

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE AGRONOMÍA**



**ADQUISICIÓN Y PROCESAMIENTO DE IMÁGENES RGB E
HIPERESPECTRALES, PARA LA FENOTIPIFICACIÓN DE LA SEQUÍA EN
*Opuntia ficus-indica (L.) Miller***

TESIS

QUE PARA OBTENER EL GRADO DE
DOCTOR EN CIENCIAS AGRÍCOLAS

PRESENTA

JUAN ARREDONDO VALDEZ

General Escobedo, N. L.

Julio de 2022

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE AGRONOMÍA**



**ADQUISICIÓN Y PROCESAMIENTO DE IMÁGENES RGB E
HIPERESPECTRALES, PARA LA FENOTIPIFICACIÓN DE LA SEQUÍA EN
*Opuntia ficus-indica (L.) Miller***

TESIS

QUE PARA OBTENER EL GRADO DE

DOCTOR EN CIENCIAS AGRÍCOLAS

PRESENTA

JUAN ARREDONDO VALDEZ

General Escobedo, N. L.

Julio de 2022

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE AGRONOMÍA**

SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



**ADQUISICIÓN Y PROCESAMIENTO DE IMÁGENES RGB E
HIPERESPECTRALES, PARA LA FENOTIPIFICACIÓN DE LA SEQUÍA EN
*Opuntia ficus-indica (L.) Miller***

TESIS

**QUE PARA OBTENER EL GRADO DE
DOCTOR EN CIENCIAS AGRÍCOLAS**

PRESENTA

JUAN ARREDONDO VALDEZ

General Escobedo, N. L.

Julio de 2022

ESTA TESIS FUE REVISADA Y APROBADA POR EL COMITÉ PARTICULAR
COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE

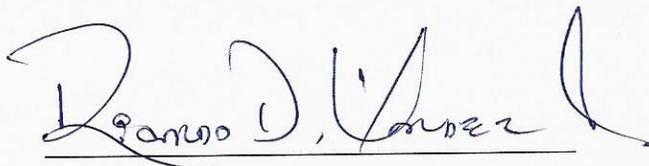
DOCTOR EN CIENCIAS AGRÍCOLAS

COMITÉ PARTICULAR



Ph.D. Alejandro Isabel Luna Maldonado

Director de tesis



Dr. Cs. Ricardo David Cepeda Valdez

Co-Director de tesis



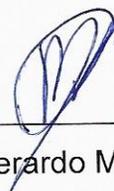
Ph.D. Juan Antonio Vidales Contreras

Asesor



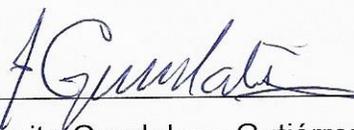
Dr. Cs. Humberto Rodriguez Fuentes

Asesor



D. Ph. Gerardo Méndez Zamora

Asesor



Dra. Juanita Guadalupe Gutiérrez Soto

Subdirectora de Estudios de Posgrado e Investigación

DEDICATORIA

A mis amados padres Magdaleno y Juanita⁺ a quienes debo mi vida, educación y valores.

A mi esposa Juanita Leticia Grimaldi, que siempre me ha apoyado en todo aquello que he emprendido.

A mis queridos hijos Juan Francisco, Cecilia Gabriela y Ricardo, quienes forman mi riqueza y legado en la tierra.

A mi nietecita Paola, mi gran amor.

AGRADECIMIENTOS

Mi agradecimiento a la Universidad Autónoma de Nuevo León y a la Facultad de Agronomía, por haberme permitido ser parte de ellas como estudiante de doctorado.

Al Ph.D. Alejandro Luna Maldonado por su gran paciencia, motivación y conocimiento inmenso hacia mí y por el apoyo y amistad incondicional brindados durante mis estudios de doctorado y en mi proyecto de investigación. No podría haber imaginado tener un mejor asesor y mentor.

Al Dr. Ricardo David Valdez Cepeda por la crítica constructiva que me incentivó a ampliar mi investigación desde varias perspectivas.

Al Dr. Cs. Humberto Rodríguez Fuentes por su apoyo, compartir su experiencia, sus conocimientos y acompañamiento durante mi estancia doctoral.

Al Ph.D. Juan Antonio Vidales Contreras por su disposición, ayuda y guía.

Un agradecimiento especial al Ing. Bríjido Saúl Zúñiga Hernández por su desinteresada amistad y gran apoyo, asimismo al Dr. Cs. Josué García López, pues gracias a su ayuda se pudieron realizar muchas actividades de este proyecto de investigación. Mi agradecimiento también a la Dra. Sughey R. Sinagawa García y al Ing. Jesús Lara Reyes por su gran apoyo y ayuda.

Gracias a todos los profesores de la Facultad de Agronomía, quienes siempre mostraron su profesionalismo y responsabilidad, especialmente al Ph.D. Emilio Olivares Sáenz y al Ph.D. Rigoberto Vázquez Alvarado por sus consejos y disposición en todo momento, que nunca olvidaré.

Gracias al Dr. Urbano Luna Maldonado, a Arianna Ruiz González y Alan Fernando González Eguía por su ayuda y su amistad y a todas aquellas personas que de alguna manera me han apoyado y que ya han pasado a formar parte de mi vida.

ÍNDICE DE CONTENIDOS

INDICE DE CUADROS.....	X
INDICE DE FIGURAS.....	xi
RESUMEN GENERAL.....	1
CAPÍTULO 1. <i>Opuntia ficus-indica</i> L. Y LAS METODOLOGÍAS MODERNAS PARA SU FENOTIPIFICACIÓN.	3
RESUMEN	3
I. INTRODUCCIÓN.....	3
1.1.1. Transpiración de la planta.	5
1.1.2. Temperaturas para captación de CO ₂	5
1.1.3. Absorción neta máxima de CO ₂	5
1.1.4. Sistema radicular.....	6
1.1.5. Masa seca.	6
1.1.6. Senescencia de la planta.	6
1.1.7. Potencial hídrico.....	7
1.1.8. Fotosíntesis del cladodio.....	7
1.1 Aplicaciones del HSI agrícolas, alimentarias y ambientales	7
1.2.1. Aplicaciones del HSI en la agricultura	8
1.2.2. Aplicaciones del HSI en los alimentos.....	8
1.2.3. Aplicaciones del HSI en el ambiente.....	9
1.3 Aplicaciones de HSI a la fenotipificación	9
1.3.1. Procesamiento de imágenes hiperespectrales en la fenotipificación de la sequía.	9
1.3.2. Procesamiento de imágenes hiperespectrales en la fenotipificación del nopal.....	10
1.3.3. Trabajos del HSI sobre la sequía.	11
1.3.4. Procesamiento de imágenes en la sequía del nopal.	11
1.4. Algoritmos usados para el manejo de los datos obtenidos mediante la espectroscopía de imágenes en la Agricultura.....	12
1.4.1. Bosques aleatorios.....	14
1.4.2. Redes Bayesianas	14
1.4.3. Máquinas de Soporte Vectorial y Redes Neuronales.	15
1.4.4. Cadenas de Markov	15
1.4.5. K-means.....	16
1.4.6. Modelos Estocásticos	17

1.4.7. Agrupación Espacial.....	17
1.4.8. Árboles de clasificación y regresión	17
1.5. Condiciones para la adquisición de las imágenes hiperespectrales.....	17
1.6. Programas informáticos para el manejo de las HSI.....	18
II. MATERIALES Y MÉTODOS	20
III. RESULTADOS.....	20
IV. CONCLUSIONES.....	25
CAPÍTULO 2. CARACTERIZACIÓN DE CLADODIOS MADUROS DE <i>Opuntia ficus-indica</i> (L.) Miller MEDIANTE DESCRIPTORES MORFOLÓGICOS Y COLORIMÉTRICOS	26
RESUMEN	26
I. INTRODUCCIÓN	27
2.1. Descriptores morfológicos	27
2.2. Atributos de color	28
2.3. Programas informáticos utilizados	28
OBJETIVO	28
II. MATERIALES Y MÉTODOS.....	29
2.4 Material vegetal	29
2.5. Relación entre las imágenes electrónicas y algunos descriptores morfológicos.	29
2.6. Descriptores de Color.	32
2.7. Análisis Estadístico.....	34
III. RESULTADOS Y DISCUSIÓN	35
IV. CONCLUSIONES	41
CAPÍTULO 3. APRENDIZAJE AUTOMÁTICO Y PROCESAMIENTO DE IMÁGENES EN LA PREDICCIÓN DE MINERALES, CLOROFILAS, FENOLES, ANTIOXIDANTES Y RASGOS MORFOLÓGICOS DE NOPALITOS FRESCOS DEL CULTIVAR VILLANUEVA.	42
RESUMEN	42
I. INTRODUCCIÓN	42
II. MATERIALES Y MÉTODOS.....	49
3.1. Sitio experimental.	49
3.2. Muestreo y firmeza de nopalitos	49
3.3. Adquisición y preprocesamiento de imágenes hiperspectrales.....	50

3.4. Determinación de minerales (macro y micro elementos) por espectrometría de emisión atómica por inducción de plasma acoplado (ICP-AES).....	51
3.5 Análisis multivariado de los datos de las imágenes.....	51
III. RESULTADOS.....	52
III. CONCLUSIONES	59
CAPÍTULO 4. PREDICCIÓN DE LA SEQUÍA DE <i>Opuntia ficus-indica</i> L., MEDIANTE APRENDIZAJE AUTOMÁTICO Y PROCESAMIENTO DE IMÁGENES.	61
RESUMEN	61
I. INTRODUCCIÓN	62
4.1 Importancia del estudio de la sequía en la agricultura.....	62
4.2 <i>Opuntia ficus-indica</i> y la sequía.....	62
4.3 La inteligencia artificial en estudios de sequía.....	63
4.4 Aplicación del estudio de las Imágenes hiperespectrales en la sequía	64
4.5 Aplicaciones y usos de UAVs (vehículos aéreos no tripulados) y HSI para uso agrícola.....	64
OBJETIVOS	65
II MATERIALES Y MÉTODOS.....	65
4.6 Materiales.....	65
4.7 Material vegetal.....	65
4.8 Imágenes hiperespectrales a sequía.....	66
4.8.1. Imágenes hiperespectrales.....	66
4.8.2. Muestras complementarias de cladodios.....	66
4.9 Pruebas de laboratorio.....	66
4.10 Análisis de fotografías RGB y su relación con las masas de las plantas de <i>Opuntia ficus-indica</i>	67
4.11 Estadísticas.....	67
III. RESULTADOS.....	67
4.12 Análisis de los cladodios sujetos a sequía extrema.....	71
4.13 Análisis de la masa de las plantas de <i>Opuntia</i> , fotografiadas mediante un dron DJI Mini SE.....	72
IV. CONCLUSIONES	75
BIBLIOGRAFÍA	77

ÍNDICE DE FIGURAS

Figura 2.1. Diagrama de flujo del procesado con Imagej.....	31
Figura 2.2. Imágen de cladodio de nopal procesado con Imagej.....	32
Figura 2.3. Medición de los parámetros de color de las pencas maduras.....	33
Figura 2.5. Gráficos que muestran los valores medios de los atributos de color.	33
Figura 2.6. Parámetros de color L*, C y H medios de los cladodios.....	34
Figura 3.1. Intensidad de los espectros de las K-m de los 15 cladodios en 768 píxeles.....	54
Figura 3.2. Valores de predicción de las intensidades de reflexión del nopalito.....	54
Figura 3.3. coeficientes β para N y P.....	56
Figura 3.4. coeficientes β para K y Ca.....	56
Figura 3.5. coeficientes β para Mn y B..... ¡Error! Marcador no definido.	
Figura 3.6. coeficientes β para Mg, Fe, Zn and Cu	57
Figura. 3.7 coeficientes β para clorofilas a, b y Totales.	57
Figura 3.8 coeficientes β para ABTS y FRAP.....	58
Figura. 3.9 coeficientes β para Fenoles y Antioxidantes (DPPH).	58
Figura 4.1. Coeficientes de regresión para prolina y clorofilas a y Totales.....	70 ^o
Figura 4.2 Variación de la masa de cladodios sin riego.....	70
Figura 4.3 Fotografía RGB de plantas, usando dron DJI Mini SE.	72
Figura 4.4 Fotografía procesada por medio de Imagej.....	73
Figura 4.5 Índices NDVI para una planta de Opuntia.	75
Figura 4.6 Valores de NDVI de las 30 plantas de Opuntia.	75

ÍNDICE DE CUADROS

Cuadro 1.1. Relación de autores, aplicaciones de las HSI y el año.	20
Cuadro 1.2. Autor, algoritmo y año de publicación del artículo.	22
Cuadro 1.3. Relación de autor, contribución y año de publicación.	24
Cuadro 2.1. Valores mínimos, máximos, desviación estándar y coeficiente de variación (CV) de parámetros morfológicos de pencas maduras de <i>Opuntia</i>	36
Cuadro 2.2. Análisis de correlación entre parámetros morfológicos de pencas maduras de <i>Opuntia</i>	37
Cuadro 2.3. Modelos y ecuaciones de regresión no lineales y coeficiente de determinación R^2 , con nivel de confianza del 95% para los parámetros de forma.	37
Cuadro 2.4 Relación de variables, modelo matemático, valor de r y Error RMSE.	39
Cuadro 2.5. Valores promedio de los parámetros de color.	39
Cuadro 2.6. Resumen de ANOVA de los valores medios de los parámetros de color de cladodios de <i>Opuntia</i>	39
Cuadro 2.7. ANOVA de parámetros de color de cladodios de <i>Opuntia</i>	40
Cuadro 2.8. Matriz de Correlación de parámetros de color de cladodios de <i>Opuntia</i>	40
Cuadro 2.9. Modelos matemáticos de los parámetros de color de <i>Opuntia</i>	40
Cuadro 3.1. Valores de laboratorio de nutrientes de nopalitos.	52
Cuadro 3.2. Valores morfológicos usando ImageJ.	54
Cuadro 3.3. Resultados de PLSR para los nutrientes, clorofilas a, b, Totales y antioxidantes.	55
Cuadro 3.4. Valores promedio de los contenidos de minerales, clorofilas y antioxidantes medidos y los calculados (pronóst) mediante el modelo PLSR.	58
Cuadro 4.1. Análisis de medias de Tukey de los tratamientos de riego T_i ..	68
Cuadro 4.2. Análisis de varianza de la regresión para prolina ..	68
Cuadro 4.3. Análisis de varianza para Clorofila A ..	68
Cuadro 4.4. Análisis de varianza para clorofilas Totales ..	69

Cuadro 4.5. Selección y validación de modelo para prolina, Clorofila A y Totales.....	69
Cuadro 4.6 Disminución del espesor de cladodios sin riego.	71
Cuadro 4.7. Datos de color de los cladodios sujetos a sequía severa.	71
Cuadro 4.8. Valores promedio de grados Brix, pH y Resistencia a la penetración de los cladodios.	71
Cuadro 4.9. Valores calculados de las áreas A_i en cm^2 y las masas en kg.	73
Cuadro 4.10. Resultados del análisis de varianza de las masas y áreas de plantas.....	73
Cuadro 4.11. Modelos de regresión para los cinco tratamientos de riego... ..	74

RESUMEN GENERAL

Esta tesis doctoral se dividió en cuatro capítulos; en el primero, se realizó un estudio crítico de la información del cultivo de *Opuntia ficus-indica* L., la producción en nuestro país y sus características fisiológicas; se presentan también investigaciones de las aplicaciones que el procesamiento de imágenes hiperespectrales (HSI) tiene en la actualidad en el campo agrícola, alimentario y afines. Finalmente se presentan las metodologías de Aprendizaje automático (Machine Learning) empleadas para el análisis de la información derivada del procesado de Imágenes Hiperespectrales (HSI, por sus siglas en inglés) en aplicaciones agrícolas, de los alimentos, medicina y medio ambiente.

En el segundo capítulo, se ejecutó un análisis de los rasgos morfológicos de los cladodios madre de *Opuntia*, los cuales se fotografiaron usando un teléfono móvil y el programa informático ImageJ; se analizaron los cambios de color que se presentan en las etapas iniciales después de la siembra, mediante un colorímetro Minolta CR-410. Ambos conjuntos de datos de forma y de color, se trataron matemáticamente usando el software CurvExpert, para obtener los modelos de los parámetros morfológicos y de color de los cladodios; obteniéndose coeficientes de determinación desde 0.14 hasta 0.99 entre la relación de aspecto vs. Perímetro y entre la relación de aspecto vs. la redondez, respectivamente. En el estudio de color se obtuvieron coeficientes de determinación de 0.871 para b^* vs. H y de 0.999 para a^* vs. C.

En el tercer capítulo se presenta un trabajo que estudia las relaciones entre algunas de las características químicas de cladodios frescos (nopalitos) y sus imágenes hiperespectrales. Para ello se llevó a cabo un proceso de regresión para interrelacionar ambos conjuntos de datos y obtener los modelos de predicción de los macro y micro nutrientes minerales, las clorofilas y los antioxidantes versus las imágenes hiperespectrales de los cladodios frescos de *Opuntia*; Lo anterior se realizó usando Regresión de Mínimos Cuadrados Parciales (PLSR), mediante el software Minitab 2021 y preprocesado de imágenes usando Hypertools v3., se

encontraron modelos lineales con coeficientes de determinación R^2 entre 0.79 a 0.90.

En el cuarto capítulo se presenta el estudio de estrés hídrico en plantas de *Opuntia ficus-indica*, sujetas a cinco diferentes niveles de riego durante cuatro meses, tomando pesos de las plantas y datos de color y espesor de un cladodio durante ese período, al término del cual se cortaron, se fotografiaron usando un teléfono móvil con 12 Mp, después de ello se realizó el procesamiento de imágenes hiperespectrales, para luego llevar a cabo el análisis del contenido de prolina y de clorofilas para posteriormente realizar un análisis estadístico de regresión usando PLSR. Dos semanas más tarde, se hizo otro muestreo de cladodios sin riego para su HSI, grados Brix, textura, prolina y clorofilas. Como una etapa complementaria, se cosecharon todos los cladodios, dejando solo el cladodio madre. Se hizo la toma de fotografías RGB (Rojo, Verde y Azul por sus siglas en inglés) de los cladodios cosechados, usando un dron DJI MiniSE, con una resolución de 12 Mp, se midió su masa, se obtuvieron sus índices NDVI y se llevó a cabo un análisis morfológico mediante ImageJ para obtener sus áreas. Posteriormente se analizaron estadísticamente las relaciones entre las áreas calculadas y las masas, llevando a cabo un análisis PLSR, para obtener sus modelos matemáticos.

CAPÍTULO 1. *Opuntia ficus-indica* L. Y LAS METODOLOGÍAS MODERNAS PARA SU FENOTIPIFICACIÓN.

RESUMEN

En este capítulo se presentan estudios realizadas por diversos investigadores sobre el nopal y sus características biológicas, su sistema fotosintético y metabolitos más importantes; sobre las metodologías de HSI y su uso en la fenotipificación. Se presentan también aplicaciones de HSI en la agricultura, alimentos, medio ambiente y medicina, tratando de evidenciar la cada vez más amplia importancia que la espectroscopia de imágenes y sus aplicaciones ha adquirido en los últimos años, así mismo se presentan las técnicas de aprendizaje automático más usadas en las disciplinas agrícola y de alimentos.

I. INTRODUCCIÓN

El cambio climático y el incremento del número de habitantes han generado la necesidad de producir cultivos sustentables, de alto rendimiento en ambientes adversos (Drapikowski *et al.*, 2016). Las tecnologías de fenotipificación pueden acercar al fenotipo y al genotipo de las plantas, siendo por ello muy importante llevar a cabo un buen desarrollo de estas (Yao *et al.*, 2017).

La fenotipificación en el campo, al caracterizar una gran cantidad de líneas genéticas, por lo general se lleva a cabo usando sólo mano de obra y métodos destructivos, lo cual resulta muy costoso, y convierte en un reto el desarrollo de variedades de cultivos resistentes al clima. Por lo anterior, es necesario el desarrollo de sistemas automatizados de fenotipado de los cultivos para su fitomejoramiento, para lograr el desarrollo de fenotipos de alto rendimiento, precisos, consistentes y rentables para el asegurar la producción alimentaria (Vuong *et al.*, 2018).

Al respecto, en la actualidad los sensores hiperespectrales y las técnicas de HSI han demostrado un enorme potencial en la fenotipificación de plantas (Brugger *et al.*, 2019) ya que se pueden utilizar para obtener información espectral y espacial

de un objeto sobre las regiones espectrales ultravioleta, visible y de infrarrojo cercano (300 nm – 2,600 nm).

