gordillo, S., Ortega-Arévalo, C., Iglesias-Contreras, M., Moreno, J. M., Souza-Ferreira, L., & Durán-Zuazo, V. H. (2018). Thermal imaging to monitor the crop-water status in almonds by using the non-water stress baselines. *Scientia Horticulturae*, 238, 91–97.
<https://doi.org/10.1016/j.scienta.2018.04.045>
- Gheysari, M., Pirnajmedin, F., Movahedrad, H., Majidi, M. M., & Zareian, M. J. (2021). Crop yield and irrigation water productivity of silage maize under two water stress strategies in semi-arid environment: Two different pot and field experiments. *Agricultural Water Management*, 255.
<https://doi.org/10.1016/j.agwat.2021.106999>
- Gomes, K. R., Lopez, D., Ortega, J. F., Ballesteros, R., Poblete, T., & Moreno, M. A. (2017, September 28). *Calibración de cámaras térmicas no refrigeradas*

embarcadas en uavs para aplicaciones agronómicas. <https://doi.org/10.7127/iv-inovagri-meeting-2017-res0240343>

Jiménez, A. F., Cárdenas, P. F., & Jiménez, F. (2022). Intelligent IoT-multiagent precision irrigation approach for improving water use efficiency in irrigation systems at farm and district scales. *Computers and Electronics in Agriculture*, 192. <https://doi.org/10.1016/j.compag.2021.106635>

LI-COR, inc. (1989). *LI-1600 Steady State Porometer Service Manual* (Issue 82100030). <https://licor.app.boxenterprise.net/s/auoxn0ewmmka5r5inwcf>

LI-COR, inc. (1993). *LI-1600 Steady State Porometer Service Manual*. <https://licor.app.boxenterprise.net/s/2xxlgebebh5dagr1zsel>

López López, R., Arteaga Ramírez, R., Alberto Vázquez Peña, M., López Cruz, I., & Sánchez Cohen, I. (2009). *Índice de estrés hídrico como un indicador del momento de riego en cultivos agrícolas * water stress index as an indicator of irrigation timing in agricultural crops* (Vol. 35).

Melexis. (2019). *MLX90640 32x24 IR array, Datasheet*. <https://github.com/melexis/mlx90640->

Melo, L. L. de, Melo, V. G. M. L. de, Marques, P. A. A., Frizzzone, J. A., Coelho, R. D., Romero, R. A. F., & Barros, T. H. da S. (2022). Deep learning for identification of water deficits in sugarcane based on thermal images. *Agricultural Water Management*, 272. <https://doi.org/10.1016/j.agwat.2022.107820>

Noguera, M., Millán, B., Pérez-Paredes, J. J., Ponce, J. M., Aquino, A., & Andújar, J. M. (2020). A new low-cost device based on thermal infrared sensors for olive tree canopy temperature measurement and water status monitoring. *Remote Sensing*, 12(4). <https://doi.org/10.3390/rs12040723>

Ouma, G., Wanyama, J., Kabenge, I., Jjagwe, J., Diana, M., & Muyonga, J. (2024). Assessing the effect of deficit drip irrigation regimes on crop performance of

eggplant. *Scientia Horticulturae*, 325.
<https://doi.org/10.1016/j.scienta.2023.112648>

Oz, N., Sochen, N., Mendlovic, D., & Klapp, I. (2025). *End-to-end pipeline for simultaneous temperature estimation and super resolution of low-cost uncooled infrared camera frames for precision agriculture applications*. <http://arxiv.org/abs/2502.13985>

Paciolla, F., Popeo, G., Farella, A., & Pascuzzi, S. (2025). Agronomic Information Extraction from UAV-Based Thermal Photogrammetry Using MATLAB. *Remote Sensing*, 17(15). <https://doi.org/10.3390/rs17152746>

Sagan, V., Maimaitijiang, M., Sidike, P., Eblimit, K., Peterson, K. T., Hartling, S., Esposito, F., Khanal, K., Newcomb, M., Pauli, D., Ward, R., Fritschi, F., Shakoor, N., & Mockler, T. (2019). UAV-based high resolution thermal imaging for vegetation monitoring, and plant phenotyping using ICI 8640 P, FLIR Vue Pro R 640, and thermomap cameras. *Remote Sensing*, 11(3). <https://doi.org/10.3390/rs11030330>

Wu, Y., Jiang, J., Zhang, X., Zhang, J., Cao, Q., Tian, Y., Zhu, Y., Cao, W., & Liu, X. (2023). Combining machine learning algorithm and multi-temporal temperature indices to estimate the water status of rice. *Agricultural Water Management*, 289. <https://doi.org/10.1016/j.agwat.2023.108521>

Yun, H., Lo, S., Diepenbrock, C. H., Bailey, B. N., & Earles, J. M. (2024). *VisTA-SR: Improving the Accuracy and Resolution of Low-Cost Thermal Imaging Cameras for Agriculture*. <http://arxiv.org/abs/2405.19413>

4. MEJORAMIENTO DE IMÁGENES TÉRMICAS MEDIANTE SUPER RESOLUCIÓN E IMÁGENES RGB

Ml. Juan J. Pérez-Paredes¹.

Dr. Gilberto de J. López-Canteñas^{1*}.

Dr. Ramón Arteaga-Ramírez¹

Dr. Eugenio Romantchik-Kriuchkova¹

Dr. Juan Carlos Olguin Rojas²

Dr. Ronald Ernesto Ontiveros-Capurata⁴

¹Universidad Autónoma Chapingo, Posgrado en Ingeniería Agrícola y Uso Integral del Agua. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

²Universidad Autónoma Chapingo, Departamento de Ingeniería Mecánica Agrícola. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

³Universidad Autónoma Chapingo, Departamento de Irrigación. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

⁴Instituto Mexicano de Tecnología del Agua, Paseo Cuauhnáhuac 8532 Colonia Progreso C.P. 62550 Jiutepec, Morelos, México.

Autor de correspondencia: alelopez10@hotmail.com

4.1 Resumen.

Los sensores térmicos son una herramienta importante para el monitoreo del estado hídrico de los cultivos, sin embargo, tienen baja resolución debido a limitaciones en la miniaturización de los microbolómetros, esto ha impulsado la aplicación de técnicas de fusión y superresolución. Debido a lo anterior, la presente investigación evaluó diferentes métodos de superresolución integrando información radiométrica de imágenes térmicas con el detalle estructural de imágenes RGB de alta resolución, se realizaron vuelos en parcelas de maíz, ubicadas en la Universidad Autónoma Chapingo (19°49'72" N , 98°85'72" O), para ello, se utilizó un sistema aéreo no tripulado equipado con una cámara infrarroja

térmica de baja resolución (32x24 píxeles) y otra RGB de 16 MP. Para el mejoramiento de las imágenes térmicas se emplearon técnicas de superresolución guiada con apoyo de información estructural proveniente del canal visible (RGB). Inicialmente, las imágenes térmicas fueron redimensionadas mediante interpolación bicúbica y vecino más cercano para aumentar su tamaño a 640×480 píxeles. Posteriormente, se realizó la segmentación del dosel vegetal en el espacio de color YCrCb, utilizando el canal Cr y el umbral de Otsu para generar una máscara binaria del follaje, aislando la zona de interés asociada al dosel y al suelo para fusionarlas con el canal “Y” y generar imágenes de mayor resolución. Sobre las imágenes creadas y alineadas con el método de correlación mejorada, se implementaron y evaluaron tres modelos de fusión térmica guiada: Filtrado Guiado, Aumento de Resolución Bilateral Conjunto, Refinamiento Bilateral Conjunto. Los resultados mostraron una mejora progresiva en la calidad radiométrica y la coherencia espacial conforme aumentó la complejidad del modelo. El método de Refinamiento Bilateral Conjunto se consolidó el mejor desempeño global (MAE = 0.010, RMSE = 0.014, PSNR = 36.50 dB, SSIM = 0.957, ERGAS = 4.33, SAM = 2.00°, $r = 0.974$), integrando suavizado adaptativo y refinamiento bilateral, maximizando la fidelidad térmica y la relación estructural del dosel.

Palabras clave: Cámara térmica, sensores infrarrojos, temperatura del dosel, estrés hídrico, RPAS.

4.2 Abstract.

Thermal sensors are an important tool for monitoring crop water status; however, they exhibit low spatial resolution due to limitations in microbolometer miniaturization. This constraint has driven the application of image fusion and super-resolution techniques. Therefore, this study evaluated different super-resolution methods by integrating the radiometric information from thermal images with the structural detail from high-resolution RGB imagery. Flights were conducted over maize plots located at the Universidad Autónoma Chapingo (19°49'72" N, 98°85'72" W) using an unmanned aerial system equipped with a low-resolution infrared thermal camera (32 × 24 pixels) and a 16 MP RGB camera. For thermal image enhancement, guided super-resolution techniques were employed, supported by structural information from the visible (RGB) channel. Initially, thermal images were resized using bicubic and nearest-neighbor interpolation to 640 × 480 pixels. Subsequently, canopy segmentation was performed in the YCrCb color space using the Cr channel and Otsu's threshold to generate a binary foliage mask, isolating canopy and soil regions for fusion with the “Y” channel to produce higher-resolution images. Aligned images were processed using enhanced correlation matching, and three guided thermal fusion models were implemented and evaluated: Guided Filtering (GF), Joint Bilateral Upsampling (JBU), and Joint Bilateral Refinement (JBR). The results revealed a progressive improvement in radiometric quality and spatial coherence with

increasing model complexity. The Joint Bilateral Refinement method achieved the best overall performance (MAE = 0.010, RMSE = 0.014, PSNR = 36.50 dB, SSIM = 0.957, ERGAS = 4.33, SAM = 2.00°, $r = 0.974$), effectively combining adaptive smoothing and bilateral refinement to maximize thermal fidelity and canopy structural consistency.

Key words: Thermal camera, infrared sensors, canopy temperature, water stress, RPAS.

4.3 Introducción.

El uso de cámaras térmicas basadas en sensores infrarrojos de onda larga ha experimentado un crecimiento significativo en el monitoreo del estado hídrico de los cultivos agrícolas. Estas cámaras constituyen una tecnología de detección pasiva que capta la radiación emitida por los objetos, generando representaciones visuales asociadas a la distribución de temperatura (Raimundo et al., 2021; Cascarano et al., 2020). Entre sus principales ventajas se encuentran su resistencia a interferencias y la capacidad de discriminar objetivos respecto al fondo (Jiang et al., 2024; Raimundo et al., 2021). Sin embargo, en comparación con la imagen de luz visible (RGB), los sistemas infrarrojos presentan limitaciones en la resolución espacial, lo que afecta la calidad de las imágenes (Jiang et al., 2023a; Raimundo et al., 2021; Klapp et al., 2021) .

La baja resolución de los sensores térmicos se relaciona con restricciones tecnológicas en la miniaturización de los microbolómetros, lo que limita la capacidad de mejora en el corto y mediano plazo (Jiang et al., 2024; Raimundo et al., 2021). Adicionalmente, la calidad de las imágenes térmicas se ve afectada por la sensibilidad del sensor a factores ambientales como la temperatura y la humedad, que introducen variaciones en la radiación emitida o reflejada por los objetos (Batchuluun et al., 2023). Mientras que las cámaras térmicas de bajo costo resultan más accesibles, ofrecen resoluciones limitadas; por el contrario, los equipos de alta resolución mantienen precios elevados y un considerable consumo energético (Jiang et al., 2023a; Rivadeneira et al., 2022; Du et al., 2018).

Las imágenes térmicas suelen presentar desventajas como baja nitidez espacial, niveles significativos de ruido y pérdida de detalle, limitaciones derivadas en gran medida de las restricciones de los componentes electrónicos de las cámaras térmicas (Jiang et al., 2024; Du et al., 2018 ;Jiang et al., 2023a). Estas restricciones han impulsado el desarrollo de técnicas de fusión de imágenes, que integran la información radiométrica de los sensores térmicos con el contenido

estructural de las imágenes RGB, generando productos más nítidos y completos (Yuan et al., 2024; Du et al., 2018).

La superresolución de imágenes térmicas se define como un método computacional avanzado de visión por computadora cuyo propósito es generar imágenes de alta resolución a partir de una o varias imágenes de baja resolución (Panda et al., 2023; Nardelli et al., 2022; Cascarano et al., 2020).

En el caso de las imágenes termográficas, los algoritmos de super resolución deben cumplir con una doble exigencia: por un lado, mejorar la nitidez y los detalles de alta frecuencia; y por otro, preservar la fidelidad radiométrica de los valores asociados a cada píxel. Este aspecto es esencial, dado que la resolución espacial influye directamente en la estimación de temperaturas superficiales, particularmente cuando los objetos de interés presentan dimensiones similares o inferiores al tamaño de un píxel (Rivadeneira et al., 2022; Jiang et al., 2023a). En consecuencia, las imágenes térmicas reconstruidas no solo deben ser visualmente más detalladas, sino también radiométricamente precisas, garantizando información confiable para análisis cuantitativos y toma de decisiones (Cascarano et al., 2020; Feng et al., 2024).

Diversos enfoques han sido propuestos para abordar el problema de la superresolución. Entre ellos destacan los métodos de interpolación, reconstrucción regularizada y más recientemente, los algoritmos basados en aprendizaje automático y redes neuronales convolucionales profundas. Estas últimas han demostrado una alta capacidad para modelar de forma eficiente la relación entre imágenes de baja-alta resolución, lo que las ha posicionado como la corriente principal en esta área (Rivadeneira et al., 2022).

Los enfoques de super resolución en imágenes térmicas delimitados por Rivadeneira et al., (2022) y Cascarano et al., (2020) pueden clasificarse según distintos criterios:

- Dominio de aplicación: espacial o espectral.