Por otra parte, las plataformas de fenotipificación recopilan imágenes, ambiente (agua, luz, temperatura, humedad) y datos físicos (peso de la planta) para cuantificar el genotipo por fenotipo por interacciones ambientales (Fahlgren *et al.*, 2015).

En años recientes, se han desarrollado plataformas de fenotipificación de alto rendimiento y tecnologías de detección para evaluaciones precisas, eficientes y rápidas de los fenotipos, especialmente en campo. En el noroeste del Pacífico, los investigadores de la Universidad Estatal de Washington y el Departamento de Agricultura de los Estados Unidos- Servicio de Investigación Agropecuaria (USDA-ARS, por sus siglas en inglés), en colaboración con los agricultores locales de productos básicos, han establecido programas de mejoramiento para los cultivos en condiciones de riego y de secano, a través de plataformas inteligentes para cuantificar los rasgos de cultivo deseados, además de procedimientos de minería de datos como apoyo a las decisiones en la mejora de cultivos, ([https://css.wsu.edu/research/breeding/.](https://css.wsu.edu/research/breeding/)) Por otra parte, Thorp *et al.* (2012) han estudiado las tecnologías de detección proximal, los sistemas geográficos de información, los modelos de simulación de desarrollo de cultivos y otras técnicas informáticas, tratando de relacionar el código genético y las características de crecimiento observables de una planta en el campo. Naik *et al.* (2017) desarrollaron un marco simple usando teléfonos inteligentes, que permiten establecer características para cuantificar la extensión del índice IDC (cantidad de amarillamiento, cantidad de café) de imágenes digitales para definir el fenotipo de la soya. Huang *et al.* (2018) han aplicado otras técnicas, como los modelos de reflectancia 3D, para minimizar los efectos de la geometría en las imágenes hiperespectrales, y mejorar significativamente el fenotipado.

El nopal y sus características.

Origen del nopal

Opuntia ficus-indica es nativa de regiones áridas y semiáridas (Winter *et al.*, 1985; Nobel & Israel, 1994) y tiene un metabolismo conocido como del ácido crasuláceo (CAM, por sus siglas en inglés) (Cui & Nobel, 1994; Nobel & De la Barrera, 2003).

1.1.1. Transpiración de la planta.

Opuntia tiene una apertura estomática nocturna, por lo que se produce una absorción neta de CO₂ y pérdida de humedad durante la parte más fría del ciclo de 24 horas. La frecuencia estomática suele ser baja para *Opuntia*, comúnmente de 20 a 30 estomas en cada mm² (Pimienta-Barrios *et al.*, 1993). *Opuntia* tiene un 1% del valor de saturación del aire de vapor de agua dentro del tejido de sus tallos y hojas (Nobel, 2011); la absorción neta de CO₂ es reforzada por la concentración de CO₂ atmosférico, así como con el aumento de las temperaturas (Drennan & Nobel, 2000).

1.1.2. Temperaturas para captación de CO₂.

La temperatura ideal para llevar a cabo la captación nocturna de CO₂ del cladodio disminuye si las plantas se someten a estrés hídrico (Nobel & Hartsock, 1984), acentuándose cuando la sequía se prolonga (Nobel, 2001). El mismo patrón decreciente de CO₂ se muestra en cladodios separados (Raveh & Nobel, 1999). Por otro lado, la presencia de cladodios jóvenes es otro factor que reduce la cantidad de absorción neta del CO₂ por los cladodios primarios (Pimienta-Barrios *et al.*, 2005).

1.1.3. Absorción neta máxima de CO₂.

Para conservar su agua, *O. ficus-indica* tiene una cutícula cerosa en sus tallos de 5 a 30 µm (North *et al.*, 1995). La cutícula cerosa y la frecuencia estomática reducida permiten que el 20% de la absorción neta máxima de CO₂ esté presente incluso un mes después de que las plantas estén en condiciones de sequía (Raveh *et al.*, 1995). Durante un estrés hídrico de *O. ficus-indica* de tres meses, la clorénquima en los tallos decrece en espesor en un 13%, y el parénquima disminuye en espesor en un 50% (Goldstein *et al.*, 1991) y sus raíces tienden a ser poco profundas, de 15 cm aproximadamente (Kausch, 1965).

1.1.4. Sistema radicular.

El sistema radicular es de solo 12% de la biomasa vegetal total (Nobel & McDaniel, 1988). Por otro lado, Snyman, (2014) estudió dos variedades de *Opuntia* de un año de plantadas en macetas y encontró que la masa de la raíz disminuyó y su longitud aumentó significativamente para ambas especies con estrés hídrico, necesitándose una aplicación de 12 a 14 mm de agua para llenar los cladodios. Por su parte, Hassan *et al.*, (2017) encontraron que las raíces de esquejes plantados en macetas de 49 y 33 L exhibieron valores significativamente mayores de longitud, peso fresco y seco en *Opuntia*, en cuanto mayor fue el volumen del suelo.

1.1.5. Masa seca.

Aunque la productividad extremadamente grande (50 t de masa seca ha⁻¹ por año) es posible para *O. ficus-indica*; la productividad prevista es de 5 a 6 t ha⁻¹ por año bajo limitaciones de agua. Se ha encontrado que la plantación vertical de cladodios de tamaño completo (12 meses de edad, 8 a 15 cm de ancho) influye significativamente en la tasa de crecimiento relativo y el peso seco a los 2, 4 y 6 meses (Singh & Singh, 2003). Por otra parte, Pérez-Cacho *et al.*, (2006) han caracterizado nopalitos, sensorial y reológicamente, obteniendo 6 atributos (acidez, dureza, masticabilidad, olor a verdura, luminosidad y paladar), que se analizaron mediante el uso la técnica estadística de Componentes principales (PCA, por sus siglas en inglés). Según Lim & Kim, (2013) la resistencia al estrés por sequía de las plantas puede ser inducido mediante rizobacterias que sirven para motivar el crecimiento de los cultivos.

1.1.6. Senescencia de la planta.

La senescencia de la planta se caracteriza por una degradación de los pigmentos y el movimiento de nutrientes de las hojas maduras hacia las más tiernas (Guiboileau *et al.*, 2010; Munné-Bosch & Alegre, 2004). Este es un proceso continuo que es invisible a simple vista. Las primeras etapas de senescencia han sido investigadas por el uso de análisis bioquímicos invasivos (Gómez, 2012). Las condiciones más extremas de sequía/calor en que *Opuntia* puede producir frutas, forraje o nopalitos sin riego, se presentan en la meseta central de México (Pimienta-Barrios *et al.*, 2005). Becerril & Valdivia, (2006) encontraron una reducción significativa de los

contenidos de clorofilas en cladodios de 24 semanas de edad sometidas a un estrés hídrico severo.

1.1.7. Potencial hídrico.

El potencial hídrico pasa de ser más grande en los cladodios más nuevos que en los cladodios maduros, a disminuir después de cuatro semanas de crecimiento en condiciones óptimas de humedad de suelo (Wang *et al.*, 1997), por el contrario, el parénquima se reduce durante la sequía (Liguori *et al.*, 2013) y el grosor total del cladodio también se reduce. El parénquima almacena o libera agua hacia la clorénquima para proporcionar un efecto amortiguador eficiente durante la sequía (Nobel & De la Barrera, 2003), mientras que el grosor de la clorénquima de los cladodios madre muestra pocos cambios entre períodos secos y húmedos (Liguori *et al.*, 2014). Por otro lado, después de dos a tres meses sin irrigación, la conductancia estomática nocturna y la acumulación de ácido son reducidos; sin embargo, la tasa y las concentraciones mayores siempre se encuentran antes del amanecer (Goldstein *et al.*, 1991).

1.1.8. Fotosíntesis del cladodio.

Después de una sequía prolongada, también la fotosíntesis se reduce en los cladodios, probablemente causado por el decremento en el contenido de agua, del contenido de clorofila y del espesor en parénquima (Pimienta-Barrios *et al.*, 2005). La presión de turgencia se reduce en un 86% en condiciones de sequía (Goldstein *et al.*, 1991). Existen aumentos muy grandes de la presión osmótica del parénquima en pitahaya (*Hylocereus undatus*) en condiciones de sequía (Nobel, 2006).

1.1 Aplicaciones del HSI agrícolas, alimentarias y ambientales

Las imágenes hiperespectrales tienen ventajas sobre las imágenes RGB, la espectroscopia NIR (infrarrojo cercano por sus siglas en inglés) y las imágenes multiespectrales, como son, la capacidad de recopilar información espacial y espectral. Debido a sus características, esta técnica ha sido aplicada en varios campos, incluidos la agricultura, la minería, la farmacéutica, la ciencia de los materiales y la ciencia de los alimentos. Las aplicaciones del procesamiento de

imágenes en la confiabilidad y el control de la calidad en alimentos, que involucra la detección de contaminantes, identificación de posibles fallas y la cuantificación de compuestos químicos (Huang *et al.*, 2018).

1.2.1. Aplicaciones del HSI en la agricultura

Pérez-Sanz *et al.* (2017) han incursionado en nuevas tecnologías, como el LIDAR de alta definición o las cámaras multi-hiperespectrales, los cuales tienen un gran potencial para mejorar en el futuro cercano, especialmente en entornos de campo, asimismo Sánchez-Méndez & Arguijo-Hernández (2018) han trabajado usando imágenes multiespectrales satelitales en la detección de patógenos en cultivos de café, resultando en la toma de buenas de decisiones.

En otro trabajo, se aplicó HSI para estudiar el daño en hojas de café variedad típica, causados por la roya amarilla (*Hemileya vastatrix*), evaluando muestras analizadas con HSI y comparadas con las clasificadas por expertos en forma visual, encontrando diferencias significativas entre ambos métodos y resultando más fiable HSI (López, 2019). Huang *et al.* (2017) hicieron trabajos en predicción de los rendimientos de los cultivos de maíz, considerando fertilización, precipitación y radiación, mientras que Shicheng *et al.* (2021) analizaron con HSI y modelaron arándanos descompuestos mediante Redes Neuronales Probabilísticas (PNN, por sus siglas en inglés) con un 97.7% de eficiencia en la detección y Kaur *et al.* (2018) en la valoración de la mineralización de azufre y nitrógeno en suelos que se trataron con residuos de los cultivos. En otro estudio Sun *et al.* (2016) demostraron que la técnica de imágenes hiperespectrales VIS y NIR son herramientas potentes para la clasificación rápida de frijoles negros. Obteniendo 98% de eficiencia.

1.2.2. Aplicaciones del HSI en los alimentos

Elmasry *et al.* (2012) han aplicado técnicas de HSI para evaluar las características de calidad de productos cárnicos, asegurando que, si se desarrolla un sistema de control de la calidad de la carne usando dichas tecnologías, se garantiza que su autenticación beneficie a esa industria, aumentando la confianza del consumidor. Verdú *et al.* (2016) emplearon esta metodología en procesos de panificación donde se mezclaron diferentes granos y se relacionaron con espectros electromagnéticos

en el rango de onda corta-infrarrojo cercano. Los resultados permitieron diferenciar significativamente las mezclas de panes estudiadas.

Usando HSI, Liu *et al.* (2014) desarrollaron un método no invasivo, que consume poco tiempo y que además es preciso y confiable para la predicción del pH y coloración de carne de puerco, mientras que Valencia *et al.* (2018) desarrollaron un dispositivo electrónico no destructivo para inspeccionar la conservación de alimentos usando empaques inteligentes de aligato de mora.

1.2.3. Aplicaciones del HSI en el ambiente

En otras aplicaciones se han estudiado imágenes hiperespectrales del entorno marino y costero del sur de la isla de Gran Canaria, para hacer levantamientos batimétricos en las superficies del fondo del mar (Vázquez Otero, 2019). También se ha usado HSI en el cambio climático y la posible contaminación ambiental (Rainville *et al.*, 2014 y Stanaway & Reeves, 2011).

De acuerdo con Lu *et al.* (2021), la firma espectral de las clorofilas a se caracteriza por una elevada absorción en el azul (443 nm) y el rojo (cerca de 675 nm), y por una alta reflectancia en las regiones del espectro verde (550-555 nm) y rojo (685-710 nm).

1.3 Aplicaciones de HSI a la fenotipificación

1.3.1. Procesamiento de imágenes hiperespectrales en la fenotipificación de la sequía.

El estrés hídrico en una planta comienza fisiológicamente cuando ésta no puede tomar agua del suelo (debido a que la energía potencial de la planta es mayor que la del agua en el suelo), lo cual provoca disminución en la capacidad de la planta para la toma de CO₂ del ambiente (Mondragón-Jacobo & Pérez-González, 2001).

Las imágenes hiperespectrales de corto rango proporcionan información espectral con altos grados de resolución temporal y espacial, siendo capaces de descubrir procesos relacionados con el estrés hídrico de manera no destructiva en las primeras etapas que son invisibles para el ojo humano (Behmann *et al.*, 2014).

Según estudios realizados (Rumpf *et al.*, 2010; Kim *et al.*, 2011; Amatya *et al.*, 2012; Sun *et al.*, 2017; Behmann *et al.*, 2014; Gago *et al.*, 2015), han sido aplicados Índices de vegetación (VIs), para caracterizar el estado fisiológico y biofísico de la planta en respuesta al estrés por sequía. El índice de reflectancia fotoquímica (PRI, por sus siglas en inglés) así como el índice de vegetación de diferencia normalizada (NDVI, por sus siglas en inglés) son los índices vegetativos (IV, por sus siglas en inglés) más utilizados para la evaluación del estrés hídrico de los cultivos. Otros índices de reflectancia como el índice de vegetación de diferencia normalizada de borde rojo (RENDVI, por sus siglas en inglés) y el índice de reflectancia de senescencia de la planta (PSRI, por sus siglas en inglés) también se han utilizado con resultados variables. Sun *et al.* (2017) en su investigación, hallaron correlaciones significativas entre el contenido de agua y el PRI, habiendo demostrado que RENDVI y NDVI son dos índices que están altamente correlacionados con el estrés por sequía de las plantas (Kim *et al.*, 2011). Además de estos índices, Behmann *et al.* (2014) reportaron PSRI como relevante indicador para detectar el estrés por sequía de la planta (Asaari *et al.*, 2019).

Asaari *et al.* (2018) han llevado a cabo estudios donde exploraron el gran potencial de HSI como herramienta para detectar respuestas tempranas al estrés por sequía en plantas cultivadas, usando una plataforma de fenotipificación de alto rendimiento (HTPPP, por sus siglas en inglés), encontrando que los espectros de reflectancia de las imágenes de hojas están altamente influenciados por la geometría de la planta y su alineación específica hacia el sistema de adquisición, lo que nos dice que la tecnología de fenotipificación de alto rendimiento puede predecir el estrés hídrico de las plantas (Pieruschka & Schurr, 2019; Gosa *et al.*, 2019; Wageningen University and Research, 2019; Sankaran, 2016), a través de un sistema de HSI en el rango del espectro UV (ultravioleta)-NIR.

1.3.2. Procesamiento de imágenes hiperespectrales en la fenotipificación del nopal.

La ingeniería agrícola tiene el desafío de satisfacer la demanda de mejora de métodos de manejo y la productividad del cultivo con mayores niveles de tolerancia

a la sequía. Por lo tanto, la identificación, cuantificación y visualización de las respuestas al estrés hídrico deben realizarse en las primeras etapas, antes de que la recuperación sea irreversible y se produzcan daños y el rendimiento no se maximice, lo cual se pudiera lograr mediante el uso de cámaras hiperespectrales, que detectan cambios senescentes en las características de reflectancia espectral de las hojas.

1.3.3. Trabajos del HSI sobre la sequía.

El estrés por sequía es el culpable de provocar la deshidratación de los tejidos y por ende la reducción en la producción de cultivos, por lo cual, la detección temprana del estrés hídrico puede ayudar a salvar cosechas y a evitar la disminución de los rendimientos agrícolas, analizados como parámetros de reflectancia. De acuerdo a Chavhan *et al.* (2021) se han encontrado diversos índices de agua comunes como el índice de agua de la planta (PWI, por sus siglas en inglés), índice de agua de relación simple (SRWI, por sus siglas en inglés), índice de agua de diferencia normalizada (NDWI, por sus siglas en inglés), índice de estrés hídrico infrarrojo de onda corta (SIWSI, por sus siglas en inglés), y el índice de adsorción de celulosa (CAI, por sus siglas en inglés) asociados a los coeficientes de estrés hídrico de las plantas.

Dao *et al.* (2021) usando espectros completos y espectros derivados obtenidos mediante HSI, integraron estos con algoritmos de aprendizaje automático avanzados para detectar y clasificar de manera temprana la sequía, probados en pasto de bromo liso (*Bromus inermis*), bajo estrés hídrico, lo que permitió la detección precisa de casos de sequía con coeficientes de determinación de hasta 97,5% y 100%, mientras que los índices espectrales y los modelos de índice espectral no detectaron el estrés temprano.

1.3.4. Procesamiento de imágenes en la sequía del nopal.

De acuerdo con Becerril & Valdivia (2006) las alteraciones fisiológicas provocadas por déficit de agua en *Opuntia* han sido poco estudiados (clorofilas y transporte fotosintético de electrones), posteriormente, Nascimento & Fett-Neto (2010) realizaron su investigación mostrando que el contenido de compuestos con capacidad antioxidante se incrementa en las plantas en condiciones de estrés

hídrico, pero aunque la detección temprana del estrés en las plantas de cultivo es muy importante, es difícil de conseguir (Behmann *et al.*, 2014). Aunque los datos combinados que estos estudios presentan son útiles, las diferencias en las técnicas y las condiciones de cultivo y la edad de los cladodios entre los diversos estudios impiden la comparación directa de los valores (Mayer & Cushman, 2019). Por otra parte, y como se tenía poca información sobre el efecto del riego sobre el contenido de compuestos fenólicos y la capacidad antioxidante en extractos de cladodios de Opuntia (Luna *et al.*, 2021) estudiaron la influencia del riego en la capacidad antioxidante y el contenido de compuestos polifenólicos de cladodios de nopal tunero.

Sin embargo, el aminoácido prolina, que se sintetiza en grandes cantidades en plantas superiores expuestas a diferentes tipos de estrés abiótico, no fue estudiado. las plantas de nopal tunero cultivadas bajo temporal o riego suplementario sintetizan prolina como defensa ante un déficit hídrico prolongado (Zegbe-Domínguez *et al.*, 2021).

Una técnica prometedora y no invasiva para el análisis de los rasgos de las plantas es la imagen hiperespectral de corto alcance (HSI), que tiene un gran potencial para la detección temprana de las respuestas de las plantas al estrés por sequía (Asaari *et al.*, 2019).

1.4. Algoritmos usados para el manejo de los datos obtenidos mediante la espectroscopía de imágenes en la Agricultura.

Existe un gran número de técnicas para el análisis de los espectros, como son las Máquina de Soporte Vectorial (SVM, por sus siglas en inglés), los Bosques Aleatorios (RF, por sus siglas en inglés), la Regresión Logística Multinomial (MLR, por sus siglas en inglés), el Perceptrón Multicapas (MLP, por sus siglas en inglés), la Red Neuronal Convolutiva (CNN, por sus siglas en inglés), aunque ninguno de estos clasificadores provee una precisión óptima, pues cada uno de ellos tiene debilidades y fortalezas en diferentes condiciones de uso (Paolletti *et al.*, 2019). Así surge un reto en la investigación usando el HSI, por la gran cantidad de datos disponibles y su integración con procesos como la mejora del cultivo, la predicción

del rendimiento, el análisis de enfermedades del cultivo, la identificación del estrés hídrico, etc. Las técnicas informáticas como el aprendizaje automático son una nueva herramienta de análisis y resolución de problemas complejos que actualmente se presentan (Elavarasan *et al.*, 2018).

En el área agrícola específicamente, se han realizado una gran cantidad de trabajos usando herramientas de ML, como los llevados a cabo por Rhee & Im (2017) quienes crearon un modelo de pronóstico de estrés hídrico de alta resolución para áreas no calibradas, usando el aprendizaje automático y la interpolación espacial. Por su parte, usando algoritmos de Árbol de Decisión, Liu *et al.* (2017) estudiaron la pérdida de grano y el pronóstico del efecto de varios parámetros, al igual que Waheed *et al.* (2006) quienes analizaron la existencia de malezas y tasas de utilización de nitrógeno; también Kim *et al.* (2011) usaron arboles de decisión al estudiar la heterogeneidad y densidad bacteriana y microbiana del suelo, mientras que Rossi Neto *et al.* (2017) cuantificaron el rendimiento del cultivo de la caña de azúcar sujeta a condiciones ambientales y edafoclimáticas diversas.