- Estrategia de reconstrucción: interpolación, reconstrucción regularizada o aprendizaje automático.
- Número de imágenes de entrada: superresolución de una sola imagen, con una única imagen de baja resolución, o superresolución multimagen, que emplea múltiples imágenes de la misma escena.

En el campo de la super resolución de imágenes de teledetección, pueden diferenciarse dos enfoques principales: por un lado, los algoritmos que priorizan la mejora visual de la imagen (mejor definición, nitidez de bordes, aumento de escala), y, por otro lado, aquellos que además de mejorar la resolución buscan preservar la fidelidad radiométrica del sensor original (Mizuochi et al., 2022). Este doble enfoque de mejora espacial más preservación radiométrica, es particularmente relevante para aplicaciones agrícolas o de monitoreo térmico, donde los valores absolutos de temperatura o radiancia tienen significado fisiológico. Así, la selección del algoritmo debe considerar no solo la escala de ampliación, sino también la calibración radiométrica y la integridad física de los datos resultantes (Greza et al., 2024).

La termografía infrarroja ofrece la ventaja de realizar mediciones sin contacto, generando mapas térmicos basados en la radiación emitida bajo el supuesto de un comportamiento de cuerpo gris. Los recientes avances en el diseño de sensores más sensibles, junto con el desarrollo de algoritmos de reconstrucción de súper resolución, han ampliado significativamente su aplicabilidad en la teledetección agrícola (Marini et al., 2021). Sin embargo, la resolución espacial de las cámaras termográficas sigue siendo un factor crítico que condiciona la precisión del análisis. Las cámaras de baja resolución solo permiten distinguir estructuras a nivel de planta, dificultando la discriminación de órganos individuales como hojas, tallos, flores o frutos, lo que limita la evaluación de variaciones térmicas intraespecíficas y el desarrollo de modelos biofísicos de alta fidelidad (Yun et al., 2024).

Por lo tanto, la mejora de la calidad y resolución de las imágenes térmicas mediante la fusión con imágenes RGB de alta resolución, empleando técnicas de

superresolución que preserven la información radiométrica original, representa una estrategia efectiva para incrementar la resolución espacial de las imágenes térmicas. Debido a lo anterior, la presente investigación tiene como objetivo evaluar tres algoritmos de superresolución guiada: Filtrado Guiado, Aumento Bilateral Conjunto y Refinamiento Bilateral Conjunto, aplicados a imágenes térmicas para optimizar su resolución espacial a partir de la información estructural contenida en las imágenes RGB de alta resolución.

4.4 Materiales y métodos.

4.4.1 Adquisición de imágenes térmicas y RGB.

Para la adquisición de imágenes térmicas y RGB se realizaron 18 vuelos fotogramétricos en tres parcelas de maíz (*Zea mays L.*) con una superficie aproximada de 0.8 ha cada una (Figura 16), ubicadas en el campo experimental “Ranchito” de la Universidad Autónoma Chapingo, municipio de Texcoco, Estado de México (Latitud Norte: 19°49'72", Longitud Oeste: 98°85'72"). Las misiones de vuelos se llevaron a cabo en horario comprendido entre las 12:00 y 14:30 horas, a fin de minimizar los efectos de variabilidad térmica asociados a cambios de radiación y flujo de calor latente durante el día.




Figura 16. Zona de estudio de vuelos fotogramétricos con el RPAS.

En el estudio se empleó un RPAS de tipo cuadricóptero equipado con una controladora de vuelo Pixhawk 2.4.8, la cual permite la ejecución de vuelos autónomos para la adquisición de imágenes georreferenciadas mediante GPS. Se construyó una cámara térmica basada en el sensor infrarrojo MLX90640 de 32 x 24 píxeles, que se montó en la parte frontal del vehículo aéreo (Figura 17), junto con una cámara RGB de 16 Mega píxeles para la obtención de información complementaria del cultivo.




Figura 17. Vista superior (a), inferior (b), de la cámara térmica montada.

Los archivos de imágenes térmicas en formato TIFF generados a partir de los vuelos fueron georreferenciados utilizando las coordenadas GPS correspondientes a los puntos de captura (waypoints) del plan de vuelo. Para asociar la información espacial a cada imagen, se empleó la librería ExifTool, un software de código abierto diseñado para la escritura de metadatos en archivos de imagen, asegurando la correcta vinculación entre la posición geográfica y las imágenes térmicas.

La planificación de las trayectorias de vuelo se realizó mediante el software QGroundControl, siendo los parámetros de vuelo del RPAS: altura de vuelo de 10m sobre el dosel del cultivo, velocidad de desplazamiento de 1.5 m/s, traslape frontal y lateral de 70%, respectivamente. Estas condiciones garantizaron una adecuada cobertura espacial de información para los procesos posteriores de super resolución.

4.4.2 Procesamiento y mejoramiento de imágenes térmicas mediante interpolación bicúbica

Para la generación de imágenes de alta resolución (HR) a partir de imágenes térmicas de baja resolución (LR), se emplean comúnmente métodos de interpolación espacial, entre los cuales destacan las técnicas bilineal y bicúbica, por su capacidad para estimar los valores de píxel en función de las coordenadas adyacentes (Yuan et al., 2024).

Se desarrolló un procedimiento automatizado en MATLAB 2021, para incrementar la resolución espacial de las imágenes térmicas adquiridas con el sensor MLX90640, preservando la precisión radiométrica de los valores de temperatura y conservando la información georreferenciada, indispensable para el análisis espacial del dosel de cultivos. Este procedimiento utiliza un algoritmo de interpolación bicúbica y de vecino más cercano para mejorar la calidad de la imagen de 32 x 24 píxeles a 620 x 480 píxeles, lo que facilita la fusión de imágenes térmicas con las imágenes RGB, permitiendo una segmentación más precisa de la temperatura del dosel y del suelo. El flujo metodológico general comprende las siguientes etapas:

1. Selección y preparación de las imágenes:

Las imágenes térmicas originales, en formato TIFF de 32 x 24 píxeles georreferenciadas, fueron seleccionadas mediante una interfaz gráfica desarrollada en MATLAB. Cada imagen fue cargada en formato “double” con el fin de preservar la exactitud numérica de los valores de temperatura (°C) durante las operaciones de interpolación bicúbica y filtrado.

2. Interpolación bicúbica:

La interpolación bicúbica permite estimar los valores intermedios de píxeles, generando imágenes de alta resolución (HR) con transiciones suaves entre píxeles (Zhang et al., 2020). Este algoritmo fue propuesto por Robert G. Keys (1981), y es ampliamente utilizado en procesamiento digital de imágenes para el escalamiento y suavizado de datos espaciales. El método calcula el valor de un

nuevo píxel $I(x, y)$ a partir de los 16 píxeles vecinos más cercanos $I_{(i,j)}$ de la imagen original, según la expresión:

$$I(x, y) = \sum_{i=-1}^2 \sum_{j=-1}^2 w(i) w(j) I_{\text{original}}(x_i, y_j)$$

donde:

- $I_{\text{original}}(x_i, y_j)$: Píxeles vecinos de la imagen original.
- $w(i)$ y $w(j)$: Polinomios cúbicos de interpolación definidos como:

$$w(t) = \begin{cases} (a+2)|t|^3 - (a+3)|t|^2 + 1, & |t| \leq 1 \\ a|t|^3 - 5a|t|^2 + 8a|t| - 4a, & 1 < |t| < 2 \\ 0, & |t| \geq 2 \end{cases}$$

con $a = -0.5$ para la configuración estándar (bicúbica).

Este procedimiento permitió aumentar la resolución de imágenes térmicas de 32 x 24 píxeles a 320 x 240 píxeles, generando una representación térmica continua y suavizada, sin pérdida de información radiométrica relevante.

3. Escalado y suavizado:

Posteriormente, se aplicó una interpolación por vecino más cercano para conservar los valores discretos de temperatura y evitar la introducción de artefactos o ruido numérico en los bordes térmicos. Esta segunda fase duplica la resolución de 320 x 240 píxeles a 640 x 480 píxeles sin alterar los valores térmicos, ya que este método no genera nuevos valores, sino que replica píxeles adyacentes.

4. Almacenamiento y preservación de metadatos

Las imágenes procesadas se exportaron en formato TIFF (float32), conservando la precisión decimal de los valores de temperatura. Mediante el uso de ExifTool, se copiaron los metadatos originales, incluyendo la información GPS, para mantener la integridad geoespacial de las imágenes.


En el Cuadro 7 se muestra el aumento de resolución de la imagen original con los dos métodos de interpolación y la utilidad de cada uno.


Cuadro 7. Aumento de resolución con los métodos de interpolación.

Etapa	Método	Tamaño final de resolución	Detalles
Original	—	32 x 24	Datos reales del sensor
Interpolación 1	Bicúbica	320 x 240	Suaviza gradientes térmicos
Interpolación 2	Vecino más cercano	640 x 480	Aumenta tamaño sin distorsionar temperatura

En el Cuadro 8 se muestra el mejoramiento de las imágenes térmicas utilizando los métodos antes descritos. Permitió mantener la precisión radiométrica de los valores de temperatura originales, incrementó la resolución espacial, mejorando el detalle visual y preservó la información georreferenciada, fundamental para aplicaciones de mapeo térmico y en la agricultura de precisión.

Cuadro 8. Imágenes térmicas originales e interpoladas.





4.4.3 Fusión de imágenes térmicas y RGB

Después del mejoramiento radiométrico y espacial de las imágenes térmicas, se aplicó un procedimiento complementario orientado a la fusión térmica–RGB. Este proceso permitió mejorar la correspondencia espacial entre las imágenes capturadas por los sensores térmico y visible, incrementa la definición visual del dosel vegetal y preservar la consistencia radiométrica de la información térmica.

El procedimiento se implementó en Python 3.11, utilizando las librerías OpenCV, scikit-image, NumPy y Matplotlib. La estructura modular del código permitió automatizar las etapas de selección, alineación, segmentación, fusión térmica y análisis de desempeño, garantizando reproducibilidad y eficiencia computacional.

Selección e ingreso de datos:

Se diseñó una interfaz gráfica de usuario (GUI) mediante la biblioteca Tkinter, para seleccionar de forma interactiva las carpetas de entrada y salida. Este módulo automatizó la lectura de imágenes térmicas y de imágenes RGB, además de establecer la carpeta de destino para el almacenamiento de los resultados procesados. La implementación de esta interfaz aseguró una mayor trazabilidad de los datos, permitiendo al usuario identificar visualmente los pares térmicos–RGB antes de la fusión. Adicionalmente, se incorporaron rutinas de verificación de nombres y extensiones de archivo, garantizando la correcta correspondencia entre las imágenes de ambos sensores y reduciendo el riesgo de desalineaciones durante las etapas posteriores del flujo de trabajo.

Lectura y preprocesamiento de imágenes:

Cada par de imágenes térmica–RGB fue cargado utilizando las funciones de lectura de la librería scikit-image, lo que permitió trabajar directamente con matrices multicanal y preservar la integridad de los metadatos asociados. Las imágenes RGB fueron redimensionadas a una resolución estándar de 640×480 píxeles mediante la función `resize_and_crop`, que mantiene la proporción de aspecto original y recorta los bordes excedentes.

Para asegurar la correspondencia espacial entre ambas fuentes, el ajuste geométrico se realizó mediante un redimensionamiento directo de la imagen térmica hacia las dimensiones de la imagen RGB (Figura 18, a). Posteriormente, la imagen visible fue transformada al espacio de color YCrCb (Figura 18, b), favoreciendo una segmentación cromática más robusta frente a variaciones de iluminación (Samsuzzaman et al., 2024).




Figura 18. a) Imagen RGB (640 x 480), b) Espacio de color YCrCb.

Segmentación del dosel vegetal y del suelo:

La segmentación del dosel vegetal se realizó en el espacio de color YCrCb, empleando el canal Cr (crominancia diferencia-rojo) como variable discriminante (Figura 19a). Las imágenes correspondientes al canal Cr fueron normalizadas a 8 bits, y posteriormente se aplicó el método de Otsu, N. (1979), para separar las regiones asociadas al dosel vegetal y al suelo desnudo. El método de Otsu, es un algoritmo autoajustable, que determina automáticamente el umbral óptimo de separación entre ambas clases, optimizando la segmentación de manera objetiva

(Samsuzzaman et al., 2024). Esta diferenciación puede visualizarse claramente en el histograma de la imagen Cr (Figura 19b).




Figura 19. a) Canal Cr del espacio de color YCrCb, b) Histograma del canal Y

A partir del canal Cr y utilizando el método de Otsu, anteriormente mencionado, se generó una máscara binaria refinada mediante operaciones morfológicas de cierre, eliminación de objetos pequeños y relleno de huecos, con el propósito de mejorar la continuidad y precisión de las áreas correspondientes al dosel vegetal (Figura 20).




Figura 20. Imagen binaria filtrada obtenida del canal Cr y método de Otsu

Fusión térmica–RGB:

Finalmente, se generó una imagen térmica fusionada combinando los valores térmicos promedio de cada región con la luminancia (Y) del modelo de color YCrCb, mediante un proceso de interpolación lineal guiada por luminancia. Esta técnica permitió integrar la información térmica con la textura visible del dosel,

mejorando la representación espacial del cultivo y preservando las relaciones térmicas locales (Zhang, Niu, et al., 2019).