Kim *et al.* (2011) desarrollaron un marco de inteligencia artificial y un sistema de información geográfica, para predecir y mapear la diversidad bacteriana del suelo con información de bases de datos geográficos, espaciales y ambientales conocidos.

Elvanidi *et al.* (2018) al usar aprendizaje automático con imágenes hiperespectrales, han obtenido información valiosa sobre estrategias de riego y control ambiental, para cuantificar el impacto del agua y estrés por déficit de nitrógeno en la fisiología vegetal.

Las clorofilas, las antocianinas y los carotenoides son los principales causantes del espectro en el rango visible y suelen estar en diferentes cantidades y cercanamente relacionados con la fotosíntesis de las plantas (Feret *et al.*, 2008). En aplicaciones al análisis de suelos, Yu *et al.* (2016) analizaron el comportamiento de la Regresión

Multipasos de Mínimos Cuadrados (MLSR, por sus siglas en inglés) y la Regresión de Mínimos Cuadrados Parciales para analizar las HSI en huertos de manzana, resultando mejor MLSR. Mientras que Xu *et al.* (2021) estudiaron la distribución y variabilidad espacial de las diferentes fracciones de N del suelo, usando redes neuronales artificiales (ANN), árbol de regresión cubista (Cubist), k-vecino cercano (KNN), regresión de máquina de soporte vectorial (SVMR, por sus siglas en inglés) y PLSR, dando mejores resultados SVMR, para esta aplicación.

1.4.1. Bosques aleatorios

Del mismo modo Fukuda *et al.* (2013) usaron la técnica de Bosques Aleatorios (BA) para desarrollar la predicción de los rendimientos de mango en el norte de Tailandia. Asimismo, Tulbure *et al.* (2012) estudiaron el rendimiento estacional (lluvia, sedimentos del suelo, fertilizantes, etc.) de Switchgrass (*Panicum virgatum* L.) como biocombustible alternativo. También usando esta técnica, en la predicción de la sequía, se ha estudiado la cantidad de nitrógeno presente en las hojas, en la identificación de las malezas en el campo de la caña de azúcar (Rhee & Im, 2017; Yano *et al.*, 2016). Por su parte, Saussure *et al.* (2015) han usado BA para la búsqueda de soluciones para ahuyentar a los gusanos de alambre. En Australia Tulbure *et al.* (2016) usaron la información sobre las aguas superficiales en períodos largos y la cantidad de las inundaciones, en escalas subcontinentales para medir la dinámica de las aguas usando BA. Esta misma técnica de bosques aleatorios fue usada por Philibert *et al.* (2013) dando predicciones de N₂O más precisas que las obtenidas mediante regresión, siendo los factores más relevantes la duración del experimento, la tasa de nitrógeno y el tipo de cultivo.

1.4.2. Redes Bayesianas

Otra técnica utilizada para el manejo de datos agrícolas es la de Redes Bayesianas (RB), usadas para medir los recursos naturales y los factores más importantes en los cultivos (Drury *et al.*, 2017; Aguilera *et al.*, 2013). También en el trabajo de Roper *et al.* (2014), se estudiaron las redes bayesianas para la solución de modelos de distribución de tortugas moras, su clasificación, caracterización y regresión.

En predicción de los rendimientos de los cultivos también se ha trabajado con RB (Huang *et al.*, 2018; Cornet *et al.*, 2016). También, (Kaur *et al.*, 2018; Rainville *et al.*, 2014; Stanaway & Reeves, 2011), han usado RB en el análisis de la transmisión de enfermedades de los cultivos y el brote de malezas, en función del cambio climático y las posibilidades de contaminación.

1.4.3. Máquinas de Soporte Vectorial y Redes Neuronales.

La técnica de SVM fue usada por Kovačević *et al.* (2010) en la clasificación de datos de cultivos, asignando las etiquetas apropiadas y evaluando algunas propiedades hidráulicas del suelo. (Huang, *et al.*, 2018; Singh *et al.*, 2020; Kawamura-Aoyama *et al.*, 2014; Liu & Wang, 2021), trabajaron en observación temprana y la clasificación de diversas enfermedades de los cultivos, con la aplicación de fertilizantes para cultivos y el fenotipado de alto rendimiento de estrés en plantas, así como el control de la calidad en suelos.

Las Redes Neuronales Aplicadas también ha sido muy utilizadas, así Elavarasan *et al.* (2018) las aplicaron en agricultura y biología vegetal; Lu *et al.* (2019) y Rustia *et al.* (2021) lo usaron para pronosticar el rendimiento del cultivo y crear modelos para el análisis de control de plagas; Glezakos *et al.* (2010) en combinación con algoritmos genéticos lo ha utilizado en la detección de virus vegetales y Were *et al.* (2015) y Nahvi *et al.* (2016) en el pronóstico del contenido de carbono orgánico y estimación de la temperatura del suelo en combinación con algoritmos genéticos. Misra *et al.* (2009) en su estudio usaron SVM y redes neuronales artificiales, para modelar la escorrentía y evaluar los sedimentos en cuencas hidrográficas.

1.4.4. Cadenas de Markov

(Sonnadara & Jayewardene, 2015; Deni *et al.*, 2010; Tettey *et al.*, 2017), han usado estos algoritmos para determinar los patrones secos y húmedos del clima, incluso en términos de períodos más cortos como semanas. Otros, como Mandal *et al.* (2015) explican el análisis de las precipitaciones para la planificación de cultivos, utilizando las funciones de distribución de probabilidad, que prevén el inicio y la retirada de los monzones. La predicción de la sequía agrícola basada en la lluvia y la humedad del suelo que afecta el rendimiento de los cultivos, han sido estudiados por Alam *et al.* (2014) y Rahmat *et al.* (2017) usando índices de precipitación

estándar. Yaron & Olian (2002) investigaron sobre la calidad del agua con énfasis en los aspectos de la dinámica del riego salino. Kim & Lee (2017) analizaron un generador aleatorio de precipitación para datos meteorológicos diarios, de precipitación, temperatura mínima y temperatura máxima; Khadr (2016) también trabajaron para pronosticar la ausencia de lluvias por medio de un proceso al azar, Andriyas & McKee (2014) explican el comportamiento de riego en la región del delta para modelar la necesidad de riego de los agricultores y predecir sus futuras decisiones; Ip *et al.* (2018) explican la protección de cultivos detectando y manejando malezas para cuantificar la baja de rendimiento considerando el componente espacial de los sitios aledaños y construir modelos de resistencia a herbicidas.

1.4.5. K-means

Otro algoritmo usado en la agricultura es el K-means, usado en la administración de los recursos hidráulicos determinando eficientemente regiones de precipitación homogéneas utilizado por Roushangar & Alizadeh (2018). (Windarto & Wanto, 2018; Supriyatna *et al.*, 2020) usaron la minería de datos en Indonesia con tres atributos de evaluación en la producción de arroz agrupándolos en baja, media y alta. Por otra parte, Dhingra & Sinclair (2017) estudiaron la enfermedad de las hojas en las plantas identificada y clasificada en función de la infección; Gorgoglione *et al.* (2018) en Uruguay usaron el PCA, junto con el análisis de conglomerados de K-means, para identificar una variación estacional de la calidad del agua del río Santa Lucía. Huang *et al.* (2017) lo usaron en el análisis de la precipitación y los cambios climáticos de una región que influyen en el rendimiento del cultivo. También Shakeel *et al.* (2018) usaron esta técnica de agrupamiento en el análisis de pacientes con diabetes mellitus, obteniendo buenos resultados en su diagnóstico. Trabajando en el rendimiento de los cultivos por medio del análisis de datos (big data), Phasinam & Shabaz (2022) usaron los métodos de agrupación de K-means para determinar cuáles métodos de cultivo son mejores para una región en particular para estimar su rendimiento por medio de algoritmos Apriori para mejorar su rendimiento.

1.4.6. Modelos Estocásticos

Covarrubias (2018) analizó la diversidad fenotípica individual en el desarrollo de la almeja Sifón en Bahía Magdalena, por medio de seis modelos de crecimiento aleatorios, mientras que Chen *et al.* (2020) usaron este tipo de modelos en la identificación de las hojas enfermas de una planta infectada a partir de su imagen; Trevezas *et al.* (2014) también lo usaron en el análisis matemático de los modelos de crecimiento de las plantas.

1.4.7. Agrupación Espacial

Leroux *et al.* (2018) han aplicado esta técnica en la agricultura de precisión basada en la aplicación con ruidos, en la administración de la producción de cultivos usando mapas de rendimiento por medio de las características espaciales del vecindario, que apoyan el rendimiento del cultivo, mientras que Majumdar & Mahato (2018) lo aplicaron en el análisis de los datos agrícolas, en varias condiciones ambientales, la variabilidad de los precios, del suelo, y otros factores que afectan al rendimiento de los cultivos; Ferrara *et al.* (2018) estudiaron la cobertura del área forestal en una región, en función de parámetros como la estimación del área de madera, la biomasa leñosa aérea y el índice de la región foliar, mientras que Eizentals & Oka (2016) lo hicieron en la identificación del crecimiento de la fruta en las plantas en función de su posición.

1.4.8. Árboles de clasificación y regresión

Hay trabajos como el de Waheed *et al.* (2006) en los que usaron la técnica de árboles de clasificación y regresión (CART, por sus siglas en inglés) para clasificar datos hiperespectrales de parcelas experimentales de maíz sujetas a estrés hídrico, presencia de malezas y tasas de aplicación de nitrógeno, pudiendo clasificarse los 12 tratamientos con una precisión del 75% al 100% en las 3 etapas de desarrollo que se estudiaron.

1.5. Condiciones para la adquisición de las imágenes hiperespectrales.

Para la obtención de las HSI, la selección de la fuente de luz es muy importante para lograr un buen rendimiento y fiabilidad de cualquier sistema de inspección. Las lámparas halógenas se utilizan más ampliamente en los sistemas HSI para

aplicaciones con plantas en interior (Mishra *et al.*, 2017). Éstas son fuentes de iluminación de banda ancha que cubren las regiones visible y NIR, proporcionando un espectro uniforme bastante estable, aunque si se necesita iluminación de alta potencia y rango de longitud de onda pequeña (Mahlein *et al.*, 2015), los diodos emisores de luz (LED) son una buena alternativa a la iluminación halógena. La interrelación de la luz (radiación electromagnética, EMR) con las plantas, varía según las frecuencias de luz. Ya que las hojas son las principales responsables de la fotosíntesis, la interacción de la luz con éstas es de particular interés (Jacquemoud & Ustin, 2001). Para las hojas verdes, las regiones relevantes de la EMR son la región VIS (400 e 700 nm), responsable de la absorción de luz mediante las moléculas fotosintéticas; el NIR (700 e 1100 nm), dominado por la absorción de materia seca; y el infrarrojo de onda corta (SWIR) (1100 e 2500 nm), donde tiene lugar la absorción por el agua.

Brenes-Zeledón (2019) logró diseñar un sistema de control para un dron, usando el software Mission planner y Pixhawk2, así como programas en MATLAB para la obtención de los hipercubos en estudios de suelos.

Brenes-Zeledón (2019) logró diseñar un sistema de control para un dron, usando el software Mission planner y Pixhawk2, así como programas en MATLAB para la obtención de los hipercubos en estudios de suelos.

1.6. Programas informáticos para el manejo de las HSI.

Para el análisis de la cantidad de nitrógeno en suelos, Xu *et al.* (2021) Procesaron las imágenes mediante el software ENVI v5.3 (Exelis Visual Information Solutions, Boulder, CO, USA).

Por otra parte, MATLAB (The Math Works, Inc., Massachusetts), es una poderosa herramienta para procesar imágenes, usando lenguaje de alto nivel para análisis de datos, modelación y visualización de imágenes hiperespectrales, Jia *et al.* (2020).

Unscrambler (CAMO Software AS, Oslo, Norway), es otro programa quimiométrico interactivo para análisis, calibración y predicción multivariante Tysso (1987).

Hay otro programa para los HSI llamado Eigenvector (Eigenvector Research, Wenatchee, WA, USA), que efectúa Calibración multivariante y reconocimiento de patrones con PLS_Toolbox y Solo.

(http://www.eigenvector.com/software/pls_toolbox.htm).

Otra opción para HSI es hyperSpec, que puede trabajar con sistemas avanzados de visión artificial y aplicaciones aéreas.

(<https://cran.r-project.org/web/packages/hyperSpec/index.html>).

Corradini *et al.* (2021) Usaron uFTIR que es un paquete de R que permite analizar imágenes hiperespectrales FTIR, diseñado con principio modular, compatible y de código libre.

Es posible usar programas informáticos de acceso libre como Weka (<https://sourceforge.net/projects/weka/>), de acceso libre para minería de datos y aprendizaje automático; Hypertools, que es una Interfaz Gráfica de Usuario para HSI de código libre (<https://www.hypertools.org/>).

OBJETIVOS

Los objetivos de esta investigación de revisión fueron los siguientes:

- a) Realizar una búsqueda, recopilación y análisis en estudios científicos y discusión bibliográfica, relacionada con las aplicaciones de las imágenes hiperespectrales a la industria agroalimentaria que nos permita conocer el estado actual de los HSI y su posible aplicación en la detección del estrés hídrico de *Opuntia*.
- b) Realizar una investigación bibliográfica sobre las características del nopal, *Opuntia ficus-indica* y las repercusiones de la sequía sobre este cultivo.
- c) Llevar a cabo una recopilación de información de las técnicas de Inteligencia Artificial usadas en las ciencias agrícolas y en otras áreas afines, para su posible uso en el análisis de la gran cantidad de datos que se generan al aplicar las HSI en el estudio del estrés hídrico de *Opuntia ficus-indica*, así

como los programas informáticos de acceso abierto y otros, que puedan ser usados en la investigación.

II. MATERIALES Y MÉTODOS

Se llevó a cabo una búsqueda exhaustiva para hacer la recopilación de artículos científicos, tesis y libros acerca de los temas de referencia. Se buscó literatura del cultivo del nopal y sus características fisiológicas, aplicaciones del procesamiento de imágenes a las ciencias agrícolas, de alimentos, medicina y medio ambiente, así como de las técnicas de Inteligencia Artificial y los programas computacionales más usados en la actualidad.

III. RESULTADOS

La información de las aplicaciones de las HSI a la Industria Alimentaria recopilada se muestra resumida en los cuadros siguientes; en el Cuadro 1.1 se muestra un resumen de las diferentes aplicaciones de las HSI en la industria Agroalimentaria, así como los autores y el año de su publicación. En el Cuadro 1.2 se resumen las aplicaciones de diferentes algoritmos, las técnicas de Aprendizaje Automático (Machine Learning) usadas y el año de su publicación. En el Cuadro 1.3 se presentan los trabajos de investigación llevados a cabo por diferentes investigadores en relación con el nopal, características y estudios de sequía.

Cuadro 1.1. Relación de autores, aplicaciones de las HSI y el año.

Autores	Aplicación	Año
• Drapikowski <i>et al.</i>	Fenotipificación de plantas Xerofitas	2016, 2018
• Elmasry <i>et al.</i>	Calidad y control en carnes	2012
• Liu <i>et al.</i>	Predicción de color y pH en carne de puerco	2014
• Elavarasan <i>et al.</i>	Pronóstico de rendimiento de cultivos en función de factores agrícolas	2018
• Elvanidi <i>et al.</i>	Detección de plagas en tomate	2018

<ul style="list-style-type: none"> • Fouquet 	Detección de hongos en tomate	2021
<ul style="list-style-type: none"> • Ivorra • Gomes <i>et al.</i> • Matese <i>et al.</i> 	Cuantificación de Azúcar y pH en vitivinicultura.	2015
	Cuantificación de azúcares y pH en uvas.	2021
	Vitivinicultura (Review).	2015
<ul style="list-style-type: none"> • Feret <i>et al.</i> 	Propiedades ópticas y químicas en Hojas.	2008
<ul style="list-style-type: none"> • Fukuda <i>et al.</i> 	Rendimiento en mango.	2013
<ul style="list-style-type: none"> • Guolan & Baowei 	Aplicaciones médicas (Review).	2014
<ul style="list-style-type: none"> • Huang <i>et al.</i> • Tejada <i>et al.</i> 	Calidad en alimentos (Review).	2013
	Predicción del almidón en queso.	2021
<ul style="list-style-type: none"> • Yano <i>et al.</i> • Neto <i>et al.</i> • Huang <i>et al.</i> 	Detección de malas hierbas en caña.	2016
	Productividad en caña de azúcar.	2017
	Detección del barrenador en caña de azúcar.	2018
<ul style="list-style-type: none"> • Kovačević <i>et al.</i> • Kim <i>et al.</i> • Yu <i>et al.</i> • Kaur <i>et al.</i> • Xu <i>et al.</i> • Nahvi <i>et al.</i> 	Clasificación de suelos.	2010
	Diversidad bacteriana en suelos.	2011
	Análisis de suelos.	2016
	Estimación del N y mineralización de S.	2018
	Determinación de N en suelos.	2021
	Estimación de la temperatura del suelo.	2016
<ul style="list-style-type: none"> • Li <i>et al.</i> • Vivian <i>et al.</i> 	Técnicas de fenotipificación (Review).	2014
	Fenotipificación de frutos verdes.	2018
<ul style="list-style-type: none"> • López • Sánchez-Méndez. 	Detección de roya amarilla en café.	2019
	Detección de plagas en café.	2018
<ul style="list-style-type: none"> • Amatya <i>et al.</i> • Van De Vijver <i>et al.</i> 	Déficit de agua en papa.	2012
	Detección de <i>Alternaria solani</i> en Papa.	2020

• Misra <i>et al.</i>	Climatología, lluvias y escorrentía.	2009
• Deni <i>et al.</i>	Movimientos espaciales de la sequía.	2010
• Gago <i>et al.</i>	Manejo del agua sustentablemente.	2015
• Gorgoglione <i>et al.</i>	Calidad del agua.	2020
• Lu <i>et al.</i>	Mejora de la calidad del agua (Review).	2021
• Lu <i>et al.</i>	Clasificación de insectos de plagas.	2019
• Waheed <i>et al.</i>	Clasificación de niveles de humedad.	2006
• Asaari <i>et al.</i>	Detección de enfermedades en Maíz.	2019
• Asaari <i>et al.</i>	Detección de estrés hídrico en maíz.	2019
• Naik <i>et al.</i>	Clasificación de la severidad en Soja.	2017
• Rhee <i>et al.</i>	Previsión meteorológica.	2017
• Stanaway <i>et al.</i>	Estudios en plantas exóticas.	2011
• Dao <i>et al.</i>	Estudios de sequía en pastos.	2021
• Glezakos <i>et al.</i>	Detección de virus en plantas.	2010
• Majumdar & Mahato.	Identificación de hojas comunes.	2018
• Mandal <i>et al.</i>	Planeación de cultivo de arroz.	2015
• Ferrara <i>et al.</i>	Separación de maderas y hojas.	2018
• Sun <i>et al.</i>	Clasificación de frijoles negros.	2016

Cuadro 1.2. Autor, algoritmo usado y año de publicación del artículo.

Autores	Algoritmo usado	fecha
• Stanaway <i>et al.</i>		2011
• Aguilera <i>et al.</i>		2013

<ul style="list-style-type: none"> • Cornet <i>et al.</i> • Fernández <i>et al.</i> • Drury <i>et al.</i> • Huang <i>et al.</i> • Rainville <i>et al.</i> 	Redes Neuronales Bayesianas (BNN).	2016 2014 2017 2017 2014
<ul style="list-style-type: none"> • Aurore <i>et al.</i> • Fukuda <i>et al.</i> • Yano <i>et al.</i> 	Bosques aleatorios (RF).	2013 2013 2016
<ul style="list-style-type: none"> • Behmann <i>et al.</i> • Ivorra. • Huang <i>et al.</i> • Kovačević <i>et al.</i> • Misra <i>et al.</i> 	Máquinas de soporte vectorial (SNV).	2014 2015 2018 2010 2009
<ul style="list-style-type: none"> • Naik <i>et al.</i> • Rhee <i>et al.</i> • Liu <i>et al.</i> 	Aprendizaje Automático (ML)	2017 2017 2017
<ul style="list-style-type: none"> • Kim <i>et al.</i> • López. • Neto <i>et al.</i> 	Arboles de decisión.	2011 2019 2017
<ul style="list-style-type: none"> • Asaari <i>et al.</i> 	Variable Normal Estándar (SNV).	2019
<ul style="list-style-type: none"> • Paoletti <i>et al.</i> 	Técnicas de clasificación (Review).	2019
<ul style="list-style-type: none"> • Perez-Sanz. 	Algoritmos en Imágenes (Review).	2017
<ul style="list-style-type: none"> • Waheed <i>et al.</i> 	Arboles de clasificación y regresión.	2006
<ul style="list-style-type: none"> • Yu <i>et al.</i> 	MLSR y PLSR.	2016
<ul style="list-style-type: none"> • Xu <i>et al.</i> 	KNN, ANN, SVMR, PLSR.	2021

• Andriyas & Mckee	Modelos de Markov.	2014
• Khadr.	Modelos de Markov	2016
• Covarrubias.	Distribución normal y multinomial.	2018
• Keshava.	Algoritmos de desmezclado.	2003
• Lu <i>et al.</i>	Redes generativas adversariales.	2019
• Dao <i>et al.</i>	Bosques A., SVM y Perceptrón MI.	2021

Cuadro 1.3. Relación de autor, contribución y año de publicación.

Autor	Contribución	Año
• Aguilar <i>et al.</i>	Alteraciones Fisiológicas en sequía.	2006
• Aguilar <i>et al.</i>	Fitoquímicos del semidesierto mexicano.	2008
• Vázquez-Alvarado <i>et al.</i>	Cultivo hidropónico del nopal.	2009
• Bárcenas.	Acumulación de prolina en las raíces .	1999
• Crop Ecology.	Cultivo CAM para un mundo seco y caliente.	2017
• Cruz & Lara.	Rentabilidad del nopal verdura.	2009
• FAO.	cultivation and uses of cactus pear.	2017
• FAO.	Plant Production and protection, Cactus.	2001
• García.	Identificación de pectinas y mucilago.	2013
• Gómez-LLallahui.	Información de una crema a base del mucilago del nopal.	2016
• Landa Salgado <i>et al.</i>	Persistencia de Salmonela Typhimurium en Nopal verdura.	2013
• López-Borja <i>et al.</i>	Variación morfológica en <i>Opuntia jaliscana</i> .	2017
• Maki-Díaz <i>et al.</i>	Características fisicoquímicas de nopal verdura para exportación y consumo interno.	2015
• Molina	Caracterización y clasificación numérica en nopal mediante características morfológicas	2001

	y fisicoquímicas.	
• Mondragón-Jacobo & Pérez-González	Cactus as Forage.	2002
• Orona Castillo <i>et al.</i>	Rendimiento del agua en el cultivo de nopal usando riego por goteo.	2003
• Rodríguez & Fortiz.	Calidad de nopalito cortado y envasado con películas plásticas durante su refrigeración.	2017
• SAGARPA.	Factibilidad para el establecimiento de cultivo de nopal (opuntia).	2015
• Talemi & Sedaghatthoor.	Estudio de las propiedades bioquímicas de diferentes partes de tres especies de <i>Opuntia</i> .	2017
• Torres-Ponce <i>et al.</i>	Nopal: planta del semidesierto y sus aplicaciones.	2015

IV. CONCLUSIONES

Se puede concluir que las aplicaciones del HSI son muy importantes y se ha avanzado a pasos enormes; sin embargo, aún falta mucho por hacerse en el desarrollo de procesos de fenotipificación para diversos cultivos, así como la incorporación de las técnicas del HSI para los mismos.

Por otra parte, las metodologías de aprendizaje automático (ML), también se han desarrollado e incorporado a los diversos programas informáticos existentes como Matlab, Minitab, Xlstat, R, Phyton, Hypertools, Weka entre otros, impulsados, particularmente por el incremento en la velocidad y capacidad de los sistemas computacionales y en las altas características de las cámaras hiperespectrales modernas.

CAPÍTULO 2. CARACTERIZACIÓN DE CLADODIOS MADUROS DE *Opuntia ficus-indica* (L.) Miller MEDIANTE DESCRIPTORES MORFOLÓGICOS Y COLORIMÉTRICOS

RESUMEN

México es el principal productor mundial de *Opuntia ficus-indica*. Esta especie de nopal es el cactus más extendido y de mayor importancia comercial en México. Los descriptores morfológicos y colorimétricos se encuentran entre los rasgos agronómicos más importantes porque afectan el rendimiento, de tal manera. El objetivo de esta investigación fue presentar una metodología rápida y confiable para obtener la relación funcional en los parámetros de forma y color, de los cladodios de *Opuntia ficus-indica*, utilizando un teléfono inteligente, un colorímetro y un software de libre acceso.

La adquisición de imágenes y su procesamiento descubrieron interesantes relaciones entre las características morfológicas de los cladodios de *Opuntia*, así como los parámetros colorimétricos de los mismos. Los comportamientos no lineales de los datos se ajustaron utilizando modelos determinísticos y el software CurveExpert. Como resultados, los mejores descriptores morfológicos fueron la circularidad frente al perímetro ($r= 0.9815$) y la relación de área frente a la redondez ($r= 0.9999$).

Además, los valores medios de los parámetros de color L^* , C y H , se mostraron en una ventana de un programa informático en línea. También, se comprobó que la relación a^* vs. C de los parámetros de color tuvo el mayor coeficiente de correlación (0.999). Por lo tanto, se puede concluir que las relaciones de descriptores morfológicos: circularidad vs. perímetro, relación de área vs. redondez y los parámetros de color a^* - C pueden predecir de forma rápida y precisa la calidad de las pencas para semilla de *Opuntia ficus-indica*.

I. INTRODUCCIÓN

México es líder mundial en el cultivo de *Opuntia ficus-indica* (nopal). En 2019 se cosecharon 863,000 toneladas de nopal fresco en 12,471.09 hectáreas; 34,000 toneladas anuales de este nopal se exportaron a otros países, principalmente a Estados Unidos y Canadá. En el estado de Nuevo León el rendimiento promedio de nopal fue de 38 t ha⁻¹ (SIAP, 2021). Sin embargo, la producción de cladodio fresco (nopalito) de *Opuntia ficus-indica* en México podría verse afectada por la selección de las pencas maduras para siembra.

2.1. Descriptores morfológicos

Los descriptores morfológicos delinean las características específicas con respecto a la geometría de un rasgo particular, de tal manera que la medición de las características físicas de las plantas, técnica conocida como fenotipificación, ha dado a los investigadores la oportunidad de relacionarlas con la composición genética de las plantas, tal como lo han realizado Farina (2020) en sus estudios de la soya, o Gutiérrez (2020) con su investigación de la caracterización morfológica del cacao blanco y morado. Morales-Morales *et al.* (2019) indican que caracterización de las plantas se basa en descriptores morfológicos, como la forma, el color y el tamaño de la semilla, además de sus atributos cuantitativos como el contenido de minerales.

Aunque la forma de un cladodio de *Opuntia* no puede reconstruirse conociendo los descriptores morfológicos, estos pueden ser variables discriminantes de la forma de los cladodios (Wirth, 2001 y Bober, 2001). Los descriptores morfológicos se han aplicado con éxito para la evaluación de diversas formas biológicas en animales y plantas (D'Silva & Bhuvaneshwari, 2015; Žunić, 2012) así como también en el estudio de Laouadi *et al.* (2020), que proporcionaron una base de trabajo sobre la morfología de las cabras locales en la región de Laghouat por la vía de la caracterización fenotípica.

Según Iwata *et al.* (2004), la cuantificación de la forma debe ser un requisito antes de evaluar la herencia de las características morfológicas en la genética cuantitativa.

La caracterización morfológica es necesaria porque proporciona información sobre las características y la estructura de los objetos (Cheesa, 2010). La identificación de descriptores altamente discriminantes es importante para obtener una clasificación eficiente y reproducible de las pencas maduras de *Opuntia ficus-indica*. La importancia taxonómica potencial de la morfología de las plantas y los frutos ha sido reconocida por biólogos, genetistas y agricultores (Visa *et al.*, 2014).

El análisis morfológico ha avanzado con las modernas tecnologías de adquisición, procesamiento y caracterización de las imágenes de las plantas y ha adquirido mucha importancia para la selección, y los estudios taxonómicos (Brewer *et al.*, 2006; Newton & Kendrick, 1990).

2.2. Atributos de color

Por otra parte, el color es una cualidad sensorial importante para proporcionar la información básica de calidad para la percepción humana, y tiene una estrecha relación con la frescura, la madurez, la variedad, la conveniencia y la seguridad alimentaria. Por lo tanto, los descriptores colorimétricos son parámetros importantes de clasificación de los productos agrícolas y alimentarios (McCaig, 2002). En la medición del color de los alimentos, el espacio de color $L^* a^* b^*$ es el más utilizado debido a la distribución uniforme de los colores y porque es perceptualmente uniforme (McGuire, 1992; Leon *et al.*, 2006).

2.3. Programas informáticos utilizados

El uso de los programas de libre acceso ImageJ y CurveExpert permite llevar a cabo el estudio de los parámetros de forma y de color de pencas maduras de *Opuntia* en forma más rápida y efectiva.

OBJETIVO

El objetivo de esta investigación fue presentar una metodología rápida y fiable para obtener la relación funcional entre los parámetros de forma y color de los cladodios de *Opuntia ficus-indica*, utilizando un teléfono inteligente, un medidor de color y software de libre acceso.

II. MATERIALES Y MÉTODOS

2.4 Material vegetal

Se seleccionaron visualmente cladodios de *Opuntia ficus-indica* de un año de edad del cultivar Villanueva y fueron cortados de la planta por personal con experiencia en el manejo de plantas de *Opuntia* del rancho Alejandra en Zuazua, Nuevo León; ubicado geográficamente a 25 ° 52' 03" de Latitud Norte y 100 ° 05'18" de Longitud Oeste, localizado a 30 km del sitio experimental. Las pencas maduras fueron desinfectadas con una solución de 1 kg de cal más 1 kg de sulfato de cobre diluida en 98 L de agua y posteriormente sembradas en macetas de 22 L con suelo migajón arcilloso.

2.5. Relación entre las imágenes electrónicas y algunos descriptores morfológicos.

Se fotografiaron individualmente treinta pencas maduras y todas las imágenes obtenidas se procesaron con la plataforma libre ImageJ versión 1.51j8 para estimar los descriptores de forma. En ImageJ se puede mostrar, editar, analizar, procesar, guardar e imprimir fotogramas (imágenes) de 8, 16 y 32 bits en escala de grises y de 8 y 24 bits en color. Como primer paso, cada imagen de extensión jpg se abrió desde el directorio correspondiente dentro de una carpeta en un ordenador personal y se transformó en una imagen de 8 bytes. Se estableció el umbral, se convirtió en una máscara y se transformó en una imagen binaria. Posteriormente, se invirtió la imagen binaria y se estableció la escala de cm a píxeles, se configuraron los descriptores morfológicos deseados, y de nuevo se invirtió la imagen y finalmente se analizaron las pencas maduras de *Opuntia* con el software Imagej (Figuras 2.1 y 2.2). Se utilizaron un total de 12 descriptores morfológicos (Área, Longitud, Longitud del eje menor, Perímetro, Diámetro del feto, Relación de aspecto, Compacidad, Redondez, Fuerza, Centroide, Centro de masa y Kurtosis) para construir el conjunto de datos y el análisis estadístico para caracterizar las pencas maduras de *Opuntia* y determinar el uso potencial de estos descriptores para su clasificación.

Los formatos de imagen, incluyendo TIFF, GIF, JPEG, BMP, DICOM, FITS y 'raw' pueden ser importados y leídos como imágenes individuales o pilas e incorpora

varias herramientas útiles para el procesamiento de imágenes (Hartig, 2013), y utiliza una forma eficiente de preprocesamiento de imágenes utilizando la ecualización de histogramas para seleccionar adecuadamente la región de interés (Veena *et al.*, 2016).

Los descriptores de forma analizados fueron:

a) Área: El área de la penca madura medida como el número de píxeles de su silueta de contorno.

b) Longitud del eje mayor: La longitud de la línea más larga que puede dibujarse a través de la penca madura, medida como la distancia en píxeles en los puntos extremos.

c) Longitud del eje menor: La longitud de la línea más larga que se puede dibujar a través de la penca madura perpendicular al eje mayor, medida como la distancia en píxeles en los puntos extremos.

d) Perímetro: Longitud que corresponde al contorno cerrado de n vértices de una figura, que es la suma de los lados que forman el polígono (límite poligonalizado o vectorizado).

e) Diámetro de Feret: Diámetro de un círculo con la misma área que un objeto, calculado con la fórmula: $FD = \sqrt{(4 * \text{área}) / \pi}$.

f) Relación de aspecto (AR): La relación entre la longitud de la penca madura de *Opuntia* y su anchura.

g) Compacidad: Proporciona una medida de la redondez de la penca madura: si es 1 la penca madura es aproximadamente circular, cuando disminuye en 1, la penca madura es menos circular, calculada como $C = FD / \text{Longitud del eje mayor}$.

h) Redondez o circularidad: Medida de redondez o circularidad (relación área-perímetro) que excluye el objeto del área de un círculo con el mismo perímetro convexo. Si la relación es igual a 1, el objeto es un círculo perfecto, cuando la relación disminuye en 1, el objeto sale de una forma circular, calculada como $R = [(4\pi * \text{área}) / \text{perímetro}^2]$.

- i) Resistencia: Mide la densidad de un objeto.
- j) Centroide: Media de las coordenadas x e y de todos los píxeles de la imagen o selección.
- k) Centro de masa: Media ponderada del brillo de las coordenadas x e y de todos los píxeles de la imagen o una selección. Utiliza las coordenadas XM e YM. Estas coordenadas son los momentos espaciales de primer orden.
- l) Kurtosis: El momento de cuarto orden por encima de la media.

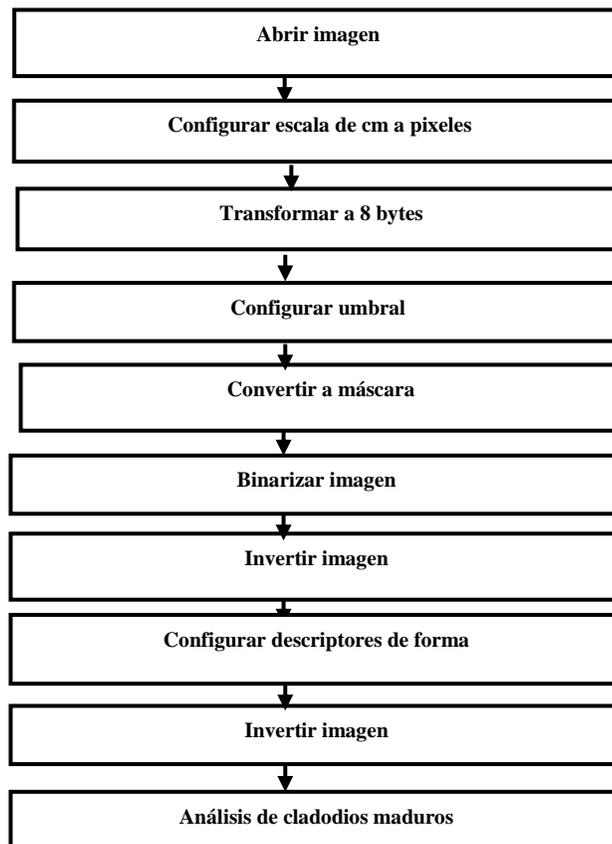


Figura 2.1. Diagrama de flujo del procesado con ImageJ.

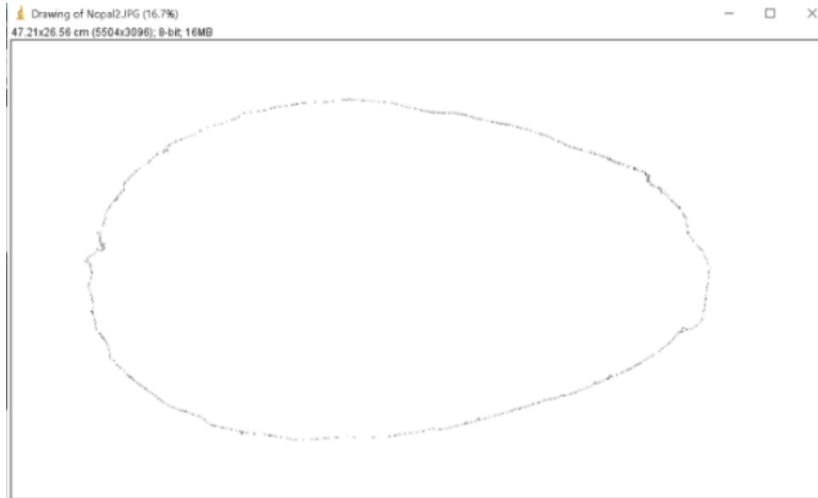


Figura 2.2. Imagen de cladodio de nopal procesado con ImageJ.

2.6. Descriptores de Color.

Los parámetros de color de 30 cladodios de *Opuntia* que se sembraron en macetas de 22 litros y se midieron cada semana, durante 16 semanas desde octubre de 2019 hasta febrero de 2020. Los parámetros a, b, C, L y H, se obtuvieron utilizando un medidor de color Konica Minolta CHROMA METER CR-410, con un iluminante estándar C, observadores estándar de 2° y un campo de visión con un diámetro de 8 mm, apertura de 50 mm. La figura 2.3 muestra cómo se tomó el color en el espacio de color $L^* a^* b^*$; donde L^* es la luminosidad; a^* es la cromaticidad del verde al rojo; y b^* es la cromaticidad del azul al amarillo. También se midió el tono del color ($^\circ H$).

La correlación entre los parámetros de color, a^* , b^* , C, y H, se muestran en los parámetros de la esfera de color (Figura 2.4) donde $C^* = (a^{*2} + b^{*2})^{1/2}$ y $H = \arctan(b^* / a^*)$ (Grajeda-González *et al.*, 2019).



Figura 2.3. Medición de los parámetros de color en las pencas maduras.

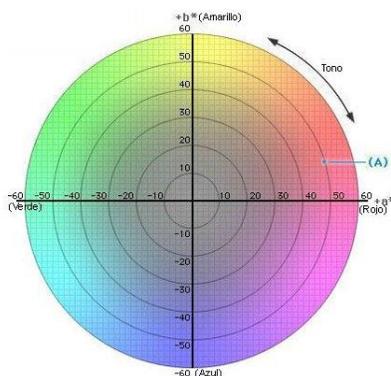


Figura 2.4. Esfera del espacio de color L*a*b*.

Los parámetros L *, a * y b * se obtuvieron tomando la media de dos medidas realizadas en dos lados opuestos del nopal (Figura 2.5).

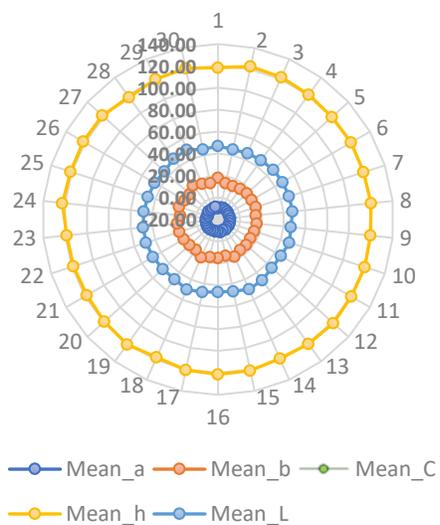


Figura 2.5. Valores medios de los atributos de color.

Para mostrar los colores correspondientes a los valores medios de los parámetros de color medidos de $L^*a^*b^*$, utilizamos un programa en línea de Johnston (Figura 2.6) (Johnstone, 2019).



Figura 2.6. L^* , C y H medios de los cladodios.

2.7. Análisis Estadístico.

Se realizaron estadísticas descriptivas y se analizaron un total de 12 variables cuantitativas, obteniéndose parámetros como la media, el mínimo, el máximo y el coeficiente de variación (Cuadro 2.1). Se llevó a cabo un análisis de la varianza (ANOVA), que indicó diferencias significativas con una baja probabilidad de error.

Posteriormente, se ejecutó un análisis de correlación entre los parámetros morfológicos para buscar una relación entre ellos (Cuadro 2.2). Debido a la distribución de los datos, se llevó a cabo un análisis de regresión no lineal de alto nivel utilizando el programa gratuito CurveExpert Pro: 2.6.5. Mediante un análisis de regresión no lineal (RNL), se obtuvieron los modelos matemáticos para la combinación de siete pares de los parámetros morfológicos más importantes, con su correspondiente coeficiente de determinación a un nivel de confianza del 95% (Cuadro 2.3).