Este procedimiento, basado en los trabajos de Yu et al., (2024), Zhu et al., (2020) y Kopf et al., (2007), consiste en proyectar la luminancia de la imagen RGB sobre el rango térmico correspondiente a cada tipo de superficie (dosel y suelo), de acuerdo con la siguiente expresión:

$$I_T^{final}(x, y) = \begin{cases} T_{planta}^{min} + Y(x, y) \cdot (T_{planta}^{max} - T_{planta}^{min}), & (x, y) \in \text{mask}_{planta} \\ T_{suelo}^{min} + Y(x, y) \cdot (T_{suelo}^{max} - T_{suelo}^{min}), & (x, y) \in \text{mask}_{suelo} \end{cases}$$

Donde:

- $I_T^{final}(x, y)$: Valor de temperatura fusionado para el píxel (x, y) .
- $Y(x, y)$: Luminancia del píxel (x, y) obtenida del canal Y del espacio de color YCrCb.
- mask_{planta} : Máscara binaria correspondiente al dosel vegetal (región fría).
- mask_{suelo} : Máscara binaria correspondiente al suelo desnudo (región caliente).
- $T_{planta}^{min}, T_{planta}^{max}$: Temperaturas mínima y máxima del dosel, obtenidas de la segmentación térmica.
- $T_{suelo}^{min}, T_{suelo}^{max}$: Temperaturas mínima y máxima del suelo.


Este tipo de fusión se fundamenta en la correlación radiométrica entre la intensidad visible (Y) y la temperatura superficial, relación que ha sido validada en diversos estudios de teledetección agrícola (Ma et al., 2017; Li et al., 2021). La estrategia mejora la nitidez visual del mapa térmico sin alterar la escala radiométrica original.

De esta manera, la luminancia RGB se mapea al rango térmico correspondiente de cada tipo de superficie, generando una imagen híbrida de mayor resolución

visual y con consistencia radiométrica respecto a las observaciones térmicas originales (Zhu et al., 2020; Ma et al., 2017).

En el Cuadro 9 se muestra el proceso de fusión térmica–RGB, en el cual se integran la imagen térmica inicial (640 × 480 píxeles) y la segmentación del canal Y del espacio de color YCrCb, utilizando la máscara binaria generada a partir del canal Cr (640 × 480 píxeles). Este procedimiento permitió realizar la fusión de la imagen térmica con el canal Y, diferenciando las regiones correspondientes al dosel vegetal y al suelo desnudo, respectivamente.

Cuadro 9. Fusión de superficies: dosel y suelo



Finalmente, se fusionaron las dos superficies, correspondientes al dosel vegetal y al suelo desnudo, que previamente se encontraban separadas, con el fin de conformar la imagen térmica final (Figura 21a). Posteriormente, se segmentó la información del dosel aplicando nuevamente el método de Otsu sobre dicha imagen (Figura 21b), con el propósito de calcular la temperatura promedio del dosel.





Figura 21. a). Imagen térmica final (falso color), b) Histograma de la temperatura de la imagen térmica final.

Visualización y almacenamiento

Las imágenes resultantes fueron representadas en falso color (escala JET) para facilitar la identificación de gradientes térmicos. Cada imagen fusionada se guardó en formato TIFF de 32 bits en punto flotante (float32) utilizando la librería tiff file, preservando los valores decimales de temperatura para análisis posteriores. En el Cuadro 10 se muestran los diferentes tipos de imágenes que se fusionaron, térmica-RGB en los 18 vuelos, el espacio de color YCrCb, canal Y, Cr, la imagen fusionada final y la segmentación del dosel.

Cuadro 10. Fusión de imágenes térmicas y RGB

Imagen térmica falso color	Imagen RGB alineada	Espacio de color YCrCb	Canal Y de la imagen YCrCb
Cana Cr de la Imagen YCrCb	Mascara binaria de la imagen Cr	Imagen final térmica fusionada	Segmentación del dosel



4.4.4 Procesamiento de imágenes para super resolución

Alineación entre imágenes RGB y térmicas

Para asegurar la correspondencia espacial (alineación) entre las imágenes RGB y térmicas, se aplicó un proceso de registro de imágenes basado en el método de correlación mejorada propuesto por Evangelidis y Psarakis (2008). Este método busca estimar una transformación geométrica óptima que maximiza la correlación entre ambas imágenes, aun cuando presentan diferencias de intensidad o contraste, como ocurre entre los dominios visible e infrarrojo térmico.

En la implementación, la imagen RGB se utilizó como imagen de referencia (fija) y la imagen térmica como imagen móvil (a alinear). Previamente, la imagen RGB se convirtió a escala de grises para hacerla compatible con la térmica, ya que el algoritmo ECC requiere que ambas imágenes sean monoespectrales.

La estimación de la transformación se realizó mediante la función `cv2.findTransformECC()` de OpenCV, con los siguientes parámetros:

- Transformación geométrica: tipo afín (`MOTION_AFFINE`), que permite rotación, traslación, escala y cizallamiento.
- Matriz de inicialización: una matriz identidad de 2×3 (`np.eye(2,3)`), que representa una alineación inicial sin transformación.
- Criterio de convergencia: combinación de precisión (`EPS`) y número máximo de iteraciones (`COUNT`), con un límite de 5000 iteraciones y una tolerancia de 1×10^{-6} , lo que garantiza una convergencia estable y precisa.

Durante el proceso, el algoritmo optimiza iterativamente la matriz de transformación `warp_matrix` que maximiza el coeficiente ECC entre las imágenes. Una vez estimada dicha matriz, se aplicó la transformación afín a la imagen térmica mediante la función `cv2.warpAffine()`, ajustando su tamaño al de la imagen RGB y utilizando interpolación bilineal (`INTER_LINEAR`) junto con el mapeo inverso (`WARP_INVERSE_MAP`) para conservar la correspondencia espacial.

4.4.5 Modelos de super resolución

Para mejorar la calidad espacial de las imágenes térmicas generadas se aplicaron técnicas de superresolución guiada con imágenes RGB de mayor resolución. El procesamiento se desarrolló en Python (v3.10) utilizando las librerías OpenCV, NumPy, scikit-image y Matplotlib para la lectura, tratamiento y visualización de las imágenes. Se implementaron y compararon tres modelos de procesamiento descritos en el Cuadro 11.

Cuadro 11. Modelos utilizados para el mejoramiento de imágenes

Modelo	Clasificación	Principio	Tipo de mejora
--------	---------------	-----------	----------------

Guided Filter (GF)	Fusión tipo pansharpening guiado	Filtrado estructural guiado por luminancia RGB	Mejora visual y preservación de bordes y detalles en la imagen térmica.
Joint Bilateral Upsampling (JBU)	Superresolución guiada	Fusión bilateral con aumento de resolución	Preserva los bordes y mejora la nitidez espacial mediante una interpolación ponderada guiada por la textura de la imagen RGB
Joint Bilateral Refinement (JBR)	Superresolución avanzada	Refinamiento iterativo guiado por RGB	Alta coherencia térmica y estructural, que optimiza la reconstrucción térmica aprovechando las correlaciones espaciales y de intensidad entre ambas modalidades.

4.4.6 Método 1: Procesamiento y Fusión de Imágenes Térmicas y RGB mediante Filtrado Guiado (FG)

Una vez completada la etapa de fusión y alineación entre las imágenes térmicas y RGB, se aplicó un procedimiento de filtrado guiado que permite mejorar la continuidad espacial de las imágenes térmicas, reducir el ruido radiométrico y preservar la nitidez de los bordes del dosel vegetal (H. Li et al., 2024).

Se aplicó el filtro guiado descrito por He et al. (2010), el cual realiza un suavizado adaptativo preservando los bordes estructurales de una imagen al tomar otra como referencia o “guía”. En este caso, la imagen RGB convertida a escala de grises actuó como imagen guía I , mientras que la imagen térmica interpolada fue la imagen fuente p

El modelo local del filtro guiado se expresa como (H. Li et al., 2024) :

$$q_i = a_k I_i + b_k, \forall i \in \omega_k$$

Donde:

- q_i : Valor filtrado,
- I_i : Intensidad local en la imagen guía

- y a_k, b_k : Coeficientes lineales estimados en una ventana local ω_k de tamaño r .
- Dichos coeficientes se calculan como:

$$a_k = \frac{\text{cov}(I, p)}{\sigma_I^2 + \varepsilon}, b_k = \bar{p}_k - a_k \bar{I}_k$$

Donde:

- σ_I^2 : varianza local de I .
- $\text{cov}(I, p)$: covarianza entre ambas imágenes.
- ε : parámetro de regularización que controla el grado de suavizado.

En esta investigación se empleó un radio de 15 píxeles y un valor de $\varepsilon = 1 \times 10^{-6}$, parámetros que permitieron mantener los contornos definidos del cultivo y eliminar fluctuaciones térmicas espurias derivadas de la interpolación.

4.4.7 Método 2: Realce mediante filtrado bilateral conjunto (JBU)

Como segundo enfoque de mejora de resolución, se aplicó el filtrado bilateral conjunto, diseñado para incrementar la nitidez espacial de las imágenes térmicas fusionadas y reducir el desenfoque introducido durante la interpolación bicúbica. Este método utiliza la alta resolución de la imagen RGB como guía para refinar los bordes del dosel y mejorar la correspondencia estructural entre las imágenes térmica y RGB (Kopf et al., 2007).

El JBU se aplicó sobre la imagen térmica interpolada, utilizando como guía la imagen RGB en escala de grises. Matemáticamente, el filtrado se define como:

$$I_{JBU}(x) = \frac{1}{W_p} \sum_{x_i \in \Omega} G_s(\|x_i - x\|) G_r(|I_g(x_i) - I_g(x)|) I_t(x_i)$$

Donde:

- $I_{JBU}(x)$: Valor filtrado en el píxel x ,
- $I_t(x_i)$: Valores de la imagen térmica,
- $I_g(x_i)$: Intensidad de la imagen guía (RGB en gris),

- G_s y G_r : Funciones gaussianas espaciales y radiométricas, respectivamente,
- W_p : Factor de normalización que asegura que la suma de pesos sea 1.

Los parámetros utilizados fueron: diámetro de ventana $d = 21$, desviación estándar espacial $\sigma_{space} = 200$ y desviación estándar radiométrica $\sigma_{color} = 150$.

4.4.8 Método 3 Mejoramiento por superresolución guiada (JBR)

Como tercer procedimiento de mejora de las imágenes térmicas, se implementó un método de superresolución guiada, orientado a incrementar la nitidez espacial de las imágenes térmicas fusionadas y a reducir el desenfoque introducido durante la interpolación bicúbica. Este procedimiento aprovecha la alta resolución estructural de la imagen RGB como referencia o guía para refinar los bordes del dosel vegetal y mejorar la correspondencia geométrica entre las imágenes térmica y visible (Ma et al., 2021; Zhang et al., 2023).

El filtrado JBR se aplicó sobre la imagen térmica interpolada, utilizando la imagen RGB convertida a escala de grises como imagen guía. Matemáticamente, el filtrado bilateral conjunto se expresa como (Kopf et al., 2007):

$$I_{JBR}(x) = \frac{1}{W_p} \sum_{x_i \in \Omega} G_s(\|x_i - x\|) G_r(|I_g(x_i) - I_g(x)|) I_t(x_i)$$

Donde:

- $I_{JBR}(x)$: valor filtrado en el píxel x ,
- $I_t(x_i)$: Valores de intensidad de la imagen térmica,
- $I_g(x_i)$: Intensidad correspondiente de la imagen guía (RGB en escala de grises),
- G_s y G_r : Funciones gaussianas espacial y radiométrica, respectivamente,
- W_p : Factor de normalización que asegura que la suma total de los pesos sea igual a 1.

Los parámetros empleados fueron: diámetro de ventana $d = 21$, desviación estándar espacial $\sigma_{space} = 200$ y desviación estándar radiométrica $\sigma_{color} = 150$.

4.4.9 Evaluación de desempeño

Para evaluar la calidad radiométrica y estructural de las imágenes fusionadas térmicas-RGB obtenidas mediante los métodos GF, JBU y JBR, se realizó una comparación con la imagen RGB original, utilizando siete métricas de desempeño presentadas en el Cuadro 12.

Cuadro 12. Métricas de evaluación

Métrica	Tipo	Qué evalúa	Mejor valor
MAE (Error Absoluto Medio)	Error absoluto	Promedio de las diferencias absolutas entre los valores predichos y los observados.	0
RMSE (Raíz del Error Cuadrático Medio)	Error cuadrático	Magnitud promedio del error al cuadrado, penalizando más los errores grandes	0
PSNR (Relación Pico Señal-Ruido)	Relación señal-ruido	Relación entre la señal máxima posible y el ruido presente en una imagen; se usa para medir la calidad de reconstrucción o fusión.	Alto
SSIM (Índice de Similitud Estructural)	Estructural	Cuantifica la similitud perceptual entre dos imágenes considerando luminancia, contraste y estructura.	1
Pearson r (Correlación de Pearson).	Correlación	Relación lineal entre dos variables o imágenes, indicando qué tan estrechamente están correlacionadas.	1
ERGAS (Error Relativo Global Adimensional de Síntesis).	Distorsión relativa	Evalúa la calidad global de una imagen fusionada en términos de distorsión radiométrica.	Bajo
SAM (Mapeo del Ángulo Espectral).	Ángulo espectral	Mide el ángulo entre los vectores espectrales de dos imágenes; valores bajos indican mayor similitud espectral.	0°

Las métricas se calcularon para cada imagen procesada, evaluando la fidelidad radiométrica, la similitud estructural y la coherencia espectral. Asimismo, se

determinaron los valores promedio de cada métrica y la temperatura media del dosel, asegurando una evaluación robusta de la precisión, la consistencia visual y la coherencia espectral de las imágenes térmicas fusionadas.

4.5 Resultados y discusión

El método inicial de interpolación bicúbica y vecino más cercano permitió incrementar la resolución geométrica de las imágenes térmicas originales a 640 × 480 píxeles, requisito necesario para realizar las fusiones posteriores con las imágenes RGB. Aunque estos métodos mejoraron la resolución espacial aparente, no incorporaron información estructural proveniente de la imagen RGB, lo que provoca bordes suavizados y pérdida de detalle térmico como resultado del proceso de interpolación.