Se realizó estadística descriptiva para las variables de color, valores medios de los parámetros de color de todas las pencas maduras (Cuadro 2.5), y se obtuvieron parámetros como la media y la varianza (Cuadro 2.6). También se realizó un análisis de varianza para los parámetros de color L^* , a^* , b^* , C y h; indicando diferencias significativas con muy baja probabilidad de error (Cuadro 2.7). Posteriormente se realizó un análisis de correlación entre los parámetros de color de los cladodios de *Opuntia* (Cuadro 2.8) y finalmente se aplicó un análisis de regresión no lineal

utilizando el software CurveExpert (Hyams, 2010), obteniéndose las ecuaciones y modelos matemáticos mostrados en el Cuadro 2.9.

III. RESULTADOS Y DISCUSIÓN

Se redujo el tiempo de análisis de las imágenes de las pencas maduras de *O. ficus-indica* para obtener variables cuantitativas relacionadas con su morfología externa, con una precisión de hasta 9 dígitos significativos.

El peso de las pencas maduras osciló entre 682.95 g y 1299.4 g, la superficie de las mismas osciló entre 337.941 y 618.512 cm², y la longitud del eje mayor osciló entre 28.086 cm y 38.511 cm. Los resultados obtenidos del análisis de varianza indicaron una diferencia significativa con un nivel de confianza del 95% en las pencas maduras de *Opuntia* para todos los tratamientos. Los valores medios, la desviación estándar y la amplitud de las demás variables se muestran en el Cuadro 2.1, así como el coeficiente de variación, que osciló entre el 0.75% y el 70.6%; sin embargo, la mayoría de las variables mostraron un coeficiente de variación inferior al 10%.

Los resultados obtenidos para los parámetros de forma a partir del análisis de correlación mostraron factores de correlación de 0.99 para la Relación de Aspecto vs. la Redondez, y de 0.96 para el Perímetro vs. la Circularidad (Cuadro 2.2). Los resultados del análisis de regresión no lineal, utilizando CurveExpert, indicaron una fuerte relación entre los siguientes parámetros Perímetro vs. Área ($R^2= 0.805$), Circularidad vs. Área ($R^2= 0.88$), Diámetro de Feret vs. Área ($R^2= 0.88$), Circularidad vs. Perímetro ($R^2= 0.96$), Diámetro de Feret vs. Perímetro ($R^2= 0.90$), Redondez vs. Circularidad ($R^2= 0.76$), Relación de aspecto vs. Circularidad ($R^2= 0.75$), Relación de aspecto vs. Redondez ($R^2= 0.99$). Hubo otros parámetros con una relación menos fuerte como la solidez frente al área ($R^2= 0.46$), la solidez frente al perímetro ($R^2= 0.41$), el diámetro de Feret frente a la circularidad ($R^2= 0.21$), la solidez frente a la redondez ($R^2= 0.58$), la solidez frente a la relación de aspecto ($R^2= 0.57$) y el resto de los pares mostraron una relación baja, con un coeficiente de correlación menor (Cuadro 2.3). Los parámetros de mayor coeficiente de correlación, así como el tipo de modelo matemático propuesto, se muestran en el Cuadro 2.4.

Además, se obtuvo el valor medio de los parámetros de color de los 30 cladodios (Cuadro 2.5), mostrando muy poca variabilidad a lo largo del tiempo (Figura 2.5). utilizamos un programa online para visualizar los parámetros L*a*b* medidos, observando una gran similitud con la vista humana (Figura 2.6).

El análisis ANOVA indicó diferencias altamente significativas en las variables de color a niveles de confianza de 1% (Cuadro 2.7). Se obtuvo el coeficiente de correlación R^2 y el modelo matemático no lineal, siendo el más alto entre a* vs. C (0.999), así como entre b* vs. H (0.821) (Cuadro 2.9).

Los cambios en la coloración de *Opuntia ficus-indica*, así como las formas y tamaños de los cladodios son factores de interés para los investigadores. Aquí presentamos una metodología utilizando el programa gratuito ImageJ, que no se había utilizado en *Opuntia*, pero que se ha utilizado con éxito para la extracción de datos de microscopía Hartig (2013), en la delineación de quistes para la identificación de quistes/lesiones en estudios dentales Veena *et al.* (2016). En cuanto al freeware CurveExpert, resultó ser eficiente y rápido, habiendo sido utilizado por Shah *et al.* (2017), con buenos resultados en modelos de predicción de escorrentía utilizando la lluvia como único predictor, obteniendo R^2 de 95%, similares a los que se obtuvieron, mientras que en su investigación, Aponte (2017) estimó la productividad de *L. laevigatum* (Hydrocharitaceae) (producción de biomasa, carbono y proteínas) en laboratorio, estableciendo un modelo matemático logístico con R^2 de 99%. Estos investigadores obtuvieron coeficientes de determinación como aquellos que se obtuvieron usando Curve Expert.

Cuadro 2.1. Valores mínimos, máximos, desviación estándar y coeficiente de variación (CV) de parámetros morfológicos de pencas maduras de *Opuntia*.

	Área	Xm	Ym	Perímetro	Ancho	Alto
Media	451.891	17.638	14.706	87.807	33.401	18.720
Valor Mín.	337.941	15.012	11.747	73.048	28.086	15.848
Valor Máx.	634.531	21.91	18.611	144.918	38.511	22.797

Desv. Estd.	71.916	1.668	1.723	18.349	3.050	1.779
C V %	15.900	9.457	11.718	20.89	9.130	9.502
	Circularidad	Diámetro Feret	Kurtosis	Razón Aspecto	Redondez	Solidez
Mean	0.768	33.494	1.977	1.807	0.557	0.986
Valor Mín.	0.329	28.372	-0.021	1.510	0.488	0.956
Valor Máx.	0.870	38.653	5.624	2.050	0.662	0.993
Desv. Estd.	0.132	3.028	1.395	0.149	0.047	0.007
CV %	17.142	9.040	70.600	8.274	8.456	0.751

Cuadro 2.2. Análisis de correlación entre parámetros morfológicos de pencas maduras de *Opuntia*.

	Área	Perímetro	Circularidad	Diámetro Feret	Razón Asp.	Redondez	Solidez
Área	1						
Perímetro	0.844	1					
Circularidad	-0.688	-0.963	1				
Diámetro Feret	0.862	0.679	-0.570	1			
Razón Asp.	-0.033	-0.101	0.031	0.453	1		
Redondez	0.0279	0.087	-0.011	-0.454	-0.996	1	
Solidez	-0.405	-0.378	0.344	-0.476	-0.171	0.160	1

Cuadro 2.3. Modelos y ecuaciones de regresión no lineales y coeficiente de determinación R^2 , con nivel de confianza del 95% para los parámetros de forma.

Variables relacionadas	Ecuación del modelo	R^2
Perímetro vs. Área	$Perímetro = 119.5606 + 43.4425 \cos(0.008214 \text{Área} - 0.01434)$	0.805
Circularidad vs. Área	$Circularidad = 0.3824 + \frac{0.4292 \text{Área}^{-115.092}}{542.744^{-115.092} + \text{Área}^{-115.092}}$	0.881
Diámetro Feret vs. Área	$Diámetro Feret = \frac{38.1158}{(1 + e^{(19.8949 - 0.0373 \text{Área})})^{\frac{1}{25.5921}}}$	0.882
Razón Aspecto vs. Área	$Razón Aspecto = 1.7963 + 0.099 \cos(.0984 \text{Área} - 6.8176)$	0.169
Redondez vs. Área	$Redondez = 0.5559 + 0.03 \cos(0.03875 \text{Área} + 2.7462)$	0.177

<i>Solidez vs. Área</i>	$Solidez = 0.983 + 0.00836 \cos(0.0235Área + 8.9817)$	0.462
<i>Circularidad vs. Perímetro</i>	$Circularidad = 2.152 - 0.01166Perímetro + \frac{2558}{Perímetro^2}$	0.963
<i>Redondez vs. Perímetro</i>	$Redondez = 0.547 + 0.04 \cos(0.0871Perímetro + 0.4945)$	0.158
<i>Razón Aspecto vs. Perímetro</i>	$Razón Aspecto = e^{11.626 - \frac{195.75}{Perímetro}} - 1.96 \ln(Perímetro)$	0.147
<i>Solidez vs. Perímetro</i>	$Solidez = 0.977 + \frac{0.0123Perímetro^{-8.51}}{88.6^{-8.51} + Perímetro^{-8.51}}$	0.410
<i>Diámetro Feret vs. Perímetro</i>	$Diámetro Feret = \frac{37.83}{(1 + e^{177.83 - 1.94Perímetro})^{1/134}}$	0.901
<i>Redondez vs. Circularidad (Circ)</i>	$Redondez = 0.949 + (1 - 0.949)[1 - e^{1.82Circ - 58.7Circ^2 + 82.7Circ^3 - 41.68Circ^4}]$	0.763
<i>Razón Aspecto vs. Circularidad</i>	$Razón Aspecto = 1.04 + (1 - 1.04)[1 - e^{26Circ - 87.8Circ^2 + 128Circ^3 - 66.6Circ^4}]$	0.746
<i>Solidez vs. Circularidad</i>	$Solidez = 0.987 + .0049 \cos(189Circularidad - 2.629)$	0.244
<i>Diámetro Feret vs. Circularidad</i>	$Diámetro Feret = 37.885 - 7.374e^{-0.0002Circularidad^{-34.287}}$	0.584
<i>Razón Aspecto vs. Redondez</i>	$Redondez = \frac{151.293}{(1 + \frac{Razón Aspecto}{0.0066})}$	0.999
<i>Solidez vs. Redondez</i>	$Solidez = 0.987e^{-5025.24 - 1030.468Redondez}$	0.582
<i>Diámetro Feret vs. Redondez</i>	$Redondez = 0.538 + \frac{1 - 0.538}{1 + e^{-66.594 + 20.208 \ln(Diámetro Feret)}}$	0.315
<i>Solidez vs. Razón Aspecto (AR)</i>	$Solidez = \frac{0.969 - 0.473AR}{1 - 0.497AR + 0.0046AR^2}$	0.568
<i>Diámetro Feret vs. Razón Aspecto (AR)</i>	$Diámetro Feret = 278.281 \cos(AR + 40.579) + 81.885 \cos(2AR + 40.579) + 92.281 \cos(3AR + 40.579)$	0.347
<i>Diámetro Feret vs. Solidez</i>	$Diámetro Feret = \frac{(32.599)(5541785617429.7) + 37.474Solidez^{-1803.857}}{5541785617429.7 + Solidez^{-1803.857}}$	0.314

Cuadro 2.4. Relación de variables, modelo matemático, valor de r y RMSE (Error Cuadrático Medio, por sus siglas en inglés).

<i>Variables Relacionadas</i>	<i>Modelo propuesto</i>	<i>valor r</i>	<i>RMSE</i>
<i>Perímetro vs. Área</i>	<i>Regresión Sinusoidal</i>	0.897	21.583
<i>Circularidad vs. Área</i>	<i>Regresión DR. Hill.</i>	0.939	-----
<i>Diámetro Feret vs. Área</i>	<i>Regresión Richards</i>	0.939	2.869
<i>Circularidad vs. Perímetro</i>	<i>Regresión Heat Capacity</i>	0.981	0.787
<i>Diámetro Feret vs. Perímetro</i>	<i>Regresión Richards</i>	0.949	33.359
<i>Redondez vs. Circularidad</i>	<i>Regresión DR multistage-4</i>	0.873	0.440
<i>Razón Aspecto vs. Circularidad</i>	<i>Regresión DR multistage-4</i>	0.864	0.182
<i>Razón Aspecto vs. Redondez</i>	<i>Regresión Modelo Weibull</i>	0.999	0.060
<i>Solidez vs. Área</i>	<i>Regresión Sinusoidal</i>	0.679	0.005
<i>Solidez vs. Perímetro</i>	<i>Regresión DR Hill</i>	0.640	0.004
<i>Diámetro Feret vs. Circularidad</i>	<i>Regresión Modelo Weibull</i>	0.764	2.65
<i>Solidez vs Redondez</i>	<i>Regresión Exponential Decline</i>	0.763	0.984
<i>Solididez vs Razón Aspecto</i>	<i>Regresión Modelo Gaussiano</i>	0.753	1.366

Cuadro 2.5. Valores promedio de los parámetros de color.

	Cromaticidad a*	Cromaticidad b*	Valor C	Valor H	Luminosidad L*
Media	-9.059	14.592	17.234	121.930	47.084

Cuadro 2.6. Resumen de ANOVA de los valores medios de los parámetros de color de cladodios de *Opuntia*.

Fuente	SS	df	Ms	F	Probabilidad	FCritica
Entre var.	299150	4	74787.415	46541.39487	2.9711E-224	2.434

Dentro	233	145	1.607
Total	299383	149	

Cuadro 2.7. ANOVA de parámetros de color de cladodios de *Opuntia*.

Grupos	Numero	Suma	Medias	Varianza
Media de a*	30	-266.94	-8.90	0.25
Media de b*	30	461.56	15.39	1.96
Media de C	30	531.15	17.70	2.24
Media de h	30	3606.40	120.21	1.92
Media de L	30	1425.56	47.52	1.66

Cuadro 2.8. Matriz de Correlación de parámetros de color de cladodios de *Opuntia*.

Matriz de correlación	Media de a*	Media de b*	Media de C	Media de h	Media de L
Media de a*	1				
Media de b*	-0.759	1			
Media de C	-0.819	0.993	1		
Media de h	0.222	-0.789	-0.723	1	
Media de L	-0.244	0.577	0.554	-0.672	1

Cuadro 2.9. Modelos matemáticos de los parámetros de color de *Opuntia*.

Var. Relacionadas	Modelos Matemáticos	R ²	RSME

a^*-c	$a = \frac{-2.341 * c}{1 + 0.292 * c - 0.00482 * c^2}$	0.999	0.403
b^*-h	$b = 16.59 + 2.356 * \cos(0.489 \cdot h + 87.914)$	0.821	1.176
$c-b^*$	$c = 36.967e^{-e^{(0.963-0.0826b)}}$	0.807	1.461
$h-c$	$h = 108.375e^{\left(\frac{1.823}{c}\right)}$	0.724	0.987
$L-h$	$L = 47.526 + 1.31 \cos(0.671 \cdot h + 65.344)$	0.682	0.860

IV. CONCLUSIONES

Los resultados obtenidos en la investigación muestran que el procesamiento de imágenes y la modelización lineal y no lineal permitieron caracterizar la morfología y el color de las pencas maduras de *Opuntia ficus-indica* (cladodios del cultivar Villanueva) de un año de edad utilizando la plataforma ImageJ y el software CurveExpert.

Se obtuvieron valores de coeficientes de correlación significativos para los descriptores de forma de los modelos de regresión no lineal entre 8 pares de parámetros, 5 más con un valor medio, de los 21 parámetros, con un nivel de confianza del 95%. Para las características de color obtuvimos valores de coeficientes de correlación muy buenos para los parámetros a^* vs. C y b^* vs. H.

Se espera que esta investigación sea un protocolo útil para quienes deseen realizar un trabajo similar de caracterización del color y la morfología con cladodios maduros de diferentes variedades u otras semillas o productos.

CAPÍTULO 3. APRENDIZAJE AUTOMÁTICO Y PROCESAMIENTO DE IMÁGENES EN LA PREDICCIÓN DE MINERALES, CLOROFILAS, FENOLES, ANTIOXIDANTES Y RASGOS MORFOLÓGICOS DE NOPALITOS FRESCOS DEL CULTIVAR VILLANUEVA.

RESUMEN

El nopal (*Opuntia ficus-indica* L.), es un cultivo muy popular en México y es necesario el desarrollo de tecnologías para la implementación de controles no destructivos de los nopalitos. En esta investigación se combinó el uso de imágenes hiperespectrales y algoritmos de aprendizaje de máquina para predecir la cantidad de Nutrientes, clorofilas y antioxidantes en cladodios frescos de *Opuntia ficus-indica* (L), cultivar Villanueva. Inicialmente, se adquirieron y preprocesaron imágenes hiperespectrales utilizando un espectrógrafo y una cámara digital CCD de altas prestaciones apoyados por programas MATLAB R 2019a e HyperTools v3. Posteriormente, se realizaron análisis de laboratorio para determinar los minerales N, P, K, Ca, Mg, Fe, B, Mn, Zn y Cu, así como antioxidantes, clorofilas a, b y Totales en nopalitos. Finalmente, se calcularon modelos de regresión usando mínimos cuadrados parciales, mediante Minitab 2021, a partir de los datos de las imágenes frente a los contenidos químicos de los nopalitos. Los valores de los coeficientes de determinación fueron de 0.98 para el P, hasta 0.77 para ABTS y las varianzas desde 0.7 hasta 0.87. El uso de Regresión de Mínimos cuadrados Parciales (PLSR por sus siglas en inglés) y la metodología de K-means, para el procesamiento de imágenes, muestran ser herramientas adecuadas, reflejado esto en los valores de R^2 .

I. INTRODUCCIÓN

Opuntia ha sido promovido para hacer frente al cambio climático en diferentes regiones del mundo, especialmente en aquellas que sufren de falta de agua ya que minimizan la pérdida de esta durante la fotosíntesis (Nefzaoui & Ben Salem, 2001). Por otra parte, las *Opuntia* tienen frutos exóticos y no tradicionales, ricos en

fitoquímicos (polifenoles y betalaínas) benéficos para la salud (Ramadan, 2021; Bouzoubaa *et al.*, 2014). En sus investigaciones Kalegowda *et al.* (2015), encontraron que la pulpa de cladodios de *Opuntia dillenii* es una buena fuente de K, Na, Ca, Mg y Fe. Por otra parte, Rice-Evans *et al.* (1997), en sus estudios demuestran las propiedades antioxidantes de los componentes polifenólicos de plantas, que ayudan a mantener el estado antioxidante y proteger contra el daño de los radicales libres.

El ser humano, entra en contacto con el entorno a través de su percepción del color pudiendo ser o no aceptables en término de su cromaticidad, así, Delgado-Vargas *et al.* (2000), elaboraron un trabajo de recopilación, haciendo hincapié en los principales pigmentos vegetales y su obtención: carotenoides, antocianinas y betalaínas.

La cuantificación del contenido mineral, clorofilas, antioxidantes y fenoles, se realiza de forma destructiva, lenta y tediosa, En este sentido, se han desarrollado las imágenes hiperespectrales (HSI) como un método rápido para evaluar estos parámetros de calidad, de forma no destructiva; así, Yendrek *et al.* (2017), estudiaron la reflectancia foliar hiperespectral como enfoque de fenotipado para la evaluación rápida y precisa de los rasgos fotosintéticos y bioquímicos de las hojas de maíz. Por otra parte, los atributos fotoquímicos de las plantas pueden caracterizarse espectralmente mediante índices de vegetación, basados en mediciones radiométricas (690-740 nm) en el espectro visible, el infrarrojo cercano y la onda corta (Pinto *et al.*, 2019; Lowe, 2017; Costa *et al.*, 2020). La tecnología HSI es útil para el fenotipado de alto rendimiento, en la determinación de la madurez de los frutos, el estado fisiológico de la planta, los ataques de parásitos y las malas hierbas.

El concepto de imágenes hiperespectrales (HSI) se originó en la espectrometría de imágenes (Liu *et al.*, 2015), esto a mediados de la década de los 80, posteriormente, una nueva técnica de teledetección de la tierra se desarrolló en el Laboratorio de Propulsión a Chorro (JPL) del Instituto Tecnológico de California en Pasadena,

afiliado a la Administración Nacional de Aeronáutica y del Espacio (NASA). Los sensores aéreos y espaciales permitieron la identificación de los materiales de la superficie directamente y a distancia; se obtuvieron imágenes de la superficie observada simultáneamente, con valores de reflectancia procedentes de hasta 200 bandas espectrales contiguas en el espectro (Goetz *et al.*, 1985), (Benelli *et al.*, 2020).

El uso del procesamiento de imágenes hiperespectrales (HSI) es efectivo en la detección de aflatoxinas en hortalizas, de una manera rápida y no destructiva. Atas *et al.* (2012), reportaron mediante un sistema compacto de visión artificial y aprendizaje automático haber clasificado chiles contaminados con aflatoxinas de los no contaminados.

El-Guezzane *et al.* (2021) observaron en ensayos sobre *Opuntia ficus-indica* y *Opuntia megacantha* que los extractos de los cultivares de *Opuntia ficus-indica* presentaron una mayor actividad antioxidante, así como un mayor contenido de compuestos fenólicos.

En otros estudios, Fàbregas & Fernie (2019) indicaron que la regulación metabólica es uno de los mecanismos usados para mantener el potencial osmótico de las células bajo estrés abiótico, siendo los perfiles de metabolitos los más usados para caracterizar las respuestas moleculares al estrés.

Por otra parte, la cuantificación del contenido de antioxidantes como licopeno y polifenoles se lleva a cabo de forma destructiva consumiendo tiempo y trabajo, por lo cual se han desarrollado métodos rápidos para evaluar esos parámetros de calidad de forma no destructiva, como los llevados a cabo por Szuvandzsiev (2014), quien reporta modelos de predicción usando Regresión de mínimos cuadrados parciales entre datos espectrales y los valores obtenidos de los resultados analíticos. Se menciona que los resultados permitieron obtener las firmas espectrales y para esto se utilizó un espectro-radiómetro, se evaluó el puré de cinco variedades de frutos de tomate.

Pinto *et al.* (2019), mencionan que la reflectancia de los espectros de luz cambia con el tipo de planta, el contenido de agua en los tejidos y otros factores intrínsecos basándose en investigaciones sobre estudios de madurez en aguacate, lo anterior permitió establecer que los atributos biofísicos de las plantas pueden caracterizarse espectralmente mediante índices de vegetación basados en mediciones radiométricas, en los rangos visible, infrarrojo cercano y de onda corta.

La banda del espectro electromagnético del infrarrojo cercano, (690-740 nm) tiene gran importancia en la respuesta espectral para el material vegetal verde, debido a que la clorofila absorbe fuertemente las longitudes de onda hasta unos 700 nm, ya que el material tiene una baja reflectancia en este rango, pero refleja fuertemente alrededor de 720 nm (Lowe, 2017).

Para el fenotipado de campo no invasivo y de alto rendimiento, Yendrek *et al.* (2017) han probado la aplicación de la reflectancia hiperespectral de la hoja como un enfoque de fenotipado para la evaluación rápida y precisa de los rasgos fotosintéticos y bioquímicos de las hojas del maíz.

Wang *et al.* (2018), capturaron imágenes del dosel de arroz con un espectrómetro de imágenes (Cubert S185 Imaging Spectrometer), con una resolución espectral de 4 nm y un rango de 450-950 nm; y obtuvieron imágenes hiperespectrales de las hojas de arroz, para cuantificar el contenido de clorofila a partir de los espectros refinados de las hojas de 58 plantas de arroz y estimar su rendimiento.

Estudios realizados por Sofy *et al.* (2017), indicaron que la acumulación de proteínas y de prolina es uno de los efectos más inducidos por la salinidad como mecanismo de resistencia al estrés.

Por su parte, Costa *et al.* (2020), propusieron un nuevo índice de diferencias de vegetación normalizadas que denotaron vNDVI, el cual demostró ser muy preciso estimando los valores NDVI, mediante el uso de imágenes RGB, con un porcentaje de error medio global del 6.89% y un error medio de 0.052 en uvas, en caña de azúcar y cítricos, resultando una alternativa de bajo costo para la fenotipificación de plantas y la teledetección.

Por otra parte, Fathipoor *et al.* (2019), evaluaron la altura de plantas de maíz forrajero usando cámaras RGB montadas en vehículos aéreos no tripulados. Las imágenes se procesaron mediante las plataformas Minitab 2018 y el software R para obtener los índices de vegetación.

En otro estudio, Dambergs *et al.* (2019), utilizaron las imágenes hiperespectrales para discriminar las uvas rojas y blancas infectadas y no infectadas por *Botrytis*. También, identificaron las quemaduras de sol y el arrugamiento en las uvas, así como otras impurezas como cañas, madera, pecíolos, hojas e insectos, producto de la cosecha mecánica.

En otras aplicaciones, Kamruzzaman *et al.* (2012), evaluaron el potencial de los HSI en el infrarrojo cercano auxiliados con el uso del análisis multivariado para discriminar tres tipos de músculos de cordero, obteniendo una discriminación del 100%.

De acuerdo con Benelli *et al.* (2020), La tecnología de HSI, mediante la detección directamente en el campo no está aún muy extendida, pero es prometedora, siendo útil para el fenotipado de alto rendimiento, el cual nos permite determinar la fisiología de la planta, la madurez de frutos, presencia de malas hierbas y parásitos, para planear la producción.

Como otra posibilidad, Kusumiyati *et al.* (2021) predijeron atributos de calidad como los sólidos solubles y el contenido de agua en varios productos de Cucurbitaceae mediante un espectrómetro de mano han aplicado la segunda derivada de Savitzky-Golay y el método de regresión de componentes principales PCR en los espectros para evaluar los atributos de calidad interior de las frutas de forma rápida y no destructiva.

Las imágenes hiperespectrales generalmente tienen un gran número de datos, por lo que existen muchos algoritmos de pre-procesamiento y procesamiento, para la reducción dimensional tales como el análisis de componentes principales PCA, que se utiliza para eliminar efectos de la información redundante, encontrando un nuevo conjunto de variables latentes llamadas componentes principales PC, que se

expresa como una combinación lineal de características originales. Los CPs no están correlacionadas y se determinan con el objetivo de capturar la varianza máxima en los datos proporcionados (Lavadiya *et al.*, 2021).

El ser humano, entra en contacto con el entorno a través de su percepción del color pudiendo ser o no aceptables en término de su cromaticidad, así, Delgado-Vargas *et al.* (2000), elaboraron un trabajo de recopilación, haciendo énfasis en los principales pigmentos vegetales y su obtención: betalaínas, carotenoides y antocianinas.

Al ejecutar PCA en los cubos de imágenes, se realiza una transformación lineal que des correlaciona datos multivariados reduciendo y/o rotando los ejes del espacio original. Cada componente explica un cierto porcentaje de la varianza, el primer componente (PC1) explica la máxima varianza, el segundo componente (PC2) es otra parte sustancial, así hasta cubrir el 100% de la varianza explicada.

De acuerdo con Amigo *et al.* (2015) lo primero a eliminar en los análisis de HSI, es el ruido instrumental en los espectros; algunas de las técnicas más aceptadas son los métodos de suavizado de Savitzky-Golay, los métodos de Variable Normal Estándar (SNV por sus siglas en inglés), o los de Corrección Multiplicativa de la Dispersión (MSC por sus siglas en inglés), para disminuir el efecto de la dispersión de la luz en el rango NIR de la radiación.

Otra técnica muy utilizada para el preprocesado de imágenes es la de K-means. El algoritmo de agrupamiento K-means con k centroides seleccionados, trata de agrupar un conjunto de datos en k clústeres de características semejantes, en función de las distancias entre el conjunto de datos asociados al centroide más cercano a ellos.

Para el análisis de HSI se hace uso del análisis multivariado, así, Dao *et al.* (2021), demostraron la utilidad de integrar el aprendizaje profundo y los datos hiperespectrales en estudios relacionados a la sequía en pastos.

Barbin *et al.* (2012), llevaron a cabo estudios en carne de cerdo encontrando que los coeficientes de Regresión de Mínimos Cuadrados Parciales (PLSR, por sus

siglas en inglés), se pueden usar para seleccionar algunas longitudes de onda relacionadas con cada atributo medido y reducir la dimensión espectral de la imagen hiperespectral, permitiendo el uso de instrumentos multiespectrales más económicos para la evaluación en serie la calidad de la carne. Izzo *et al.* (2019) encontraron que las curvas hiperespectrales frecuentemente exhiben variables predictoras correlacionadas, provocando multicolinealidad, dada la naturaleza contigua de los datos espectrales, además de tener muchas más variables predictoras que muestras, por lo que hay que reducir la dimensionalidad de los datos hiperespectrales. Para ello se puede usar PLSR, un método que permite minimizar la covarianza entre predictores, a la vez que considera las respuestas y maximiza la covarianza entre predictores y respuesta.

Si los Factores de Inflación de la Varianza (VIF por sus siglas en inglés), para cualquiera de los predictores en un modelo MLR exceden cinco, entonces se puede asegurar que existe un nivel significativo de colinealidad y el uso de PLSR para transformarse en componentes no correlacionadas se justifica aún más (O'Brien *et al.*, 2007).

Los primeros usos de modelización usando PLSR se basaban únicamente en la validación cruzada interna para evaluar el rendimiento del modelo, ahora se recomienda la división del conjunto de datos completo en uno de entrenamiento del modelo (calibración) y otro de validación fuera de la muestra para proporcionar una evaluación más sólida y precisa de la predicción, especialmente en el caso de grandes conjuntos de datos (Burnet, 2021). Hay otras propuestas como la realizada por Boente, *et al.* (2020), quienes han propuesto el uso de técnicas paramétricas combinadas con métodos paramétricos, encaminadas a eficientizar los análisis y resolver el problema de la alta dimensionalidad (Aneiros *et al.*, 2019).

De acuerdo con Andrade-Garda *et al.* (2013), en la aplicación de PLSR, el problema es definir los pesos de las variables de tal manera que el máximo de la información de X e Y son extraídos y al mismo tiempo, relacionados entre sí, dado que la técnica analítica sugiere que estos bloques de datos, que representan dos aspectos diferentes de los mismos materiales verdaderos deben estar relacionados.

Así, aunque hay un buen número de aplicaciones en la rama agroalimentaria, el aprendizaje automático y el procesamiento de imágenes aún no se han aplicado a la predicción del contenido de nutrientes minerales, clorofilas y antioxidantes de nopalitos.

OBJETIVO

El objetivo de este estudio fue realizar un análisis de PLSR de algunos compuestos químicos de nopalitos vs. imágenes hiperespectrales para obtener modelos matemáticos que correlacionen las imágenes hiperespectrales de nopalitos y su contenido de nutrientes minerales, contenido de clorofilas y de antioxidantes. Además, obtener con ImageJ algunas características morfológicas relevantes del nopalito.

II. MATERIALES Y MÉTODOS

3.1. Sitio experimental.

La adquisición y el procesamiento de las imágenes hiperespectrales y las pruebas de textura de los cladodios frescos (nopalitos) se realizaron en el Laboratorio de ingeniería de la Facultad de Agronomía de la Universidad Autónoma de Nuevo León, en el municipio de General Mariano Escobedo, N.L., y las pruebas químicas se realizaron en el Laboratorio de Mejoramiento de Semillas de la Universidad Autónoma Agraria Antonio Narro en Buenavista, Saltillo, Coahuila, México.

3.2. Muestreo y firmeza de nopalitos

Se cosecharon nopalitos del tercer nivel de plantas de *Opuntia ficus-indica* de dos años, plantadas en macetas con suelo franco arcilloso sin fertilizar.

Los 15 nopalitos, se pesaron en una balanza de precisión, se fotografiaron con un teléfono móvil iPhone 11 y se procesaron las imágenes con el software ImageJ, para adquirir sus descriptores morfológicos. Posteriormente, se determinó la firmeza del cladodio, utilizando un analizador de textura TA. XT Plus texture analyzer (Stable Micro Systems, Reino Unido) pinchando en tres puntos de cada cladodio fresco de *Opuntia* utilizando un punzón de 1 mm de diámetro. La velocidad de la sonda fue

de 2 mm s^{-1} . La firmeza del cladodio se determinó como la fuerza de firmeza máxima en N.

3.3. Adquisición y preprocesamiento de imágenes hiperspectrales

Las imágenes hiperspectrales se adquirieron con una cámara de amplio espectro modelo PIKE F210b (Allien Vision Technologies GmbH, 2018), cuyo rango espectral es de 400 a 1000 nm. Está acoplada a un espectrógrafo modelo ImSpector V10E (Specim, Spectral Imaging Ltd., 2018), y su resolución es de 2.8 nm.

Previa a la adquisición de imágenes, se encendió el sistema de imágenes hiperespectrales para lograr la estabilidad térmica y temporal (Babellahi *et al.*, 2020). La velocidad se fijó en 30 fotogramas por segundo (fps) con un tiempo de exposición de 20 ms. Se aplicó una velocidad de movimiento de 7 mm s^{-1} para obtener la mejor relación de aspecto del cuadro, por lo que se adquirieron imágenes hiperespectrales de cladodios frescos, con dimensiones de $1024 \times 768 \times 600$, las dos primeras dimensiones son coordenadas espaciales, y la tercera dimensión es el valor espectral para crear un hipercubo. El hipercubo se construyó mediante programas informáticos en Matlab. Para eliminar el ruido, se realizó la agrupación de K-means dentro del software Hypertools v3.

Una vez obtenidos los arreglos de la matriz de firmas hiperespectrales y los centroides de K-means, se aplicó el algoritmo PLSR con validación cruzada para encontrar el número óptimo de componentes y luego se usaron en el algoritmo PLSR, para su análisis, según la ecuación (3.1) siguiente:

$$Y = XW_h(P_h'W_h)^{-1}C_h' + \varepsilon_h \quad (3.1)$$

donde Y es la matriz de variables dependientes, X es la matriz de variables explicativas; W_h es la matriz de pesos de X , generada por el algoritmo; P_h' es la matriz de cargas, transpuesta; C_h' es la matriz de pesos de Y , transpuesta; ε_h es la matriz de residuos. El subíndice h de la ecuación 3.1 indica el número de componentes a usar.

Para el procesamiento PLSR utilizado para todos los valores de reflectancia de las imágenes de cladodios frescos de *Opuntia*, se realizó una validación cruzada, para

optimizar el número de componentes, usándose $h=9$ para los minerales y $h=5$ para el resto de las variables.

3.4. Determinación de minerales (macro y microelementos) por espectrometría de emisión atómica por inducción de plasma acoplado (ICP-AES).

Se pesaron muestras de los cladodios frescos de *Opuntia* y fueron secadas en un horno Yamato DX 602C (Yamato Scientific Co, Japón) a 60°C durante 72 horas y después de ello se pulverizaron con un mortero, separando 10g de harina de nopal, los cuales se sometieron a digestión ácida en una mezcla de ácido perclórico y ácido nítrico (Alcántar and Sandoval, 1999). Nitrogen (N) se cuantificó mediante el método micro Kjendahl según Bremner (1965). Los contenidos (mg/100 g) de fósforo (P), potasio (K), calcio (Ca), magnesio (Mg), hierro (Fe), boro (B), manganeso (Mn), zinc (Zn) y cobre (Cu), se determinaron mediante el extracto de digestión ácida utilizando un espectrómetro de emisión atómica por inducción de plasma acoplado (ICP-AES Agilent 725-ES, Agilent Technologies, Estados Unidos).

Para obtener las clorofilas, se realizó mediante lo descrito por Delgado-Vargas *et al.* (2000). A 0,5 g de muestra de pulpa se le añadieron 25 mL de metanol al 80% y fueron homogeneizados, luego se centrifugaron a 5000 g por 5 min. a 4 °C., y se obtuvo el valor de absorbancia a 663, 646 y 470 nm. Los cálculos se realizaron con las fórmulas (3.2, 3.3 y 3.4) descritas a continuación:

$$\text{Clorofila a: Ca} = 12.25A_{663} - 2.29A_{646}. \quad (3.2)$$

$$\text{Clorofila b: Cb} = 21.5A_{645} - 5.21A_{663}. \quad (3.3)$$

$$\text{Clorofila Total: C(a+b)} = 7.15A_{663} + 18.71A_{470}. \quad (3.4)$$

Para determinar la capacidad antioxidante se utilizó el método ABTS propuesto por Rice-Evans *et al.* (1997) y modificado por Ozgen *et al.* (2006), para FRAP y DPPH.

3.5 Análisis multivariado de los datos de las imágenes

Los datos hiperespectrales (adquisición y extracción de información espacial y espectral) se obtuvieron a partir de imágenes de cladodios frescos de *Opuntia*, utilizando Matlab R2019a. Se redujeron los espectros mediante la técnica Variable

Normal Estándar (SNV, por siglas en inglés) y la agrupación de color de las imágenes de nopalitos se realizó con la técnica de K-Means, utilizando el programa HyperTools v3, ya que las variables son numerosas y esta técnica tiende a hacer la agrupación computacionalmente más eficiente que otras como la agrupación jerárquica (Ji *et nobe* 2020, 2020; Shakeel, 2018). Finalmente, se realizó un análisis estadístico de regresión por mínimos cuadrados parciales (PLSR) con Minitab v2021 (Cheng, 2017).

III. RESULTADOS

Los nopalitos cosechados tuvieron un peso medio de 103 g y una resistencia media a la penetración de 20,6 N (2.10 kg). Los contenidos minerales, cantidad de clorofilas, y antioxidantes de los cladodios frescos se indican en el Cuadro 3.1, expresando los valores mayores en porcentaje y el resto en ppm.

Cuadro 3.1. Valores de laboratorio de nutrientes de nopalitos.

N %	P %	K %	Ca %	Mg %
1.67	0.16	1.65	3.13	0.337
Fe ppm	Cu ppm	Zn ppm	Mn ppm	B ppm
31.65	4.71	10.49	22.15	41.71
Fenoles	AntioxDPPH	AntioxABTS	AntioxFRAP	
_mgAg	_mgET	_mgET	_mgET	
56.21	5.69	31.9	23.03	
clorofilas a	clorofilas b	clorofilas T		
5.41	2.17	7.58		

Los valores de nutrientes minerales en nopalitos son similares con el control encontrado por Zúñiga-Tarango *et al.* (2009), y Santiago-Lorenzo *et al.* (2016) ya que no se realizó ninguna fertilización al suelo de nuestras plantas.

Las imágenes de los nopalitos, una vez procesadas con ImageJ, proporcionaron los valores morfológicos medios de los cladodios, que se muestran en el Cuadro 3.2, ya que ImageJ cuenta con rutinas de sustracción del fondo de la imagen y puede calcular el área, las estadísticas de los valores de los píxeles, las distancias y los ángulos de las selecciones definidas por el usuario, así como crear histogramas de densidad y gráficos de perfiles de líneas (Hartig, 2013).

Se realizó el análisis PLSR utilizando los valores de intensidad de reflectancia, la matriz (15x768) como variable independiente. Se realizó la agrupación de K-means de la imagen de nopalitos. En la ecuación 3.5 se muestra un modelo general para el uso de PLSR.

$$[M_{(15 \times 17)}] = \beta_{oi} + [\lambda_{(15 \times 768)}][\beta_{(768 \times 17)}] + \varepsilon_{(15 \times 17)} \quad (3.5)$$

donde M es la matriz de 10 minerales y 7 metabolitos de 15 cladodios, que es la variable dependiente; β_{oi} los coeficientes constantes; λ la matriz de 768 píxeles de intensidad de reflectancia de los 15 cladodios, las variables independientes; β son los valores de la matriz de 768 coeficientes para las 17 variables y ε es el error. A partir del análisis de la varianza (Cuadro 3.3), se obtuvieron los valores del error cuadrático medio, el coeficiente de determinación (R^2) y el nivel de significancia estadística para los contenidos minerales, clorofilas y antioxidantes.

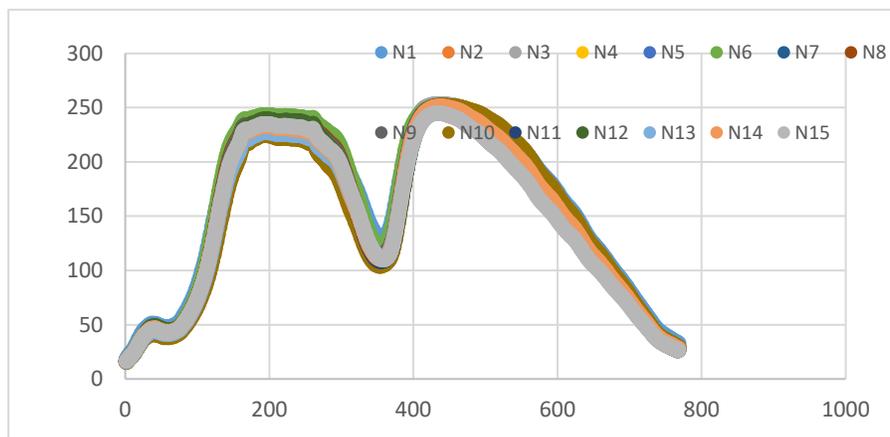


Figura 3.1. Intensidad de los espectros de las K-means de los 15 cladodios en 768 píxeles.

Figure 3.1. muestra λ calculada por los pixeles evaluados. Los valores de R^2 estuvieron en el rango de 98% en el Mn, a 99% en los demás y mostraron la variación en los contenidos minerales explicados de 0.702 en los fenoles, hasta 0.871, por lo que los contenidos minerales afectan significativamente las reflectancias. A partir del análisis de PLSR, se obtuvieron los valores estimados de λ y se muestran gráficamente en la Figura 3.2.