El proceso de fusión entre la imagen térmica interpolada y la banda Y del espacio de color YCrCb, transformado a partir de la imagen RGB, integró la información radiométrica proveniente del sensor MLX90640 con la información estructural y de luminancia de las imágenes RGB. El método propuesto generó una fusión térmica con alta coherencia espectral y precisión radiométrica, adecuada para aplicaciones de agricultura de precisión y monitoreo remoto del estrés hídrico.



Para los métodos de super resolución (FG, JBU y JBR), utilizados con las imágenes térmicas y las imágenes RGB, se presenta en el Cuadro 13 las imágenes mejoradas y sus respectivos histogramas de temperatura. Se observa un refinamiento progresivo en la distribución de los valores térmicos, con reducción de ruido, suavizado distorsiones y ruido, mejorando la delimitación de las zonas térmicas diferidas, por lo cual los histogramas evidencian una separación de temperaturas clara.

Cuadro 13. imágenes mejoras mediante FG, JBU y JBR e histogramas.



Imagen Final	Histograma
--------------	------------

Térmica



RGB





FG



JBU



JBR



En el Cuadro 14 se presentan las métricas de desempeño obtenidas, donde se observa una mejora progresiva en todos los indicadores al aplicar los métodos guiados. El modelo GF alcanzó valores de que refleja un realce moderado. Con

JBU, los errores se redujeron significativamente, evidenciando una alta correspondencia radiométrica y una preservación precisa de los bordes. Finalmente, el método JBR logró el mejor equilibrio entre nitidez visual y precisión térmica, consolidándose como el enfoque más robusto.

Cuadro 14. Métricas de desempeño de los 3 modelos y de la fusión RGB-térmica.

Método	MAE	RMSE	PSNR (dB)	SSIM	Pearson	ERGAS	SAM (°)
Guided Filter (GF)	0.058	0.079	21.967	0.733	0.870	19.727	9.59
Joint Bilateral Upsampling (JBU)	0.009	0.015	36.621	0.958	0.974	4.547	1.924
Joint Bilateral Refinement (JBR)	0.010	0.014	36.503	0.957	0.974	4.327	2.001

Los métodos de fusión guiada, como el Filtrado Guiado , el Aumento Bilateral Conjunto y el Refinamiento Bilateral Conjunto , mostraron un buen desempeño al aprovechar la estructura espacial de la imagen RGB como referencia. Estos resultados coinciden con estudios recientes de Kopf et al., (2007), Chen et al.,(2023) y Zhang et al., (2024), que destacan la eficacia de los enfoques bilaterales conjuntos y refinados en la mejora de imágenes infrarrojas de baja resolución. En particular, JBU y JBR permitieron una delimitación más precisa de los bordes del dosel.

En conjunto, los métodos guiados por información RGB, especialmente JBU y JBR, superaron notablemente a las técnicas tradicionales de interpolación, logrando una fusión térmica–RGB con mayor resolución espacial, coherencia radiométrica y preservación de detalles. Como resultado, las imágenes obtenidas presentan una mayor nitidez y fidelidad estructural, adecuadas para aplicaciones de monitoreo térmico y agricultura de precisión.

4.6 Conclusiones

Los tres modelos de fusión evaluados confirmaron la eficacia de la superresolución guiada para mejorar imágenes térmicas de baja resolución, aprovechando la información estructural del canal visible. Los resultados mostraron una mejora progresiva en la coherencia radiométrica y la definición espacial conforme aumentó la complejidad del modelo, destacando el Refinamiento Bilateral Conjunto (JBR) por su equilibrio entre nitidez visual y fidelidad térmica (PSNR > 36 dB, SSIM = 0.96).

La integración de información RGB mediante fusión bilateral guiada permitió incrementar la resolución térmica aparente sin alterar la señal radiométrica original, validando su aplicabilidad en monitoreo agrícola de precisión, detección temprana de estrés hídrico y análisis fenológico de los cultivos. En conjunto, estos resultados evidencian que la fusión multispectral guiada por luminancia representa un avance técnico significativo para optimizar el uso de sensores térmicos de bajo costo, como el MLX90640, en estudios de agricultura de precisión.

4.7 Referencias

- Batchuluun, G., Nam, S. H., Park, C., & Park, K. R. (2023). Super-Resolution Reconstruction-Based Plant Image Classification Using Thermal and Visible-Light Images. *Mathematics*, 11(1). <https://doi.org/10.3390/math11010076>
- Cascarano, P., Corsini, F., Gandolfi, S., Piccolomini, E. L., Mandanici, E., Tavasci, L., & Zama, F. (2020). Super-resolution of thermal images using an automatic total variation based method. *Remote Sensing*, 12(10). <https://doi.org/10.3390/rs12101642>
- Du, Q., Xu, H., Ma, Y., Huang, J., & Fan, F. (2018). Fusing infrared and visible images of different resolutions via total variation model. *Sensors (Switzerland)*, 18(11). <https://doi.org/10.3390/s18113827>
- Feng, Y., Yan, B., Jeon, S., & Yang, X. (2024). A hyperspectral pansharpening method using retrain transformer network for remote sensing images in UAV

communications system. *Wireless Networks*. <https://doi.org/10.1007/s11276-023-03611-2>

Greza, M., Bhattacharya, I., Hoegner, L., & Jutzi, B. (2024). GAN-Based Dual Image Super Resolution for Satellite Imagery Decreasing Radiometric Uncertainty. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10(3), 155–162. <https://doi.org/10.5194/isprs-annals-X-3-2024-155-2024>

Jiang, Y., Liu, Y., Zhan, W., Tang, Y., Li, J., & Liu, Y. (2024). Cross-modal texture transformer for thermal infrared reference-based super-resolution reconstruction. *Optics and Laser Technology*, 176. <https://doi.org/10.1016/j.optlastec.2024.110914>

Jiang, Y., Liu, Y., Zhan, W., & Zhu, D. (2023). Improved Thermal Infrared Image Super-Resolution Reconstruction Method Base on Multimodal Sensor Fusion. *Entropy*, 25(6). <https://doi.org/10.3390/e25060914>

Klapp, I., Yafin, P., Oz, N., Brand, O., Bahat, I., Goldshtein, E., Cohen, Y., Alchanatis, V., & Sochen, N. (2021). Computational end-to-end and super-resolution methods to improve thermal infrared remote sensing for agriculture. *Precision Agriculture*, 22(2), 452–474. <https://doi.org/10.1007/s11119-020-09746-y>

Kopf, J., Cohen, M. F., Lischinski, D., & Uyttendaele, M. (2007). Joint bilateral upsampling. *ACM SIGGRAPH 2007 Papers - International Conference on Computer Graphics and Interactive Techniques*. <https://doi.org/10.1145/1239451.1239547>

Lee, I. H., Chung, W. Y., & Park, C. G. (2023). Style transformation super-resolution GAN for extremely small infrared target image. *Pattern Recognition Letters*, 174, 1–9. <https://doi.org/10.1016/j.patrec.2023.08.013>

Li, H., Wang, S., Li, S., Wang, H., Wen, S., & Li, F. (2024). Thermal Infrared-Image-Enhancement Algorithm Based on Multi-Scale Guided Filtering. *Fire*, 7(6). <https://doi.org/10.3390/fire7060192>

- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 130, pp. 277–293). Elsevier B.V. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Marini, M., Bouzin, M., Sironi, L., D'Alfonso, L., Colombo, R., Di Martino, D., Gorini, G., Collini, M., & Chirico, G. (2021). A novel method for spatially-resolved thermal conductivity measurement by super-resolution photo-activated infrared imaging. *Materials Today Physics*, 18. <https://doi.org/10.1016/j.mtphys.2021.100375>
- Mizuochi, H., Iwao, K., & Yamamoto, S. (2022). Thermal remote sensing over heterogeneous urban and suburban landscapes using sensor-driven super-resolution. *PLoS ONE*, 17(4 April). <https://doi.org/10.1371/journal.pone.0266541>
- Moreno, H., Rueda-Ayala, C., Rueda-Ayala, V., Ribeiro, A., Ranz, C., & Andújar, D. (2025). Machine Learning-Powered Segmentation of Forage Crops in RGB Imagery Through Artificial Sward Images. *Agronomy*, 15(2). <https://doi.org/10.3390/agronomy15020356>
- Nardelli, B. B., Cavaliere, D., Charles, E., & Ciani, D. (2022). Super-Resolving Ocean Dynamics from Space with Computer Vision Algorithms. *Remote Sensing*, 14(5). <https://doi.org/10.3390/rs14051159>
- Panda, G., Kundu, S., Bhattacharya, S., & Routray, A. (2023). *LATIS: Lambda Abstraction-based Thermal Image Super-resolution*. <http://arxiv.org/abs/2311.12046>
- Raimundo, J., Medina, S. L. C., Prieto, J. F., & de Mata, J. A. (2021). Super resolution infrared thermal imaging using pansharpening algorithms: Quantitative assessment and application to uav thermal imaging. *Sensors (Switzerland)*, 21(4), 1–18. <https://doi.org/10.3390/s21041265>
- Rivadeneira, R. E., Sappa, A. D., Vintimilla, B. X., & Hammoud, R. (2022). A Novel Domain Transfer-Based Approach for Unsupervised Thermal Image Super-Resolution. *Sensors*, 22(6). <https://doi.org/10.3390/s22062254>

- Samsuzzaman, Reza, M. N., Islam, S., Lee, K. H., Haque, M. A., Ali, M. R., Cho, Y. J., Noh, D. H., & Chung, S. O. (2024). Automated Seedling Contour Determination and Segmentation Using Support Vector Machine and Image Features. *Agronomy*, 14(12). <https://doi.org/10.3390/agronomy14122940>
- Suárez, P. L., Carpio, D., & Sappa, A. D. (2024). Enhancement of guided thermal image super-resolution approaches. *Neurocomputing*, 573. <https://doi.org/10.1016/j.neucom.2023.127197>
- Yu, X., Huo, X., Qian, L., Du, Y., Liu, D., Cao, Q., Wang, W., Hu, X., Yang, X., & Fan, S. (2024). Combining UAV Multispectral and Thermal Infrared Data for Maize Growth Parameter Estimation. *Agriculture (Switzerland)*, 14(11). <https://doi.org/10.3390/agriculture14112004>
- Yuan, X., Zhang, B., Zhou, J., Lian, C., Zhang, Q., & Yue, J. (2024). Gradient residual attention network for infrared image super-resolution. *Optics and Lasers in Engineering*, 175. <https://doi.org/10.1016/j.optlaseng.2023.107998>
- Yun, H., Lo, S., Diepenbrock, C. H., Bailey, B. N., & Earles, J. M. (2024). *VisTA-SR: Improving the Accuracy and Resolution of Low-Cost Thermal Imaging Cameras for Agriculture*. <http://arxiv.org/abs/2405.19413>
- Zhang, L., Niu, Y., Zhang, H., Han, W., Li, G., Tang, J., & Peng, X. (2019). Maize Canopy Temperature Extracted From UAV Thermal and RGB Imagery and Its Application in Water Stress Monitoring. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.01270>
- Zhang, S., Huang, F., Liu, B., Zhong, H., Li, G., Chen, Y., & Wang, Z. (2020). Optimized calibration method for ultra-field dual bands cameras based on thermal radiation checkerboard. *Infrared Physics and Technology*, 108. <https://doi.org/10.1016/j.infrared.2020.103346>

5. DETERMINACIÓN DEL ESTADO HÍDRICO DEL MAÍZ MEDIANTE MODELOS DE APRENDIZAJE AUTOMÁTICO E IMÁGENES TÉRMICAS MEJORADAS MEDIANTE SUPER- RESOLUCIÓN

MI. Juan J. Pérez-Paredes¹.

Dr. Gilberto de J. López-Canteñas^{2*}.

Dr. Ramón Arteaga-Ramírez³

Dr. Eugenio Romantchik-Kriuchkova²

Dr. Juan Carlos Olguín-Rojas²

Dr. Ronald Ernesto Ontiveros-Capurata⁴

¹Universidad Autónoma Chapingo, Posgrado en Ingeniería Agrícola y Uso Integral del Agua. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

²Universidad Autónoma Chapingo, Departamento de Ingeniería Mecánica Agrícola. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

³Universidad Autónoma Chapingo, Departamento de Irrigación. Carretera México-Texcoco km 38.5, Chapingo, México, C. P. 56230, México.

⁴Instituto Mexicano de Tecnología del Agua, Paseo Cuauhnáhuac 8532 Colonia Progreso C.P. 62550 Jiutepec, Morelos, México.

Autor de correspondencia: alelopez10@hotmail.com

5.1 Resumen.

El maíz es el cultivo que ocupa la mayor superficie de siembra en México, con 7 millones de hectáreas. Por lo que el monitoreo de su estado hídrico es fundamental para optimizar el uso del agua y mejorar la eficiencia del riego. En esta investigación, se propone una metodología para la determinación del estado hídrico del maíz (*Zea mays* L.), integrando imágenes térmicas mejoradas mediante técnicas de superresolución y modelos de aprendizaje automático (ML).

Las imágenes térmicas, adquiridas con un sistema RPAS de bajo costo, se fusionaron con información RGB de alta resolución para incrementar el detalle espacial sin comprometer la fidelidad radiométrica. Se incorporaron mediciones fisiológicas y ambientales, incluyendo transpiración, conductancia estomática, temperatura del dosel, humedad relativa, radiación fotosintéticamente activa y contenido de agua del suelo a 20 y 40 cm de profundidad, como variables de referencia para la calibración y evaluación de los ML de regresión, clasificación supervisada y no supervisada. Los resultados mostraron que los modelos de Bosque Aleatorio (RF) y Potenciación del Gradiente Extrema (XGB) presentaron el mejor desempeño: RF con $R^2 = 0.97$, MAE = 0.37; RMSE = 1.18 y XGB con $R^2 = 0.96$, MAE = 1.51; RMSE = 0.31, capturando relaciones complejas no lineales entre variables ambientales y estrés hídrico. Por lo que La combinación de imágenes térmicas mejoradas mediante superresolución con modelos de aprendizaje automático genero una estrategia eficiente, no destructiva para monitorear el estrés hídrico en el cultivo de maíz.

Palabras clave: Estrés hídrico, Imágenes térmicas, Superresolución, Aprendizaje automático.

5.2 Abstract.

Maize is the crop with the largest cultivated area in Mexico, covering approximately 7 million hectares. Therefore, monitoring its water status is essential to optimize water use and improve irrigation efficiency. This study proposes a methodology for assessing the water status of maize by integrating thermally enhanced imagery using super-resolution techniques with machine learning (ML) models. Thermal images acquired with a low-cost RPAS system were fused with high-resolution RGB data to increase spatial detail without compromising radiometric fidelity. Physiological and environmental measurements—including transpiration, stomatal conductance, canopy temperature, relative humidity, photosynthetically active radiation, and soil water content at 20 and 40 cm depths—were incorporated as reference variables for the calibration and evaluation of regression, supervised, and unsupervised ML models. The results showed that the Random Forest (RF) and Extreme Gradient Boosting (XGB) models achieved the best performance: RF with $R^2 = 0.97$, MAE = 0.37, RMSE = 1.18; and XGB with $R^2 = 0.96$, MAE = 1.51, RMSE = 0.31, effectively capturing complex nonlinear relationships between environmental variables and water stress. The combination of thermally enhanced imagery through super-resolution and machine learning models proved to be an efficient and non-destructive strategy for monitoring water stress in maize crops.

Key words: Water stress, Thermal images, Super-resolution, Machine learning.

5.3 Introducción.

El incremento de la población mundial, junto con los efectos del cambio climático, ha intensificado la demanda sobre los recursos hídricos, planteando serios desafíos para la seguridad alimentaria y el desarrollo sostenible (Abioye et al., 2022; Aziz et al., 2022). En México, la agricultura es el principal consumidor de agua dulce, responsable de utilizar el 76.3 % de este recurso, para regar 6.6 millones de hectáreas, que representan el 26 % de la superficie total cultivada (CONAGUA, 2023). En este contexto, la gestión eficiente del riego resulta esencial para mantener la productividad agrícola sin comprometer la disponibilidad del recurso.

La creciente necesidad de mejorar la eficiencia en el uso del agua en la agricultura de riego ha impulsado la investigación en métodos de monitoreo hídrico. Para mantener la productividad de los cultivos, como el maíz, resulta fundamental programar el riego con base en información precisa sobre el estado hídrico de las plantas (Bwambale et al., 2022). En este sentido, se requieren métodos rápidos, no destructivos y confiables que permitan detectar el estrés hídrico y optimizar el uso del agua a lo largo del ciclo de crecimiento (Bijanzadeh et al., 2022; Zhou et al., 2021).

Tradicionalmente, el monitoreo se ha realizado mediante mediciones directas de humedad del suelo, conductancia estomática, potencial hídrico o características morfológicas como el índice de área foliar. Sin embargo, dichos métodos son costosos, laboriosos y poco representativos de la variabilidad espacial del campo (Bo et al., 2023; Noguera et al., 2020; Guimarães et al., 2024). Alternativamente, los enfoques basados en el balance hídrico del suelo y la evapotranspiración del cultivo, apoyados en sensores y modelos de simulación, permiten estimaciones más precisas de las necesidades hídricas (Ouma et al., 2024). Sin embargo, la necesidad de mejorar la eficiencia en el uso del agua exige estrategias de monitoreo de alta resolución espacial y temporal que permitan evaluar el estado hídrico de los cultivos (Jabro et al., 2020; Schattman et al., 2023).

Desde hace décadas, la temperatura del dosel se considera un indicador confiable del estado hídrico de las plantas, ya que constituye una de las variables más influyentes en los procesos fisiológicos, afectando directamente la transpiración, el potencial hídrico foliar y la tasa fotosintética (Gheysari et al., 2021).

Con un suministro de agua adecuado, la conductancia estomática y la transpiración aumentan, favoreciendo el enfriamiento foliar; en condiciones de estrés hídrico, ambos procesos disminuyen, elevando la temperatura del dosel, la cual puede detectarse mediante imágenes térmicas infrarrojas (Gheysari et al., 2021; Noguera et al., 2020). Las cámaras térmicas registran la radiación emitida por los cultivos en el rango espectral de 7 a 14 μm , lo que las convierte en instrumentos valiosos para el monitoreo del estado hídrico (Gheysari et al., 2021).

Las técnicas de teledetección que emplean cámaras térmicas integradas en sistemas aéreos no tripulados (RPAS) permiten detectar el estrés hídrico de manera no destructiva, a diferentes escalas espaciales y temporales, incluso antes de que los síntomas sean visibles (Wu et al., 2023; Sagan et al., 2019). Estos enfoques posibilitan un monitoreo integral del cultivo, al considerar simultáneamente múltiples individuos y áreas del dosel, contribuyendo a una estimación más precisa de los parámetros fisiológicos (Guimarães et al., 2024).

A pesar de las correlaciones establecidas entre los índices de estrés hídrico, derivado de datos de teledetección, y la conductancia estomática, estas relaciones a menudo no logran capturar la compleja interacción de múltiples factores que influyen en la dinámica estomática. Esta limitación evidencia la necesidad de enfoques más avanzados, como los modelos de aprendizaje automático (ML), para predecir con mayor precisión el estado hídrico de los cultivos (Guimarães et al., 2024).

La mayoría de los estudios previos se han centrado en sensores térmicos comerciales de alta gama o en imágenes satelitales, los cuales presentan limitaciones en costo, resolución espacial y frecuencia de adquisición (Li et al., 2023; Bo et al., 2023). Otros trabajos han utilizado cámaras térmicas montadas

en RPAS, pero sin aplicar procesos de mejora espacial o corrección radiométrica, lo que restringe la capacidad de identificar gradientes térmicos finos en el dosel. Asimismo, los modelos predictivos empleados suelen basarse en un conjunto limitado de variables ambientales o índices derivados, sin integrar información fisiológica ni de suelo que permita una caracterización más completa del estado hídrico (Zhou et al., 2021; Jin et al., 2024).

Utilizando la correlación del espectro de la vegetación y el contenido de humedad del suelo, diversos estudios han implementado modelos de regresión paramétricos y no paramétricos, incluidos algoritmos de aprendizaje automático, para estimar el estrés hídrico en plantas. La regresión de mínimos cuadrados parciales combinada con datos térmicos infrarrojos ha mostrado mejoras en la estimación del contenido de humedad del suelo, mientras que algoritmos como bosques aleatorios han demostrado alta capacidad predictiva en cultivos con elevada cobertura vegetal (Zhang et al., 2023).

El uso de aprendizaje automático se ha consolidado como una herramienta eficaz para procesar patrones térmicos complejos y generar predicciones robustas del estado hídrico. La integración de visión artificial con imágenes térmicas y algoritmos de ML ofrece una alternativa rápida, precisa y no destructiva para la evaluación del estrés hídrico. Modelos como redes neuronales artificiales, máquinas de soporte vectorial y bosques aleatorios han logrado clasificar con precisión distintos niveles de estrés en cultivos, mostrando un alto potencial para la toma de decisiones agronómicas basadas en datos del cultivo (Jin et al., 2024; Asadi & Shamsoddini, 2024).

En este contexto, las imágenes térmicas infrarrojas obtenidas mediante sistemas aéreos no tripulados se han consolidado como herramientas eficientes y para el diagnóstico temprano del déficit hídrico (Zhou et al., 2021; Bo et al., 2023). Sin embargo, su principal limitación sigue siendo la baja resolución espacial de las cámaras térmicas compactas, lo que dificulta la detección de variaciones finas en el dosel vegetal y reduce la precisión en la identificación de zonas afectadas por estrés.

Las técnicas de superresolución han surgido como una solución prometedora para mejorar la calidad espacial de las imágenes térmicas, preservando su fidelidad radiométrica y ampliando su aplicabilidad en la agricultura de precisión (Yun et al., 2024). En este marco, la presente investigación propone una metodología integral que combina imágenes térmicas mejoradas mediante superresolución con modelos de aprendizaje automático para la estimación del estado hídrico del maíz.

5.4 Materiales y métodos.

5.4.1 Adquisición de imágenes térmicas y RGB:

El estudio se realizó en el campo experimental “Ranchito”, de la Universidad Autónoma Chapingo, en Texcoco, Estado de México, 19°49'72" N y 98°85'72" O, en tres parcelas de maíz ubicados en la misma zona de estudio con una superficie de 0.8 Ha cada una (Figura 22).




Figura 22. Zona de estudio de vuelos fotogramétricos con el RPAS.

En el estudio se empleó un RPAS de tipo cuadricóptero equipado con una controladora de vuelo Pixhawk 2.4.8, la cual permite la ejecución de vuelos autónomos para la adquisición de imágenes georreferenciadas mediante GPS. Se desarrolló una cámara térmica basada en el sensor infrarrojo MLX90640 de

32 x 24 píxeles, que se montó en la parte frontal del vehículo aéreo (Figura 23), junto con una cámara RGB de 16 Mega píxeles para la obtención de información complementaria del cultivo.




Figura 23. Vista superior (a), inferior (b), de la cámara montada en el RPAS.

Para la adquisición de imágenes térmicas y RGB se realizaron 18 vuelos fotogramétricos entre los meses de julio y septiembre del año 2024, sobre cultivo de maíz. En un horario entre 12:00 am y 2:30 pm, se realizaron los vuelos fotogramétricos. El software de planificación de misiones utilizado en el RPAS fue QGroundControl, el cual permitió ajustar los parámetros de vuelo, siendo la velocidad de 1.5 m/s y altura de vuelo de 10 m sobre el cultivo, con un traslape lateral y frontal de 70% respectivamente.

5.4.2 Medición de fisiológica del cultivo.

Las mediciones de transpiración, conductancia estomática, radiación fotosintéticamente activa, humedad relativa y temperatura del dosel en el cultivo de maíz se realizaron con un porómetro de estado estacionario LI-COR LI-1600 (Figura 24, a), se tomaron 40 muestreos por día, antes del vuelo del RPAS.

Las mediciones se realizaron empleando una cámara tipo pinza para hojas (Figura 24, b), con área ajustable de 0.5 a 12 cm^2 , equipada con un sensor de humedad Vaisala Humicap y un termistor de precisión que registra la temperatura foliar en un rango de 0–64 °C (resolución 0.1 °C; exactitud ± 0.5 °C).



Figura 24. a) porómetro de estado estacionario LI-COR LI-1600, b) Cámara tipo pinza

El porómetro LI-1600 permitió cuantificar el control estomático del intercambio gaseoso, además relacionar estas mediciones con el balance hídrico y energético de las plantas. En el Cuadro 15 se presentan sus especificaciones.

Cuadro 15. Especificaciones principales del LI-COR LI-1600.

Parámetro	Rango de medición	Resolución	Precisión
Transpiración (E) $\left(\frac{mmol}{m^2s}\right)$	0.1 – 50	0.01 – 0.1	± 6 %
Conductancia estomática $\left(\frac{mmol}{m^2s}\right)$	8 – 800	4 – 20	± 10 %
Radiación fotosintéticamente activa (PAR) $\left(\frac{\mu mol}{s.m^2}\right)$	0 – 2500	1 – 10	± 5 %
Humedad relativa (HR) (%)	0 – 95	0.4	± 3 % RH (10 – 80 % RH)
Temperatura de la hoja (°C)	0 – 64	0.1	± 0.5 °C
Tiempo de operación continuo	Hasta 45 800 s (≈ 12 h)	0.7 s	± 0.05 %

5.4.3 Medición de humedad del suelo

El contenido de agua en el suelo se evaluó mediante sensores Watermark modelo 200SS (Figura 25a), los cuales estiman el potencial mátrico del suelo con

base en la resistencia eléctrica que presentan sus matrices granulares. Se instalaron dos sensores a profundidades representativas del perfil radicular del cultivo de maíz a 20 y 40 cm (Figura 25b), asegurando un contacto adecuado entre el sensor y el suelo. Cada sensor se conectó a un registrador de datos (Figura 25c), para la adquisición automática de lecturas.




Figura 25. a) Sensores Watermark 200SS, b) Datalogger implementado con paneles solares, c) Sensores colocados a 20 y 40 cm de profundidad.

El rango de operación de los sensores Watermark (WM) es de 0 a 200 cbar, donde 0 representa un suelo saturado y 200 un suelo seco. Estas lecturas pueden convertirse en contenido volumétrico de agua mediante ecuaciones de calibración reportadas por Jabro et al., (2020).

El principio de funcionamiento del WM se basa en la variación de la resistencia eléctrica entre dos electrodos embebidos en la matriz porosa. A medida que el suelo se seca, el contenido de agua en la matriz disminuye, lo que incrementa la resistencia eléctrica medida; en contraste, en suelos húmedos, la resistencia disminuye. Estas variaciones permiten estimar el potencial mátrico (ψ) del suelo (Shock et al., 1998; Hodges et al., 2023; Jabro et al., 2020).