Se calcularon los coeficientes de regresión para los nutrientes minerales, clorofilas y antioxidantes en 768 píxeles. Los valores se muestran en las Figuras 3.3 a la 3.9.

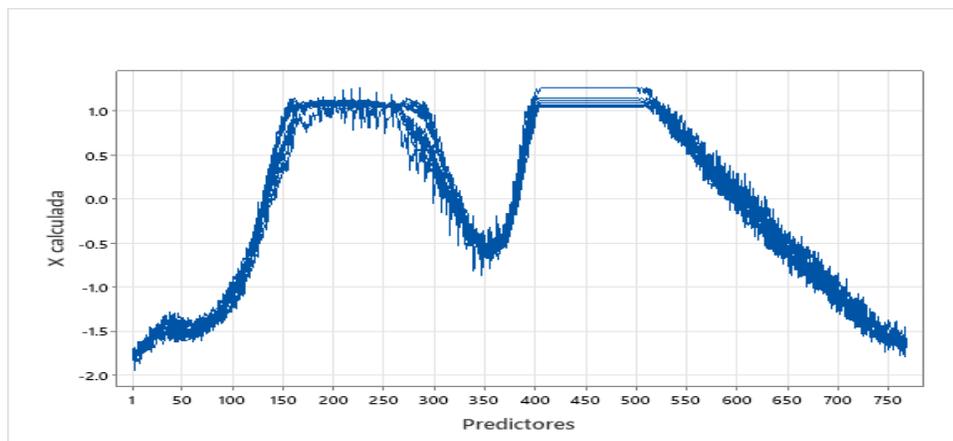


Figura 3.2. Valores de predicción de las intensidades de reflexión del nopalito.

Cuadro 3.2. Valores morfológicos usando ImageJ.

Área (cm ²)	Perím. (mm)	Circularidad	Razón/Aspecto
212.19	621.29	0.78	1.62
Redondez	Solidez	Lmáx. (mm)	Lmín. (mm)

0.62	0.98	211.86	133.74
------	------	--------	--------

Cuadro 3.3. Resultados de PLSR para los nutrientes, clorofilas *a* (Cl_a), *b* (Cl_b), *totales* (Cl_t) y antioxidantes.

Cont.	valor F	valor p	Varianza	RMSE	R ²
N	5.3	0.04*	0.871	105.12	0.905
K	12.45	0.00**	0.871	189.04	0.957
P	49.23	0.04**	0.871	5.667	0.988
Ca	5.56	0.04**	0.871	230.13	0.909
Mg	7.92	0.02**	0.871	40.919	0.934
Fe	8.4	0.01**	0.871	0.306	0.937
Cu	11.16	0.01**	0.871	0.059	0.952
Zn	16.62	0.00**	0.871	0.099	0.967
Mn	12.45	0.01**	0.871	0.453	0.957
B	10.02	0.01**	0.871	0.489	0.947
Cl_a	46.16	0.00**	0.715	0.377	0.962
Cl_b	158.23	0.00**	0.715	0.086	0.988
Cl_T	127.67	0.00**	0.715	0.317	0.986
Fen	26.84	0.00**	0.702	4.020	0.937
DPPH	3.48	0.050*	0.702	1.753	0.659
ABTS	5.99	0.010**	0.702	5.328	0.769
FRAP	28.01	0.00**	0.702	1.484	0.937

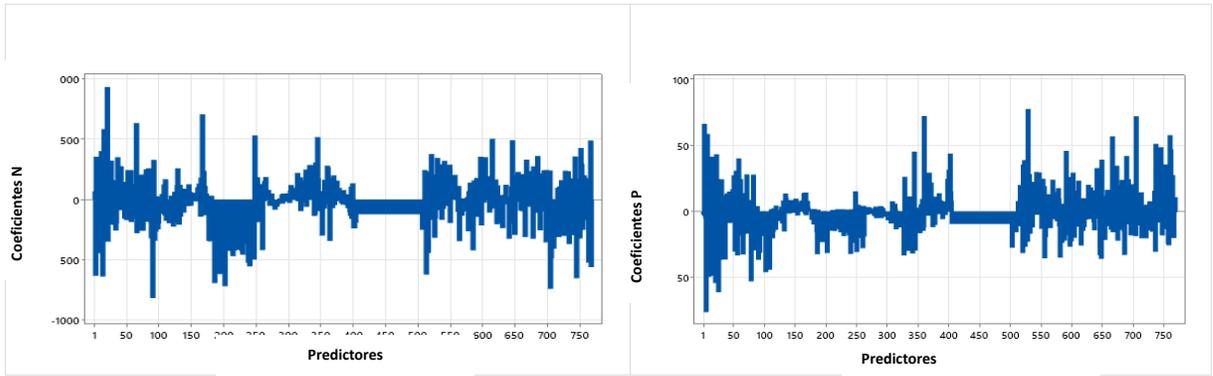


Figura 3.3. Coeficientes $\hat{\beta}$ para N y P.

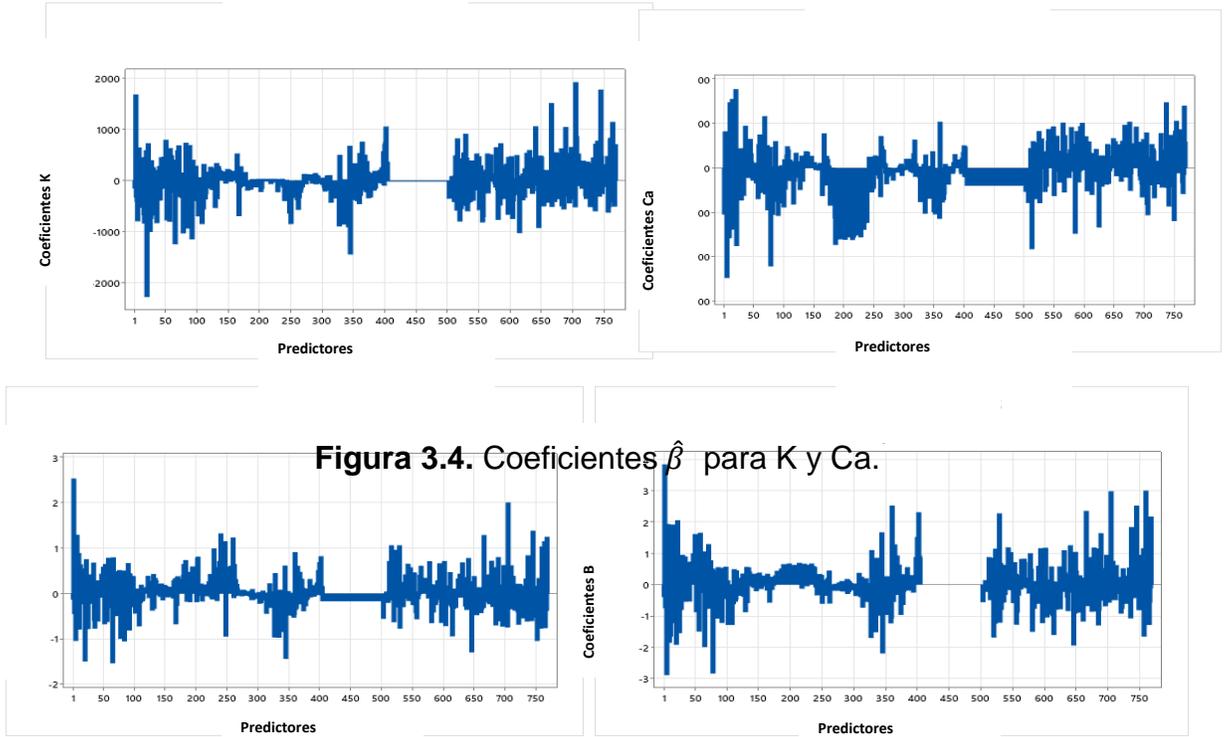


Figura 3.4. Coeficientes $\hat{\beta}$ para K y Ca.

Figura 3.5. Coeficientes $\hat{\beta}$ para Mn y B.

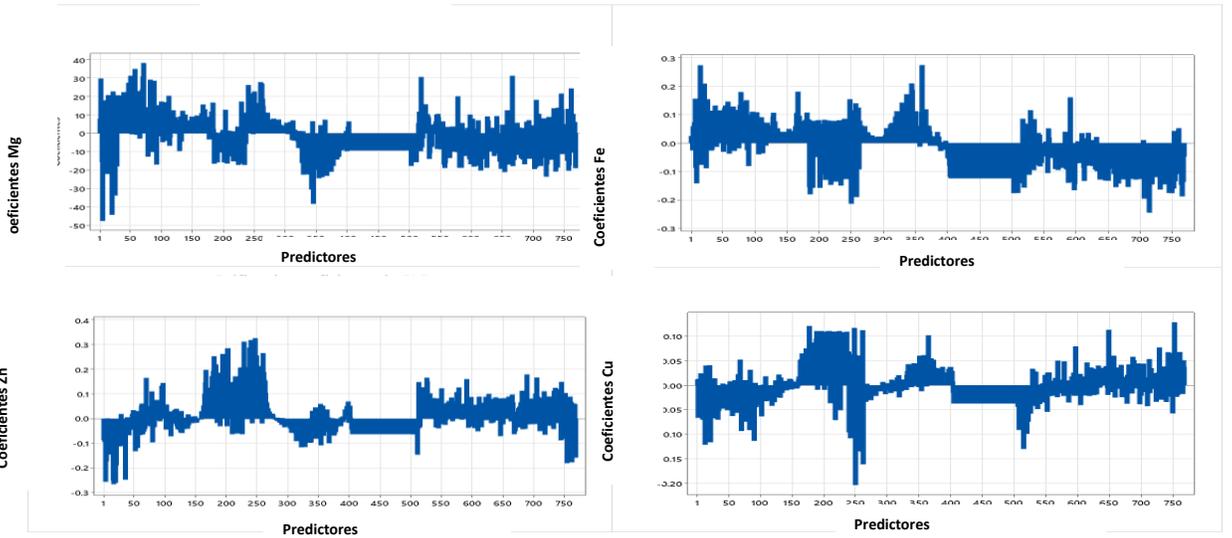


Figura 3.6. Coeficientes $\hat{\beta}$ para Mg, Fe, Zn y Cu.

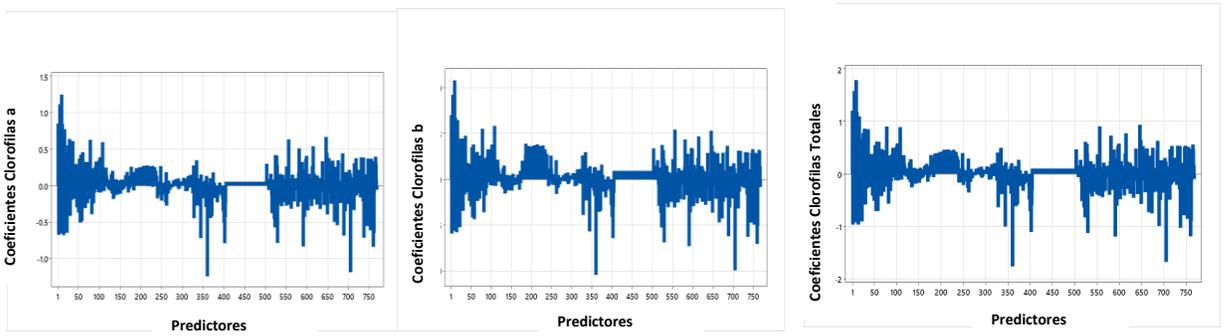


Figura. 3.7. Coeficientes $\hat{\beta}$ para clorofilas a, b y totales.

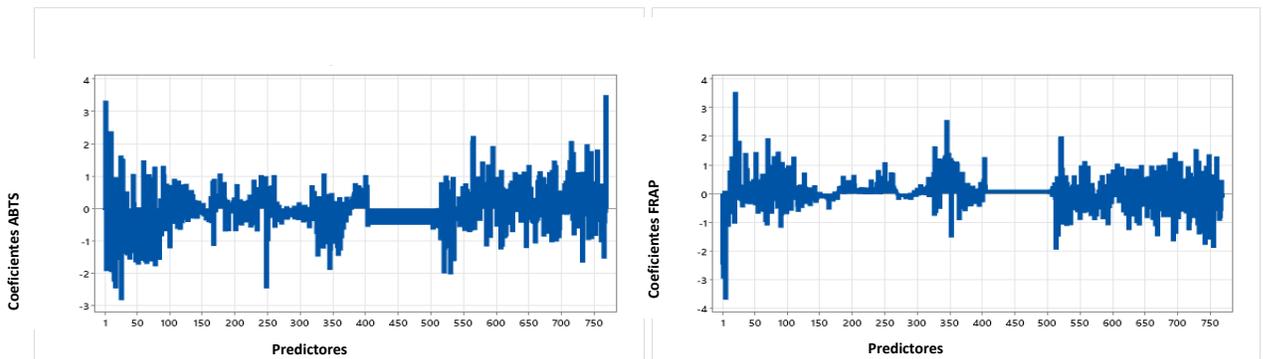


Figura 3.8. Coeficientes $\hat{\beta}$ para ABTS y FRAP.

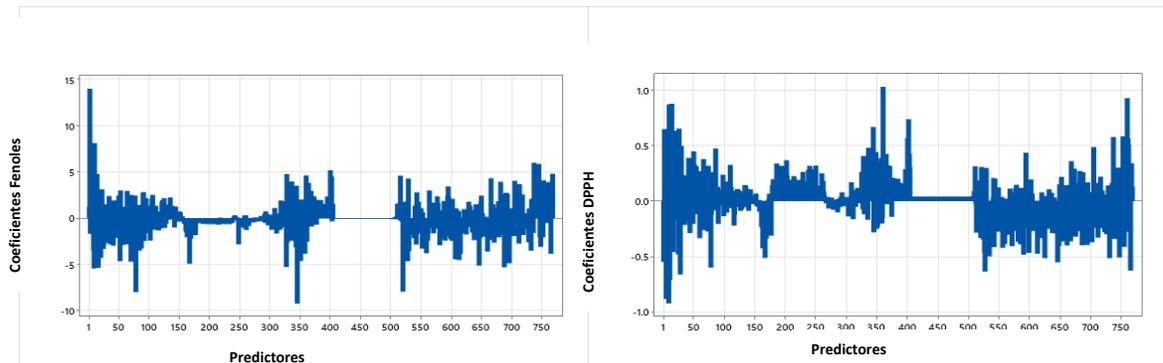


Figura. 3.9. Coeficientes $\hat{\beta}$ para Fenoles y Antioxidantes (DPPH).

Cuadro 3.4. Valores promedio de los contenidos de minerales, clorofilas y antioxidantes en ppm, medidos y los calculados (pronóst) mediante el modelo PLSR.

$N_{m_pronóst}$	$N_{m_medidos}$	$P_{m_pronóst}$	$P_{m_medidos}$
16714.439	16718.333	1618.384	1618.348
$K_{m_pronóst}$	$K_{m_medidos}$	$Ca_{m_pronóst}$	$Ca_{m_medidos}$
16551.915	16546.233	31387.757	31382.223
$Mg_{m_pronóst}$	$Mg_{m_medidos}$	$Fe_{m_pronóst}$	$Fe_{m_medidos}$
3370.852	3370.651	31.648	31.645
$Cu_{m_pronóst}$	$Cu_{m_medidos}$	$Zn_{m_pronóst}$	$Zn_{m_medidos}$
4.712	4.713	10.490	10.490
$Mn_{m_pronóst}$	$Mn_{m_medidos}$	$B_{m_pronóst}$	$B_{m_medidos}$
22.144	22.147	41.708	41.706
$Fenoles_{m_pronóst}$	$Fenoles_{m_medidos}$	$AntioxDPPH_{m_pronóst}$	$AntioxDPPH_{m_medidos}$

56.160	56.206	5.686	5.686
AntioxABTS _{m_pronóst}	AntioxABTS _{m_medido}	AntioxFRAP _{m_pronóst}	AntioxFRAP _{m_medidos}
31.899	31.896	23.026	23.026
Clorofila a _{m_pronóst}	Clorofila a _{m_medidos}	Clorofila b _{m_pronost}	Clorofila b _{m_medidos}
5.411	5.411	2.170	2.169
clorofilas T _{m_pronóst}	7.581	clorofilas T _{m medidos}	7.581

III. CONCLUSIONES

El uso del HSI apoyado con el PLSR es muy confiable en la modelación de los contenidos de nutrientes minerales, clorofilas y de antioxidantes *versus* las imágenes hiperespectrales, ya que se encontraron altos valores de los coeficientes de determinación, buenos niveles de significancia y una varianza de 0.99 (Cuadro 3.3). El análisis de los compuestos analizados de manera individual con PLSR dio por resultado valores más bajos del coeficiente de determinación; obteniéndose un mejor comportamiento con todas las variables dependientes a la vez, al generarse un mayor número de datos, para λ (15x768) de todos los píxeles *versus* todos los compuestos, obteniéndose valores del orden de $R^2= 0.98$ para el P, y para otros minerales, hasta obtener el valor más bajo de $R^2= 0.659$ para DPPH.

Del análisis de PLSR se obtuvieron varianzas que van desde 0.7 hasta 0.871 como porcentajes explicativos y valores significativos para las variables, con un 95% de confianza.

Al comparar las gráficas de los valores promedio originales de laboratorio y los valores medios de predicción, (Cuadro 3.4), se observó una gran similitud que junto con los valores de R^2 , nos indican que existe una buena correlación entre nuestras variables, mostrando que la metodología empleada tiene altas probabilidades de aceptación como técnica predictiva. Los valores obtenidos en laboratorio tienen

gran similitud con los encontrados por Zúñiga-Tarango (2009), y Santiago-Lorenzo (2016) en los análisis de los testigos, pues en este estudio no se usaron fertilizantes. La metodología aplicada puede ser utilizada para obtener modelos de predicción entre otras características agronómicas o entre compuestos químicos o bioquímicos de las plantas y sus imágenes hiperespectrales.

Por otra parte, en los valores de nutrientes minerales macro y micro, hubo diferencias en los resultados, con los presentados por otros autores por las diferentes condiciones de los estudios de Mayer & Cushman, (2019), así como en los estudios de Gregory & Felker (1992); Mokoboki & Sebola (2017); Nobel (1988) y Shoop *et al.* (1977), quienes realizaron sus análisis en cladodios maduros como alimento para ganado, mientras que Retamal *et al.* (1987) obtuvieron sus datos de muestras en diferentes períodos del año, y Teles (1977), los enfocaron al consumo humano y animal.

Se obtuvieron con ImageJ las siguientes características morfológicas de los cladodios comerciales de *Opuntia*: área media de 212 cm², perímetro de 61.2 cm y longitudes L_{max} y L_{mín} con valores que oscilaron entre 21.2 y 13.3 cm, respectivamente.

CAPÍTULO 4. PREDICCIÓN DE LA SEQUÍA DE *Opuntia ficus-indica* L., MEDIANTE APRENDIZAJE AUTOMÁTICO Y PROCESAMIENTO DE IMÁGENES.

RESUMEN

En este capítulo se describen las actividades desarrolladas en el transcurso de cuatro meses del experimento de sequía en 30 plantas de *Opuntia ficus-indica* hasta su cosecha, con cinco niveles de riegos diferenciados, desde el 100% de riego hasta plantas sin riego; midiendo además el color, peso y espesor de los cladodios, proceso de toma de imágenes en el espacio de color RGB, adquisición y procesado de imágenes hiperespectrales, pruebas de textura, análisis de clorofilas y prolina y análisis estadístico de los datos mediante PLSR, usando el programa informático Minitab2021, para buscar relaciones entre las características fisiológicas de *Opuntia* y sus imágenes hiperespectrales. También se incluyó un estudio de las imágenes RGB de las 30 plantas usando un dron DJI mini SE de 2.7k de resolución para determinar algunos rasgos morfológicos de estas plantas.

Se encontraron modelos de mínimos cuadrados parciales entre las variables de HSI y las características químicas (clorofilas y prolina) de los cladodios de nopal. Se obtuvieron coeficientes de determinación R^2 de 0.91 para prolina, 0.97 para las clorofilas *a* y totales de los nopalitos relacionadas a las imágenes hiperspectrales.

Por otro lado, se obtuvieron modelos matemáticos relacionando el área de las plantas y su imagen RGB, usando un dron. Se obtuvieron valores de R^2 desde 0.013 hasta 0.88 para las masas de cladodios relacionadas con sus imágenes RGB, de acuerdo con sus niveles de sequía.