El sensor Watermark se comporta como una resistencia variable que cambia en función del contenido de humedad del suelo. Para medir esta resistencia, se diseñó un circuito divisor de tensión conectado al datalogger, empleando un voltaje de entrada de 3.3v y una resistencia en serie de 10 k Ω . A partir del voltaje

medido en el punto medio del divisor, se calculó la resistencia del sensor mediante la siguiente ecuación:

$$R_{sensor} = R_1 \cdot \frac{V_{out}}{V_{in} - V_{out}}$$

donde:

- R_{sensor} = resistencia del sensor de humedad (Ω)
- R_1 = resistencia fija (10k Ω)
- V_{out} = voltaje leído en el pin analogico ADC del ESP32 (0–3.3 V)
- V_{in} = voltaje de entrada de excitación (3.3 v)

5.4.3.1 Determinación del potencial mátrico del agua en el suelo.

Los sensores de humedad del suelo Watermark generaron valores de resistencia eléctrica (Ω), los cuales se relacionan directamente con el potencial mátrico del agua en el suelo ψ (atm). La resistencia medida por el sensor varía en función de la cantidad de agua retenida en la matriz del suelo, lo que permite inferir la tensión mátrica del mismo. Esta relación entre la resistencia eléctrica (Ω) y el potencial mátrico $\psi_{(kpa)}$, se determinó mediante la ecuación propuesta por Shock et al. (1998):

$$\psi_{(kpa)} = - \frac{(4.093 + 3.213 \cdot R)}{(1 - 0.009733 \cdot R - 0.02316 \cdot T)}$$

donde:

- R = Resistencia medida del sensor ($k\Omega$)
- T = Temperatura del suelo ($21^\circ C$)
- $\psi_{(kpa)}$ = Potencial mátrico del agua del suelo en (kPa) o centibares

Con el potencial mátrico del agua en el suelo convertidos a atmosferas $\psi_{(atm)}$ se aplicaron las funciones de curvas de retención de humedad del suelo ajustadas a cada profundidad, estas curvas son calculadas a continuación.

5.4.3.2 Determinación de curvas de retención de humedad del suelo

Para determinar el contenido de humedad del suelo con los valores de potencial mátrico $\psi_{(atm)}$, generados con las lecturas del sensor Watermark, se utilizaron muestras de suelo recolectadas a profundidades de 20 y 40 cm. En laboratorio se determinaron la capacidad de campo, el punto de marchitez permanente y la textura del suelo (Cuadro 16).

Cuadro 16. Características físicas del suelo.

Profundidad	Capacidad de campo %	Punto de Marchitez Permanente %	Textura de Suelo:
20cm	29.23	15.59	Franco-arenoso
40cm	29.65	15.06	Franco-arenoso

Utilizando un equipo de succión controlada, conformado por una membrana porosa y una olla de presión (extractor de presión), se aplicaron presiones matriciales conocidas a las muestras de suelo para determinar la relación entre el contenido de humedad del suelo $\theta(\psi)$ y el potencial mátrico $\psi_{(atm)}$. Con los datos obtenidos se elaboraron las curvas de retención de humedad correspondientes a cada profundidad (Figura 26). Estas curvas fueron ajustadas mediante el modelo de Van Genuchten (1980), el cual describe de forma no lineal la relación $\theta(\psi)$ bajo distintas condiciones de humedad (Han et al., 2010).




Figura 26. Curvas de retención de humedad a 20 y 40 cm de profundidad.

Los parámetros del modelo se estimaron mediante ajuste no lineal por mínimos cuadrados, siendo el coeficiente de determinación R^2 de 0.98 para ambas profundidades. Con base en los parámetros calculados, las funciones de contenido de humedad del suelo $\theta(\psi)$ se expresan como:

$$\theta(\psi_{atm})_{20\text{ cm}} = 11.909 \psi_{atm}^{-0.341} + 11.031$$

$$\theta(\psi_{atm})_{40\text{ cm}} = 12.574 \psi_{atm}^{-0.347} + 10.317$$

5.4.4 Determinación del Estrés Hídrico del Cultivo mediante el Método FAO

La estimación del estrés hídrico del cultivo se realizó a partir del cálculo del coeficiente de reducción del rendimiento por déficit hídrico, siguiendo el procedimiento propuesto por la FAO (Allen et al., 1998). Para este análisis se utilizó el contenido de humedad del suelo durante el ciclo del cultivo de maíz, calculado a partir del potencial mátrico del agua en el suelo $\psi_{(atm)}$.

Determinación de parámetros hídricos del suelo

Con el promedio de la capacidad de campo (CC)= 29.44 % y el punto de marchitez permanente (PMP) = 15.33 % se calculó el agua total disponible (ATD) mediante la expresión:

$$ATD = CC - PMP$$

Se determinó el agua fácilmente disponible (AFD) considerando una fracción de agotamiento $p=0.5$ para el maíz, de acuerdo con los criterios establecidos por la FAO para cultivos de maíz bajo condiciones de riego o humedad media (Allen et al., 1998; Mkhabela et al., 2019; Kang et al., 2020). Mediante la ecuación:

$$AFD = p \cdot ATD$$

Cálculo del agotamiento de humedad y déficit de agua (Dr)

El agotamiento de humedad del suelo (%) y el déficit de agua (Dr) son indicadores fundamentales del estrés hídrico porque reflejan directamente la disponibilidad de agua en la zona radicular y su relación con la demanda atmosférica. Estos indicadores permiten cuantificar la magnitud del déficit de agua respecto a la

capacidad de campo, proporcionando una medida integradora del balance hídrico planta-suelo-atmósfera (Li et al., 2021; Sinclair & Rufty, 2022). El porcentaje de agotamiento del agua en el suelo se determinó mediante la siguiente expresión:

$$Agotamiento (\%) = \frac{(CC - \theta)}{ATD} \times 100$$

Mientras que el déficit de agua en la zona radicular (Dr) se calculó como:

$$Dr = Capacidad\ de\ campo - \theta$$

Donde:

- θ = Contenido de humedad del suelo (%)
- CC = Capacidad de campo (%)
- ATD = Agua total disponible (%)

Cálculo del coeficiente de estrés hídrico (K_s)

El coeficiente de estrés hídrico (K_s) se determinó siguiendo el método propuesto por la FAO (Allen et al., 1998), mediante la siguiente expresión:

$$K_s = \begin{cases} 1, & \text{si } Dr \leq AFD \\ \frac{ATD - Dr}{ATD - AFD} & \text{si } Dr > AFD \end{cases}$$

Donde:

- K_s = Coeficiente de estrés hídrico (adimensional)
- Dr = Déficit de agua en la zona radicular (%)
- ATD = Agua total disponible (%)
- AFD = Agua fácilmente disponible (%)

Clasificación de estrés

Los valores de K_s se interpretaron conforme a los umbrales establecidos por la FAO (1998): Un valor de $K_s = 1$ indica ausencia de estrés hídrico, mientras que valores inferiores a 1 representan grados crecientes de déficit hídrico y, por tanto,

mayor estrés en el cultivo. El cálculo del coeficiente K_s se realizó para las fechas en las que se efectuaron los vuelos fotogramétricos, con el fin de correlacionar los niveles de estrés hídrico estimados con las imágenes térmicas obtenidas durante cada vuelo.

5.4.5 Entrenamiento de modelos de aprendizaje automático

El análisis del estado hídrico del maíz se realizó mediante modelos de regresión y clasificación. Como variables predictoras (independientes) se emplearon la radiación solar, la humedad relativa y la temperatura del dosel, mientras que las variables dependientes (objetivo) correspondieron al agotamiento de humedad del suelo a 20 y 40 cm de profundidad, y el coeficiente de estrés hídrico (K_s).

Para los modelos de clasificación, se utilizó el coeficiente de estrés hídrico (K_s), como variable categórica para distinguir dos clases: estresado y no estresado, aplicando métodos de clasificación supervisada y no supervisada, esta última mediante agrupamiento de K-medias.

En el caso modelos de regresión, se emplearon los valores continuos de agotamiento de humedad del suelo a 20 y 40 cm de profundidad. Cada profundidad fue modelada de forma independiente utilizando cinco algoritmos de aprendizaje automático: Bosque Aleatorio (RF), Potenciación del Gradiente Extrema (XGB), Máquina de Soporte Vectorial (SVR), Red Neuronal Artificial (RNA) y Regresión Lineal Multivariada (MLR), con el propósito de evaluar la capacidad de cada modelo para representar relaciones lineales y no lineales entre las variables ambientales y el contenido de agua en el suelo.

El conjunto de datos estuvo compuesto por 816 muestreos medidos en todo el ciclo del cultivo. Los datos se dividieron en 70% para entrenamiento y 30% para prueba, asegurando una distribución representativa mediante muestreo aleatorio estratificado. Durante el proceso de ajuste, los modelos fueron optimizados mediante validación cruzada k-fold ($k = 10$), lo que permitió evaluar su estabilidad, robustez y capacidad predictiva.

Las variables continuas se estandarizaron mediante normalización z-score, mientras que las variables categóricas se codificaron adecuadamente según el tipo de modelo (regresión o clasificación). Cada registro se sincronizó temporalmente con la fecha y hora de adquisición de las imágenes y lecturas de sensores, garantizando la correspondencia entre las variables predictoras y las dependientes.

La selección de hiperparámetros se efectuó mediante búsqueda en rejilla, combinada con validación cruzada k-fold, con el propósito de optimizar el rendimiento y asegurar la capacidad de generalización espacial y temporal de los modelos.

Finalmente, el desempeño de los modelos se evaluó mediante las métricas Error Absoluto Medio (MAE), Raíz del Error Cuadrático Medio (RMSE) y Coeficiente de Determinación (R^2), calculadas tanto en el conjunto de prueba como en la validación cruzada. Esta estrategia se aplicó de forma independiente a cada variable dependiente, permitiendo un análisis del estrés hídrico a distintas profundidades del suelo.

Redes Neuronales Artificiales:

Se implementó una red neuronal artificial de tipo perceptrón multicapa para modelar las relaciones no lineales entre las variables ambientales y el estrés hídrico del maíz. La arquitectura consistió en una capa de entrada de tres neuronas (Radiación solar, Humedad relativa y Temperatura del dosel), una capa oculta con número de neuronas variable (5, 10 o 20) y una capa de salida de una neurona para regresión. Se empleó la función de activación ReLU en la capa oculta y lineal en la capa de salida, con optimización mediante el algoritmo Adam y regularización $L2$ ($\alpha = 0.1$).

Bosque Aleatorio:

El modelo de Bosque Aleatorio emplea un ensamble de árboles de decisión generado mediante el método de agregación por muestreo. Inicialmente se configuraron 50 árboles, utilizando el error cuadrático medio como criterio de

división de nodos. Se aplicó una normalización estándar para mantener la uniformidad entre los algoritmos evaluados.

Máquina de Soporte Vectorial:

Se empleó un modelo de Máquinas de Vectores de Soporte (SVR) con función núcleo radial (RBF) para capturar las relaciones no lineales entre las variables predictoras y las variables de salida. Los hiperparámetros principales se establecieron en $C = 150$ y $\gamma = 1$. Este modelo permite controlar la complejidad mediante el margen de tolerancia y el número de vectores soporte, ofreciendo estabilidad y una alta capacidad predictiva en problemas no lineales (Mahesh, 2018).

Potenciación del Gradiente Extrema:

El modelo XGB, basado en el aumento del gradiente aplicado a árboles de decisión, se configuró con un número de estimadores ajustable, una tasa de aprendizaje de 0.1. Este modelo permite manejar de manera eficiente las interacciones complejas entre variables, la alta dimensionalidad y las estructuras de datos heterogéneas (Abioye et al., 2022).

Regresión Multivariada Lineal :

Se incluyó un modelo de regresión lineal múltiple para evaluar la relación lineal entre las variables ambientales y estrés hídrico. Este enfoque permite interpretar directamente los coeficientes de cada predictor como su efecto sobre la variable dependiente, funcionando como referencia para comparar el desempeño de los modelos de aprendizaje automático más complejos. A pesar de su limitación para capturar interacciones no lineales, sigue siendo una herramienta válida en estudios de predicción agrícola (Silva & Bernardino, 2022).

Agrupamiento K-medias:

Para identificar los estados hídricos del cultivo, se aplicó el modelo de clasificación no supervisada Agrupamiento (K-medias) utilizando tres variables (radiación solar, humedad relativa y temperatura del dosel). Debido a su carácter

no supervisado, el modelo no emplea las etiquetas de estrés durante el entrenamiento; por lo tanto, la formación de los grupos depende exclusivamente de la similitud entre los datos de entrada. Se definieron dos agrupamientos, correspondientes a las categorías de interés “estresado” y “no estresado”, bajo una inicialización aleatoria de centroides.

5.5 Resultados y discusión

Las lecturas obtenidas mediante los sensores Watermark permitieron estimar la dinámica del potencial hídrico del suelo, identificando con claridad los periodos de déficit hídrico y su relación con las variaciones térmicas registradas en el dosel del cultivo. Esta información fue fundamental para caracterizar el comportamiento hídrico del maíz bajo diferentes condiciones de humedad del suelo.

En la Figura 27 se presentan las temperaturas promedio del dosel obtenidas con la cámara térmica, junto con las mediciones de humedad del suelo, derivadas de la resistencia registrada por los sensores Watermark instalados a 20 y 40 cm de profundidad. Estas mediciones fueron utilizadas posteriormente para calibrar los modelos de aprendizaje automático y evaluar la respuesta térmica del cultivo frente a condiciones de estrés hídrico.




Figura 27. Temperatura promedio del dosel y contenido de humedad del suelo

Los resultados evidencian una relación inversa entre la temperatura promedio del dosel y la humedad del suelo a 20 y 40 cm de profundidad. A medida que la humedad del suelo disminuyó, la temperatura del dosel aumentó.

La transpiración y conductancia estomática obtenida se graficó en la Figura 28, muestran un patrón similar a lo largo del ciclo de cultivo, con máximos durante los periodos de mayor demanda evaporativa y radiación.




Figura 28. Transpiración vs Conductancia estomática, obtenida con el porómetro licor li-1600

La correlación obtenida entre la transpiración y la conductancia estomática fue de $R^2 = 0.9$, resultado coherente con lo planteado por Medrano et al. (2023) y Zhang et al. (2022), quienes señalan que los estomas regulan el intercambio de vapor de agua y CO_2 . Estos autores destacan que los cambios en la apertura estomática se reflejan casi de inmediato en la tasa de transpiración, dado que dicha apertura controla el flujo de vapor de agua desde la hoja hacia la atmósfera.

La transpiración presentó una correlación positiva moderada con la radiación solar $R^2 = 0.74$ (Figura 29), y una relación inversa con la humedad relativa. Esto indica que la radiación actúa como el principal impulsor energético de la pérdida de agua por transpiración, mientras que la humedad relativa modula la intensidad del gradiente de vapor, reduciendo el flujo cuando el aire es más húmedo.

Investigaciones de Zhang et al., (2022) y López-López et al., (2023), destacan que tanto la radiación como el déficit de presión de vapor son los principales impulsores de la transpiración a escala de hoja y de dosel, lo que respalda el uso de la radiación cuando las mediciones directas no son viables.




Figura 29. Transpiración vs radiación solar, obtenida con el porómetro licor li-1600

En este estudio se incorporó la humedad relativa (HR) como variable clave debido a su relación directa con el déficit de presión de vapor. En términos fisiológicos, la HR actúa como modulador de la transpiración: valores elevados reducen el gradiente de vapor y la pérdida de agua, mientras que valores bajos aumentan la demanda evaporativa y favorecen el cierre estomático. Como se puede apreciar en la Figura 28 cuando la HR es alta el aire es más húmedo y genera un menor gradiente de humedad que se traduce a una menor transpiración. Al contrario de una HR baja donde el aire es más seco y existe mayor gradiente de humedad lo que se traduce a una mayor transpiración.




Figura 30. Transpiración vs Humedad relativa obtenida con el porómetro licor li-1600.

En conjunto, estos resultados evidencian que la combinación de radiación solar, humedad relativa y temperatura del dosel permiten describir de manera efectiva la dinámica de la transpiración sin necesidad de mediciones directas. Esta relación es fundamental, ya que la transpiración refleja el equilibrio hídrico entre la planta y el suelo; por tanto, su comportamiento está estrechamente vinculado al contenido de humedad del suelo y al grado de estrés hídrico del cultivo. Cuando la disponibilidad de agua en el suelo disminuye, la transpiración y la conductancia estomática se reducen, generando un aumento en la temperatura del dosel detectable mediante imágenes térmicas. De esta manera, el análisis conjunto de estas variables proporciona una herramienta confiable para inferir el estado hídrico del maíz bajo condiciones de campo.

5.5.1 Determinación del estrés hídrico mediante modelos de clasificación

Para los modelos de clasificación no supervisada, se aplicó el método de agrupamiento K-medias. Este algoritmo dividió el conjunto de datos en dos grupos basados en la similitud de las condiciones registradas, identificando patrones en función de la radiación solar, la humedad relativa y la temperatura

del dosel. Los grupos resultantes permitieron diferenciar de forma automática zonas o momentos con distinta disponibilidad de agua en el suelo, reflejando diferentes niveles de estrés hídrico en el cultivo y proporcionando una caracterización efectiva del estado hídrico del maíz.

Para validar la correspondencia entre los grupos generados por el agrupamiento K-medias (utilizando las tres variables de entrada), se compararon los resultados con el coeficiente de estrés hídrico (K_s), calculado a 20 y 40 cm de profundidad. Este coeficiente permitió clasificar las observaciones en dos categorías: “estresado” y “no estresado”. Los resultados del modelo calcularon un coeficiente Silhouette de 0.70, un índice de Calinski-Harabasz de 2785.44 y un índice de Davies-Bouldin de 0.3916, lo que corroborando una baja superposición entre los grupos y una adecuada separación de las clases formadas.

A partir de la matriz de contingencia (Figura 31) y considerando el agrupamiento 0 como “no estresado” y el agrupamiento 1 como “estresado”, se calculó una precisión global de 77.8% y 79.2 para 20 y 40cm respectivamente.






Figura 31. Matriz de contingencia del estrés calculado (k_s) vs Agrupamiento K-medias, a) 20 cm y b) 40cm.

Los resultados muestran que, aunque K-means no utiliza las etiquetas, logra diferenciar parcialmente los estados hídricos, siendo más efectivo para identificar los datos no estresados. La Figura 32 muestra los agrupamientos de los datos y la separación relativa entre los grupos, permitiendo observar claramente la distribución y la separación relativa de los grupos comparada con los valores reales del estado hídrico del cultivo en con base en el déficit hídrico (K_s).




a)




b)

Clusters K-means , 3 Variables



c)

Datos reales por Estrés hídrico




d)

Figura 32. Agrupamientos para K-means generado (a: 20 cm, c: 40 cm); Agrupamientos reales por estrés con base en el déficit hídrico (K_s) (b: 20 cm, d: 40 cm).

También se aplicaron métodos de clasificación supervisada utilizando como variables de entrada la radiación solar, la humedad relativa y la temperatura del dosel, con el objetivo de clasificar el estado hídrico del cultivo a partir de la etiqueta de salida derivada del coeficiente de estrés hídrico (K_s), que distingue entre las categorías estresado y no estresado. Los modelos empleados fueron: Bosque Aleatorio (RF), Potenciación del Gradiente Extrema (XGB), Máquina de Vectores de Soporte (SVM), Redes Neuronales Artificiales (RNA) y Regresión Logística (RL).

Los modelos RF y XGB alcanzaron una precisión del 100%, mientras que SVM y RNA obtuvieron valores de 0.71 y 0.78, respectivamente. Este desempeño se explica porque los modelos supervisados fueron entrenados directamente con la etiqueta real de estrés, lo que les permitió aprender explícitamente la relación entre las variables meteorológicas y fisiológicas del cultivo y su estado hídrico.

Las curvas de pérdida y precisión (Figura 33), evidenciaron que los modelos basados en árboles, especialmente RF y XGB, alcanzan una convergencia rápida y estable, con pérdidas bajas y altas precisiones tanto en entrenamiento como en validación. En contraste, SVM, RNA y Regresión Logística mostraron desempeños moderados (0.71 y 0.78), junto con fluctuaciones en las curvas y brechas entre entrenamiento y validación, lo que revela una menor capacidad de generalización. Aunque la regresión logística fue estable, su rendimiento permaneció por debajo de los métodos de ensamble.






Figura 33. Curvas de pérdida y precisión de los modelos: a) RF, b) XGB, c) SVM y d) RL.

En conjunto, los resultados confirman que RF y XGB son los modelos más robustos cuyos mecanismos internos basados en la creación de múltiples árboles, optimización iterativa y combinación de predicciones les permiten capturar relaciones no lineales y patrones complejos presentes en los datos, para estimar el estrés hídrico a partir del conjunto de variables medidas, destacándose como las alternativas más precisas y confiables para sistemas de diagnóstico y riego inteligente.

5.5.2 Determinación del estado hídrico mediante modelos de regresión

Para estimar el estado hídrico en el cultivo de maíz, se aplicaron cinco algoritmos de aprendizaje automático, orientados a predecir el porcentaje de agotamiento de humedad del suelo a profundidades de 20 cm y 40 cm, asociado al estado hídrico del cultivo. Las variables independientes utilizadas fueron la radiación solar, la humedad relativa y la temperatura del dosel. Los modelos evaluados incluyeron: Bosque Aleatorio (RF), Potenciación del Gradiente Extrema (XGB), Máquina de Soporte Vectorial (SVM), Red Neuronal Artificial (RNA) y Regresión Lineal Multivariada (MLR).

Los resultados, presentados en el, muestran que el modelo RF obtuvo el mejor desempeño general, con los valores MAE = 0.37, RMSE = 1.18 y un coeficiente de determinación promedio R^2 de 0.97, lo que refleja una alta precisión y estabilidad en la predicción. XGB se posicionó como la segunda mejor opción,

con métricas también favorables ($MAE = 1.51$, $RMSE = 2.55$, $R^2 = 0.95$), confirmando su capacidad para modelar relaciones no lineales de forma eficiente.


Cuadro 17. Métricas de desempeño para: agotamiento de humedad % (Ag) y déficit de agua (Dr) a 40 Y 20 cm.

Modelo	Agotamiento	MAE	MSE	RMSE	R^2 promedio (k=10)	Desviación estándar CV
RF	40cm	0.37	1.39	1.18	0.97	-
	20cm	0.63	3.55	1.88	0.97	-
XGB	40cm	1.51	6.50	2.55	0.95	0.014
	20cm	1.53	4.99	2.23	0.96	0.012
SVM	40cm	1.81	9.67	3.11	0.86	0.007
	20cm	2.61	25.11	5.01	0.74	0.087
RNA	40cm	3.73	28.80	5.36	0.74	-
	20cm	4.81	47.89	6.92	0.68	-
LIR	40cm	10.27	130.3	11.41	0.21	0.021
	20cm	11.41	130.3	10.27	0.20	0.051

Los modelos SVM y RNA mostraron un desempeño inferior al de los métodos de ensamble. En particular, SVM alcanzó un R^2 de 0.86 con errores moderados ($MAE = 1.81$, $RMSE = 3.11$), mientras que la RNA presentó mayor variabilidad y errores más elevados ($MAE = 3.73$, $RMSE = 5.36$, $R^2 = 0.74$), posiblemente debido a su sensibilidad a la cantidad de datos y a la complejidad del entrenamiento. Por su parte, la Regresión Lineal Multivariada (MLR), utilizada como modelo base, evidenció una capacidad predictiva muy limitada ($R^2 = 0.21$, $RMSE = 11.41$), lo que confirma que un enfoque lineal no es adecuado para representar la dinámica del estrés hídrico.

En contraste, los modelos Random Forest (RF) y XGBoost (XGB) destacaron por su alto rendimiento y estabilidad. RF obtuvo los mejores resultados globales ($MAE = 0.37$, $RMSE = 1.18$, $R^2 = 0.97$), seguido de XGB ($MAE = 1.51$, $RMSE = 2.55$, $R^2 = 0.95$, $CV < 0.015$), lo que demuestra su capacidad para generalizar y adaptarse a condiciones con ruido moderado. En conjunto, estos hallazgos respaldan el uso de modelos no lineales, especialmente los basados en ensambles, para mejorar la precisión en la estimación del estado hídrico del cultivo en contextos agrícolas complejos.

La **Figura 34** muestra las curvas de aprendizaje de los modelos de regresión evaluados, donde los modelos RF y XGB alcanzan rápidamente valores elevados de $R^2 > 0.9$ en validación y presentan curvas prácticamente paralelas entre entrenamiento y validación, lo que indica buena generalización, bajo sesgo y estabilidad. En contraste, SVM mantiene una brecha marcada entre ambas curvas, con valores de R^2 incluso negativos en validación, evidenciando débil capacidad de ajuste y posible sobreajuste. La RNA muestra una variabilidad considerable y bandas de confianza amplias, reflejando inestabilidad y alta dependencia del tamaño de muestra, lo que sugiere la necesidad de ajustar hiperparámetros o aplicar regularización adicional. Por su parte, la MLR se mantiene en valores bajos de R^2 (~ 0.2) y con curvas prácticamente planas, confirmando su limitación para modelar relaciones no lineales entre las variables ambientales y el estado hídrico del suelo.






Figura 34. Curvas de pérdida y precisión de los modelos: a) RF, b) XGB, c) SVM y d) RL.

En conjunto, las curvas de aprendizaje confirman la superioridad de los modelos no lineales y basados en ensambles, especialmente RF y XGB. Estos modelos resultan los más adecuados para sistemas de diagnóstico del estado hídrico, donde la robustez estadística y la trazabilidad física son esenciales.

5.6 Conclusiones

En este estudio se determinó el estado hídrico del cultivo de maíz mediante el uso de modelos de aprendizaje automático e imágenes térmicas mejoradas mediante técnicas de superresolución, constituyendo una metodología eficaz para un monitoreo preciso, estable y eficiente, para la gestión del riego de precisión en la agricultura.

Los modelos de regresión RF y XGB demostraron una alta capacidad predictiva para estimar el agotamiento de humedad del suelo a 20 y 40 cm de profundidad, utilizando como variables de entrada la radiación solar, la humedad relativa y la temperatura del dosel. Ambos modelos lograron modelar de manera efectiva las relaciones no lineales y multivariadas entre las variables, alcanzando valores de R^2 superiores a 0.95 y errores mínimos ($MAE < 2$).

Los resultados de modelos de clasificación mediante el agrupamiento K-medias evidencian que, aun sin utilizar información supervisada, fue posible identificar

patrones asociados al estado hídrico del cultivo. La comparación con las etiquetas reales indicó una precisión global del 79.2 %, con mayor efectividad en la detección de plantas no estresadas. En conjunto, estos resultados demuestran que K-medias puede discriminar parcialmente entre condiciones hídricas contrastantes y ofrece una aproximación útil para la exploración inicial de patrones de estrés hídrico en maíz. Por su parte, los modelos de clasificación binaria mostraron un desempeño perfecto en la detección de niveles de estrés hídrico, alcanzando exactitudes y F1-scores cercanos a 1.0 en la mayoría de los modelos evaluados.

Aunque los modelos obtuvieron buena correlación y estimación entre las variables de entrada y salida, en trabajos futuros se podría aumentar el tamaño del conjunto de datos, explorar otros algoritmos de aprendizaje profundo, como las redes neuronales convolucionales, y realizar estudios en diferentes tipos de suelo y condiciones climáticas. Además, se recomienda incorporar variables edáficas y fisiológicas adicionales, validar los modelos en distintas etapas fenológicas del cultivo y evaluarlos en diversas regiones productoras, con el fin de mejorar su robustez y desarrollar modelos específicos para cada variedad, tipo de suelo y condición climática.

5.7 Referencias

- Abioye, E. A., Hensel, O., Esau, T. J., Elijah, O., Abidin, M. S. Z., Ayobami, A. S., Yerima, O., & Nasirahmadi, A. (2022). Precision Irrigation Management Using Machine Learning and Digital Farming Solutions. In *AgriEngineering* (Vol. 4, Issue 1, pp. 70–103). MDPI. <https://doi.org/10.3390/agriengineering4010006>
- Asadi, B., & Shamsoddini, A. (2024). Crop mapping through a hybrid machine learning and deep learning method. *Remote Sensing Applications: Society and Environment*, 33. <https://doi.org/10.1016/j.rsase.2023.101090>
- Aziz, M., Khan, M., Anjum, N., Sultan, M., Shamshiri, R. R., Ibrahim, S. M., Balasundram, S. K., & Aleem, M. (2022). Scientific Irrigation Scheduling for Sustainable Production in Olive Groves. *Agriculture (Switzerland)*, 12(4). <https://doi.org/10.3390/agriculture12040564>

- Bijanzadeh, E., Moosavi, S. M., & Bahadori, F. (2022). Quantifying water stress of safflower (*Carthamus tinctorius* L.) cultivars by crop water stress index under different irrigation regimes. *Heliyon*, 8(3). <https://doi.org/10.1016/j.heliyon.2022.e09010>
- Bo, L., Guan, H., & Mao, X. (2023). Diagnosing crop water status based on canopy temperature as a function of film mulching and deficit irrigation. *Field Crops Research*, 304. <https://doi.org/10.1016/j.fcr.2023.109154>
- Bwambale, E., Abagale, F. K., & Anornu, G. K. (2022). Smart irrigation monitoring and control strategies for improving water use efficiency in precision agriculture: A review. In *Agricultural Water Management* (Vol. 260). Elsevier B.V. <https://doi.org/10.1016/j.agwat.2021.107324>
- Chen, Y., Zhang, J. H., Chen, M. X., Zhu, F. Y., & Song, T. (2023). Optimizing water conservation and utilization with a regulated deficit irrigation strategy in woody crops: A review. In *Agricultural Water Management* (Vol. 289). Elsevier B.V. <https://doi.org/10.1016/j.agwat.2023.108523>
- Gheysari, M., Pirnajmedin, F., Movahedrad, H., Majidi, M. M., & Zareian, M. J. (2021). Crop yield and irrigation water productivity of silage maize under two water stress strategies in semi-arid environment: Two different pot and field experiments. *Agricultural Water Management*, 255. <https://doi.org/10.1016/j.agwat.2021.106999>
- Guimarães, N., Sousa, J. J., Couto, P., Bento, A., & Pádua, L. (2024). Combining UAV-Based Multispectral and Thermal Infrared Data with Regression Modeling and SHAP Analysis for Predicting Stomatal Conductance in Almond Orchards. *Remote Sensing*, 16(13). <https://doi.org/10.3390/rs16132467>
- Hodges, B., Tagert, M. L., Paz, J. O., & Meng, Q. (2023). Assessing in-field soil moisture variability in the active root zone using granular matrix sensors. *Agricultural Water Management*, 282. <https://doi.org/10.1016/j.agwat.2023.108268>

- Jabro, J. D., Stevens, W. B., Iversen, W. M., Allen, B. L., & Sainju, U. M. (2020). Irrigation scheduling based on wireless sensors output and soil-water characteristic curve in two soils. *Sensors (Switzerland)*, 20(5). <https://doi.org/10.3390/s20051336>
- Luna-Flores, w, Estrada-Medina, H., Jiménez-Osornio, J. J., & Pinzón-López, L. L. (2012). EFECTO DEL ESTRÉS HÍDRICO SOBRE EL CRECIMIENTO Y EFICIENCIA DEL USO DEL AGUA EN PLÁNTULAS. *Terra Latinoamericana*, 30, 343-353.
- Mertens, S., Verbraeken, L., Sprenger, H., De Meyer, S., Demuynck, K., Cannoot, B., Merchie, J., De Block, J., Vogel, J. T., Bruce, W., Nelissen, H., Maere, S., Inzé, D., & Wuyts, N. (2023). Monitoring of drought stress and transpiration rate using proximal thermal and hyperspectral imaging in an indoor automated plant phenotyping platform. *Plant Methods*, 19(1). <https://doi.org/10.1186/s13007-023-01102-1>
- Mondol, M. A. H., Zhu, X., Dunkerley, D., & Henley, B. J. (2022). Changing occurrence of crop water surplus or deficit and the impact of irrigation: An analysis highlighting consequences for rice production in Bangladesh. *Agricultural Water Management*, 269. <https://doi.org/10.1016/j.agwat.2022.107695>
- Noguera, M., Millán, B., Pérez-Paredes, J. J., Ponce, J. M., Aquino, A., & Andújar, J. M. (2020). A new low-cost device based on thermal infrared sensors for olive tree canopy temperature measurement and water status monitoring. *Remote Sensing*, 12(4). <https://doi.org/10.3390/rs12040723>
- Ouma, G., Wanyama, J., Kabenge, I., Jjagwe, J., Diana, M., & Muyonga, J. (2024). Assessing the effect of deficit drip irrigation regimes on crop performance of eggplant. *Scientia Horticulturae*, 325. <https://doi.org/10.1016/j.scienta.2023.112648>
- Pahuja, R. (2022). Development of semi-automatic recalibration sytem and curve-fit models for smart soil moisture sensor. *Measurement: Journal of the International*

<https://doi.org/10.1016/j.measurement.2022.111907>

- Sagan, V., Maimaitijiang, M., Sidike, P., Eblimit, K., Peterson, K. T., Hartling, S., Esposito, F., Khanal, K., Newcomb, M., Pauli, D., Ward, R., Fritschi, F., Shakoob, N., & Mockler, T. (2019). UAV-based high resolution thermal imaging for vegetation monitoring, and plant phenotyping using ICI 8640 P, FLIR Vue Pro R 640, and thermomap cameras. *Remote Sensing*, 11(3). <https://doi.org/10.3390/rs11030330>
- Wu, Y., Jiang, J., Zhang, X., Zhang, J., Cao, Q., Tian, Y., Zhu, Y., Cao, W., & Liu, X. (2023). Combining machine learning algorithm and multi-temporal temperature indices to estimate the water status of rice. *Agricultural Water Management*, 289. <https://doi.org/10.1016/j.agwat.2023.108521>
- Zhang, Y., Han, W., Zhang, H., Niu, X., & Shao, G. (2023). Evaluating soil moisture content under maize coverage using UAV multimodal data by machine learning algorithms. *Journal of Hydrology*, 617. <https://doi.org/10.1016/j.jhydrol.2023.129086>
- Zhou, Z., Majeed, Y., Diverres Naranjo, G., & Gambacorta, E. M. T. (2021). Assessment for crop water stress with infrared thermal imagery in precision agriculture: A review and future prospects for deep learning applications. In *Computers and Electronics in Agriculture* (Vol. 182). Elsevier B.V. <https://doi.org/10.1016/j.compag.2021.106019>

Apéndice A

Abreviaturas utilizadas

Piloto del RPAS: Persona que manipula los controles de vuelo de un sistema de aeronave pilotada a distancia.

RPA:(Remotely Piloted Aircraft - Aeronave Pilotada a Distancia): Aeronave no tripulada, que es pilotada desde una estación de pilotaje a distancia.

UA: (Unmanned Aircraft): Aeronave no Tripulada.

Dron: Aeronave no tripulada.

VANT: Un Vehículo Aéreo No Tripulado.

UAV: (Unmanned Aerial Vehicle - Vehículo Aéreo no Tripulado),

UAS (Unmanned Aircraft System): Sistema de Aeronave no Tripulada.

RPAS:(Remotely Piloted Aircraft System - Sistema de Aeronave Pilotada a Distancia): Sistema Aéreo Tripulado Remotamente.

RPAS de uso Comercial: Sistema de aeronave pilotada a distancia destinado por el operador de RPAS a realizar tareas con fines de lucro.

RPAS de uso Recreativo: Es aquel sistema de aeronave pilotada a distancia que se destina por el operador de RPAS a la recreación.

RPAS de uso Privado No comercial: Sistema de aeronave pilotada a distancia, destinado por el operador de RPAS a realizar tareas sin fines de lucro.

AP: Agricultura de Precisión.

GNSS: Sistema mundial de navegación por satélite.

LiDAR: Detección de luz y rango.

IMU: Unidad de medida Inercial.

PPM: Pulso por segundo.

RGB: Rojo, verde y azul.

RTK: Cinemática en tiempo real.

Waypoints: Coordenadas para ubicar puntos de referencia tridimensionales utilizados en la navegación basada en GPS

Abreviaturas utilizadas

Abreviatura	Palabra	Significado
T	Transpiración	La transpiración consiste en la vaporización del agua líquida contenida en los tejidos de la planta y su posterior remoción hacia la atmósfera. Los cultivos pierden agua predominantemente a través de los estomas.
E	Evaporación	La evaporación es el proceso por el cual el agua líquida se convierte en vapor de agua (vaporización) y se retira de la superficie
ET	Evapotranspiración	Combinación de dos procesos separados por los que el agua se pierde a través de la superficie del suelo por evaporación y por otra parte mediante transpiración del cultivo
ET_o	Evapotranspiración del cultivo de referencia	La tasa de evapotranspiración de una superficie de referencia, que ocurre sin restricciones de agua, se conoce como evapotranspiración del cultivo de referencia La superficie de referencia corresponde a un cultivo hipotético de pasto con características específicas.
ET_c	Evapotranspiración del cultivo bajo condiciones estándar	evapotranspiración de cualquier cultivo cuando se encuentra exento de enfermedades, con buena fertilización y que se desarrolla en parcelas amplias, bajo óptimas condiciones de suelo y agua, y que alcanza la máxima producción de acuerdo a las condiciones climáticas reinantes.
$ET_{c aj}$	evapotranspiración del cultivo bajo condiciones no estándar	Evapotranspiración de cultivos que crecen bajo condiciones ambientales y de manejo

		diferentes de las condiciones estándar. Bajo condiciones de campo, la evapotranspiración real del cultivo puede desviarse de ETc
K_c	coeficiente del cultivo	Factor adimensional que relaciona la cantidad de agua consumida por un cultivo específico (evapotranspiración del cultivo, ETc) con la evapotranspiración de referencia (ETo)
K_s	coeficiente de estrés hídrico	factor que cuantifica la reducción en la transpiración del cultivo debido a la disponibilidad limitada de agua en el suelo,
e_s	Presión de vapor de agua a saturación	Presión a la que el vapor de agua y el agua líquida (o el hielo) se encuentran en equilibrio termodinámico en un sistema cerrado
e_a	Presión real de vapor	Presión parcial del vapor de un líquido orgánico volátil en equilibrio con su fase líquida a una temperatura dada en un sistema cerrado
$e_s - e_a$	Déficit de presión de vapor	Diferencia entre la cantidad de agua que el aire puede contener cuando está saturado y la cantidad real de agua que contiene en un momento dado y a una temperatura específica
Ψ	Potencial hídrico	Medida de la energía libre del agua que indica su capacidad para moverse en un sistema
Ψ_L	Potencial hídrico foliar (hoja)	Medida de la energía potencial del agua en las hojas de una planta, indicando su estado hídrico
Ψ_S	Potencial hídrico en tallo	Es una medida de la tensión hídrica dentro de la planta, indicando el estado de estrés hídrico o la cantidad de agua disponible

Ψ_{PD}	El potencial hídrico de la hoja antes del amanecer	Medida del estado hídrico de la planta, en el punto de máxima rehidratación nocturna
Ψ_{SS}	Potencial de solutos	Medida de la tendencia del agua a moverse a través de una membrana semipermeable debido a la presencia de solutos
g_s	Conductancia estomática	Medida de la apertura de los estomas en las plantas, que determina la velocidad del intercambio gaseoso (CO_2 y vapor de agua) a través de las hojas
	Humedad de Saturación	Contenido de agua de un suelo en el que todos sus poros están llenos de agua. puede observarse inmediatamente después de una lluvia o riego abundante.
CC	Capacidad de Campo límite máximo	contenido de agua presente en un suelo luego de drenar libremente durante los 2 o 3 días posteriores a una lluvia o riego intenso.
PMP	Punto de Permanente límite mínimo, Marchitez	es el contenido de agua de un suelo retenida tan firmemente que las plantas no pueden extraerla causándoles una marchitez irreversible.
AU	Agua Útil O disponible	Es la diferencia entre los contenidos de agua a CC y PMP. Es la que se considera como agua utilizable o potencialmente extractable por las plantas en la zona de crecimiento radical

Componentes principales				Observaciones
T_c	Temperatura del dosel		(°C)	Temperatura corregida con la emisividad del cultivo ($0,986 \pm 0,009$) y temperatura ambiente

Hr	Humedad relativa	(%)	Medida del contenido de vapor de agua en el aire El potencial hídrico del ambiente (Ψ ambiente) está regulado por la temperatura y la humedad relativa
Hd	Hora del día	(12)	La mayor evapotranspiración se encuentra a medio día
ddc	Etapa de crecimiento de del cultivo	(# <i>días</i>)	Numero de días después de la siembra
Rn:	radiación neta en la superficie del cultivo	$(\frac{MJ}{m^2 \text{ día}})$	
T	temperatura media del aire a 2 m de altura	(°C)	Temperatura bulbo seco
u ₂	velocidad del viento a 2 m de altura	$(\frac{m}{s})$	
e _s	presión de vapor de saturación	(kPa)	$e_s - e_a$ Déficit de presión de vapor (kPa)
e _a	presión real de vapor	(kPa)	Esta diferencia de presión es lo que impulsa la transpiración de los estomas de las plantas. Si DPV es alto, lo que significa que el aire está relativamente seco, las tasas de transpiración aumentarán. A medida que disminuye el déficit de presión de vapor, la transpiración disminuirá o incluso se detendrá por completo. Un déficit de presión de vapor muy alto podría provocar estrés hídrico, una situación en la que la planta se pone a la defensiva, en un esfuerzo por retener agua. Los estomas se cierran para evitar la evaporación, lo que a su vez detiene la entrada de CO ₂ , que también impide el crecimiento.