Además de lo anterior, se detectó un decremento de la masa de los cladodios sujetos a sequía, así como una disminución de su espesor.

I. INTRODUCCIÓN

4.1 Importancia del estudio de la sequía en la agricultura.

La sequía se considera el factor ambiental más común que limita la producción de los cultivos y aunado a ello, el cambio climático global está aumentando la aparición de las condiciones de sequía grave (Basu *et al.*, 2016).

Las plantas en su hábitat natural poseen mecanismos de adaptación a la sequía, pero las plantas de cultivo que se escogen por su valor económico deberán sobrevivir al estrés hídrico por medio de mecanismos que no sacrifiquen el rendimiento de la cosecha Fathi & Tari (2016), así, aunque la detección temprana del estrés en las plantas de cultivo es muy importante, no es fácil de conseguir (Behmann, 2014).

Por otra parte, Yang *et al.* (2021) estudiaron los cambios de la estructura externa e interna de plantas bajo estrés (la raíz, el tallo y la hoja), lo que provoca el cambio del estado hídrico de las hojas, afectando a la función fisiológica de las plantas, a las sustancias de regulación osmótica y el metabolismo del oxígeno activo de las mismas.

De acuerdo con Nadeem *et al.* (2019), los mayores efectos del estrés hídrico son el retraso en el crecimiento, disminución de la germinación, los graves daños en el aparato fotosintético, la disminución de la fotosíntesis neta y la reducción de la absorción de nutrientes.

4.2 *Opuntia ficus-indica* y la sequía.

Los cambios fisiológicos provocados por la falta de agua en el nopal (*Opuntia ficus-indica*) han sido poco estudiados. (clorofilas y transporte fotosintético de electrones) (Becerril & Valdivia, 2006). Por otra parte, en estudios sobre *Opuntia*, Flores-Hernández *et al.* (2001) encontraron que la concentración de prolina se incrementó como una respuesta al estrés por calor, en brotes de nopalitas de tres meses, mientras que de acuerdo con Carrillo y Gibon (2011), la sobreproducción de prolina es una respuesta generalizada observada en plantas que experimentan estrés.

Según investigaciones de Do Nascimento y Fett-Neto (2010), se evidencia que el contenido de compuestos con capacidad antioxidante aumenta en las plantas en condiciones de sequía. Sin embargo, hay poca investigación sobre el efecto del riego sobre el contenido de compuestos fenólicos y la capacidad antioxidante en extractos de cladodios de *Opuntia*.

Estudios desarrollados por Mayer *et al.* (2021) indican que muchos metabolitos que encontraron eran indicativos de un entorno altamente oxidante bajo el estrés hídrico. Un total de 34 metabolitos se acumularon en respuesta al estrés, indicando que estos compuestos podrían desempeñar un papel importante en la tolerancia al estrés por sequía.

De acuerdo con Zegbe-Domínguez *et al.* (2021), la reducción de riego en plantas de nopal tunero elevaron los niveles de prolina en plantas y tejidos de los cladodios, sugiriendo que la osmorregulación podría ser un mecanismo que la especie *Opuntia* usa para tolerar períodos prolongados de sequía; sin embargo, no estudiaron el aminoácido prolina, que se sintetiza en grandes cantidades en plantas superiores expuestas a diferentes tipos de estrés abiótico.

4.3 La inteligencia artificial en estudios de sequía.

Para la teledetección de praderas desertificadas, se utilizan imágenes de teledetección con alta resolución espacial para estudiar características pequeñas y escasas en praderas degradadas.

Pi *et al.* (2021) mediante teledetección desarrollaron el análisis de plantas pequeñas con un gran número de píxeles mezclados, llevando a cabo una clasificación de alta precisión de la desertificación de poblaciones de plantas de una especie en praderas.

Rustia *et al.* (2018) en Taiwán, llevaron a cabo un trabajo de identificación de insectos multiclase mediante cámaras inalámbricas utilizando redes neuronales convolucionales (CNN), usando un algoritmo de segmentación de imágenes basada en marcadores para detección de objetos.

De acuerdo con Mishra *et al.* (2017), en la región visible (VIS, por sus siglas en inglés), la información espectral es básicamente de pigmentos, mientras que en el espectro del Infrarrojo Cercano (NIR, por sus siglas en inglés), la información es de diversos bioquímicos como agua, almidón, proteínas, etc.

Por otra parte, en la investigación realizada por Sari & Hudman (2005), la detección aplicada de cambios vegetativos en regiones analizadas mediante RGB-NDVI, permite visualizar su ubicación mediante el uso de tres fechas de NDVI simultáneamente, proporcionando la tasa de cambio en la ubicación por fechas.

4.4 Aplicación del estudio de las Imágenes hiperespectrales en la sequía

Una técnica en desarrollo y no destructiva para el análisis de las características de las plantas es la de la imagen hiperespectral de corto alcance, con un gran potencial para la detección temprana de las respuestas de las plantas al estrés por déficit hídrico.

Asaari *et al.* (2019) realizaron un estudio de estrés hídrico en plantas de maíz, que fue validado a gran escala en una plataforma de fenotipado de plantas en Ghent Bélgica.

4.5 Aplicaciones y usos de UAVs (vehículos aéreos no tripulados) y HSI para uso agrícola.

Los usos actuales de la teledetección hiperespectral aerotransportada tienen las características de alta resolución espacial y espectral, sus análisis son eficientes (Niu *et al.*, 2021). De acuerdo con Wang *et al.* (2020), el uso de UAVs brindan una nueva herramienta y un apoyo científico para el control de calidad del agua en las regiones áridas.

En aplicaciones del uso de UAVs e imágenes hiperespectrales, Lu *et al.* (2021) evaluaron algoritmos de inteligencia artificial para analizar la calidad del agua, incluyendo la clorofila a y los sólidos suspendidos.

En otras aplicaciones, Rodríguez-Martínez (2019) estudió mediante imágenes la deshidratación en plantas de albahaca (*Ocimum basilicum*), usando segmentación

K-means vs. NDVI, mediante redes neuronales; obteniendo buenas correlaciones entre ellos.

OBJETIVOS

- a) Obtener modelos de predicción de los contenidos de clorofilas a y Totales, así como de prolina, como indicadores de sequía de *Opuntia ficus-indica* de cladodios del tercer nivel de plantas de dos años y medio, mediante HSI, técnicas de inteligencia artificial y PLSR.
- b) Encontrar modelos de regresión de imágenes RGB de plantas de *Opuntia ficus-indica* vs. sus masas y sus índices NDVI calculados.

II MATERIALES Y MÉTODOS.

4.6 Materiales.

El experimento se llevó a cabo en las instalaciones de la Facultad de Agronomía de la UANL, en General Escobedo N.L., ubicada en las coordenadas 25° 47' 4.6" N 100° 17' 5.7" O, a 515 msm, con una temperatura media anual de 22.6 °C y una precipitación media anual de 47.5 mm, en el período comprendido de noviembre de 2021 a mayo de 2022.

4.7 Material vegetal.

Para el experimento se usaron 30 plantas en macetas de *Opuntia* del cultivar Villanueva de 2 años, en un suelo franco arcilloso, sujetas a riego semanal diferenciado, usando 2 L, 1.5 L, 1 L, 0.5 L y 0 L de riego por semana. El agua de riego tuvo un pH de 7.6, en el período de diciembre de 2021 a abril de 2022.

Se midieron los parámetros de color de los cladodios en la escala L*, a*, b*, C y h. Los cladodios cosechados fueron del tercer nivel de la planta, en el mismo período de tiempo, midiéndose también su espesor en tres puntos específicos, parte superior, parte media y base del cladodio, así como los gramos de masa de la planta.

4.8 Imágenes hiperespectrales a sequía.

4.8.1. Imágenes hiperespectrales.

Se separó el cladodio que se había estado midiendo de cada maceta y se fotografió mediante la cámara de un teléfono celular iPhone 11, de 12 MP. Posteriormente, se adquirieron y procesaron las imágenes hiperespectrales, mediante una cámara-espectrógrafo Pike 2B – spectra y posteriormente fueron procesados mediante Matlab 2021 y preprocesados en conglomerados mediante el software de acceso libre Hypertools v3.

4.8.2. Muestras complementarias de cladodios.

Para buscar algún indicio posterior de variación de los parámetros de sequía se hicieron análisis a 6 cladodios con tres repeticiones que estaban sujetos a sequía extrema (dos semanas más sin riego), llevando a cabo pruebas a los cladodios de imágenes hiperespectrales y color.

4.9 Pruebas de laboratorio.

Posterior al procesamiento de HSI, se llevaron las muestras al laboratorio, para realizar pruebas de textura, grados brix, análisis de prolina y clorofilas.

Para los análisis de prolina se usó el método de Bates *et al.* (1973), modificado por González-Luna *et al.* (2016), y para la clorofila se utilizó la técnica descrita por Delgado-Vargas *et al.* (2000). A 0.5 g de muestra de pulpa se le añadieron 25 mL de metanol al 80% y fueron homogeneizados, luego se centrifugaron a 5000g por 5 min. a 4 °C y se obtuvo el valor de absorbancia a 663, 646 y 470 nm. Los cálculos se realizaron con las fórmulas descritas a continuación:

$$\text{Clorofila } a: Ca = 12.25A_{663} - 2.29A_{646}. \quad (4.1)$$

$$\text{Clorofila } b: Cb = 21.5A_{645} - 5.21A_{663}. \quad (4.2)$$

$$\text{Clorofila } total: C(a+b) = 7.15A_{663} + 18.71A_{470}. \quad (4.3)$$

4.10 Análisis de fotografías RGB y su relación con las masas de las plantas de *Opuntia ficus-indica*.

Posterior a los análisis mencionados, se cortaron las plantas de *Opuntia*, dejando solo el cladodio madre en cada maceta y se tomaron fotografías aéreas a las plantas con una calidad de 2.7k, usando un dron DJI Mini SE, a una altura de 1.5 m y con iluminación natural, colocadas en un fondo blanco, para minimizar el ruido del entorno, luego se pesaron en una báscula comercial Torrey modelo PCB-100, con capacidad máxima de 100 kg y se procesaron usando el programa informático Matlab 2020^a, para calcular su Índice de Vegetación de Diferencia Normalizada (NDVI por sus siglas en inglés).

4.11 Estadísticas.

Se realizaron análisis de varianza, correlaciones binarias y regresión multivariada, mediante PLSR, usando Minitab 2021, para los parámetros prolina, clorofila *a* y clorofila *total* como variables dependientes y los valores de las imágenes hiperespectrales tratadas con agrupamientos de K-medias, como variables independientes.

III. RESULTADOS

Con los resultados del HSI, al hacer el proceso de agrupamiento con K-means, se llevó a cabo un análisis de varianza múltiple con los valores resultantes del análisis de prolina, de clorofilas *a* y *totales* (los valores de la clorofila *b* fueron muy bajos y no se consideraron en el estudio).

El análisis de varianza para la prolina, para las clorofilas *a* y *totales*, indicó que no había diferencias significativas en los valores medios y al utilizar el método de Tukey para el análisis de medias con un 95% de confianza, nos corroboró lo anterior (Cuadro 4.1). Por otra parte, el análisis de varianza de la regresión, mediante PLSR mostró que hubo diferencias significativas con nivel de confianza del 95% y con más de 99% de probabilidad, lo mismo ocurrió para las clorofilas *a* y *totales* según se puede observar en los Cuadros 4.2, 4.3 y 4.4, en los ANOVAs correspondientes.

Cuadro 4.1. Análisis de varianza y de medias de Tukey de los tratamientos de riego Ti.

Tratamientos	N. Repeticiones	M. de prolina	Clorof. a	Clorof. Tot.	
		P=0.59	P=0.785	P=0.701	
T4	6	289.8	0.1792	0.1668	A
T5	6	245.1	0.2255	0.2746	A
T3	6	243.7	0.2057	0.2329	A
T1	6	207.8	0.2232	0.2036	A
T2	6	194.8	0.1703	0.2388	A

Cuadro 4.2. Análisis de varianza de la regresión para prolina.

Fuente	GL	SC	MC	F	P
Regresión	7	296141	42305.8	34.05	0.000
Error residual	22	27335	1242.5		
Total	29	323476			

Cuadro 4.3. Análisis de varianza de la regresión para Clorofila a.

Fuente	GL	SC	MC	F	P
Regresión	7	0.232643	0.0332347	107.18	0.000
Error residual	22	0.006822	0.0003101		
Total	29	0.239465			

Cuadro 4.4. Análisis de varianza para clorofilas *totales*.

Fuente	GL	SC	MC	F	P
Regresión	7	0.470892	0.0672702	101.88	0.000
Error residual	22	0.014527	0.0006603		
Total	29	0.485419			

Después de realizar el análisis de PLSR, se calculó el número de componentes óptimo para obtener un buen modelo de regresión; obteniéndose que con siete componentes se alcanza el punto donde la pendiente tiende a cero. Después de ello, se procedió a llevar a cabo la regresión para el análisis de prolina, que tuvo una varianza del 77% y un coeficiente de determinación R^2 de 0.915, lo que se puede considerar como un buen valor de aproximación, lo mismo se hizo para las clorofilas *a* y *total*, obteniéndose porcentajes iguales de variación del 77% y R^2 de 0.97 para ambas (Cuadro 4.5).

Cuadro 4.5. Selección y validación de modelo para prolina, Clorofilas *a* y *totales*.

Comp.	Var. prolina	Error	R^2	RMSE
7	0.771773	27335	0.915	30.202

Comp.	Var. de Clorofila <i>a</i>	Error	R^2	RMSE
7	0.771773	0.0068	0.971	0.0615

Comp.	Var. Clorofila Tot.	Error	R^2	RMSE
7	0.771773	0.0145	0.970	0.022

Finalmente se calculan los coeficientes $\beta_{(768 \times 3)}$ de la ecuación 4.4 de regresión, los cuales se muestran estandarizados en la Figura 4.1 para cada compuesto.

$$[M_{(30 \times 3)}] = \beta_{oi} + [\lambda_{(30 \times 768)}][\beta_{(768 \times 3)}] + \varepsilon_{(30 \times 3)} \quad (4.4)$$

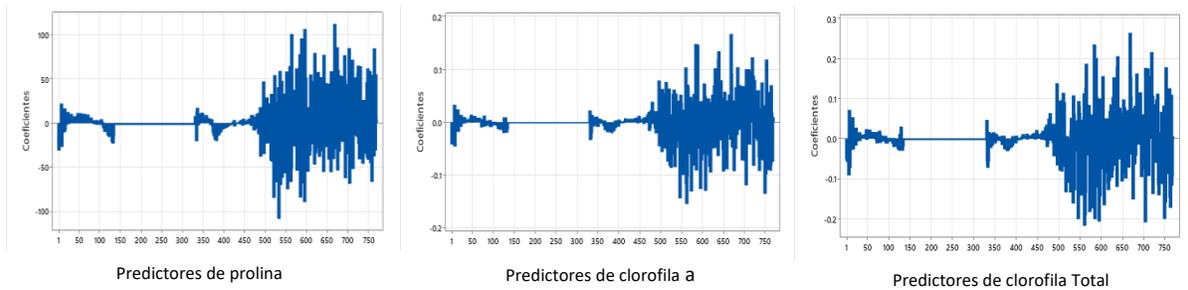


Figura 4.1. Coeficientes de regresión para prolina y clorofilas *a* y *totales*.

Al analizar el comportamiento de la masa de los cladodios, se observó una disminución promedio de 2 kg de las plantas de *Opuntia* sin riego, permaneciendo casi constante para las plantas regadas, esto debido a que en la temporada en que se evaluó, no hubo producción de nopalitos (Figura 4.2).

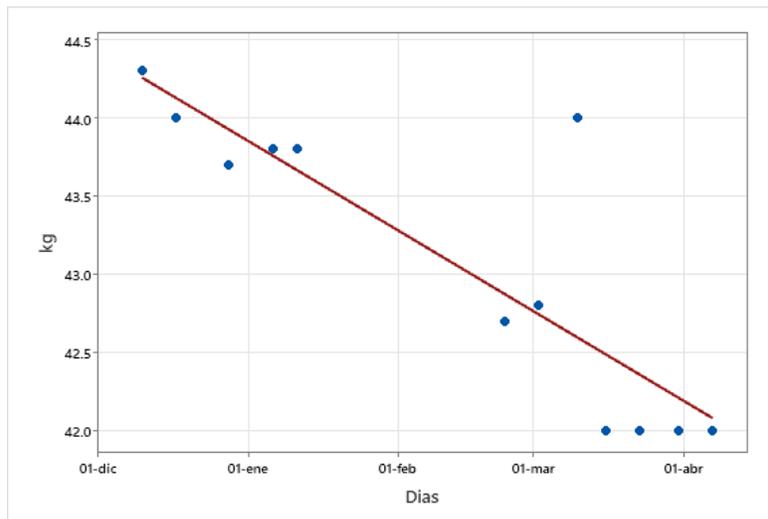


Figura 4.2. Variación de la masa de cladodios sin riego.

Otro indicador observado de la sequía de *Opuntia* fue la disminución del espesor de los cladodios en sus diferentes partes (superior, media e inferior) y en diferentes

proporciones; así hubo una disminución del 32% en la parte superior, de 40% en la parte media y de 19.69% en la parte donde se une al cladodio del piso previo (Cuadro 4.6).

Cuadro 4.6. Disminución del espesor de cladodios sin riego.

Superior	32.04 %
Medio	40.94 %
inferior	19.69 %

4.12 Análisis de los cladodios sujetos a sequía extrema.

Luego de revisar los resultados de los análisis de prolina y clorofilas a y Totales se decidió analizar otra muestra de cladodios, del lote sin riego, para verificar el comportamiento de las variables color, prolina y las clorofilas a sequía severa.

Cuadro 4.7. Datos de color de los cladodios sujetos a sequía severa.

VALORES	N1	N2	N3	N4	N5	N6	N7	N8
L*	44.56	43.6	50.36	44.71	48.85	44.99	45.86	44.16
a*	-12.35	-12.56	-13.71	-12.28	-11.91	-14.11	-13.96	-10.85
b*	16.29	16.36	25.03	18.71	21.88	19.29	19.47	14.79
C*	20.44	20.62	28.54	21.93	24.91	23.9	23.95	18.35
h	127.16	127.51	118.7	124.05	118.55	126.18	125.64	126.25

Cuadro 4.8. Valores promedio de grados Brix, pH y Resistencia a la penetración de los cladodios.

Muestra	Punción _m (N)	pH _m	°Brix _m
8	42.93	4.67	4.68

Los resultados de los análisis en los cladodios sujetos a sequía severa indicaron una disminución drástica de las clorofilas y un incremento de la prolina, así como de la resistencia a la punción, la cual aumentó en los nopales sujetos a sequía comparativamente con los nopalitos frescos de 20 N a 42.9 N.

4.13 Análisis de la masa de las plantas de *Opuntia*, fotografiadas mediante un dron DJI Mini SE.

Como un siguiente paso, se tomaron fotografías a las plantas completas a excepción del cladodio madre, mediante un dron DJI Mini SE, con 2.7k de resolución a una altura de 1.5 m, con estabilizador del viento. Se usó una lona de color blanco como fondo para minimizar el ruido en las imágenes. Posteriormente se pesaron con una báscula de 100 kg, procesando las imágenes de tipo RGB mediante el programa ImageJ, calculándose el área de cada planta (Figura 4.3) en formato RGB y la Figura 4.4 muestra la imagen ya procesada. En el Cuadro 4.9 se dan los valores de las áreas y las masas, separadas por los niveles de riego a que se sujetaron.



Figura 4.3. Fotografía RGB de plantas, usando dron DJI Mini SE.

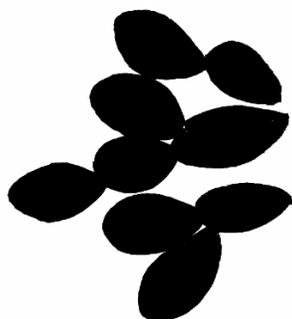


Figura 4.4. Fotografía procesada por medio de ImageJ.

Cuadro 4.9. Valores calculados de las áreas A_i en cm^2 y las masas en kg.

A1	M1	A2	M2	A3	M3	A4	M4	A5	M5
(cm^2)	(kg)								
1887.95	2.28	2673.17	2	4282.32	1.6	2575.97	1.84	3727.65	3.24
4570.17	3.5	3661.21	3.44	2744.41	3.06	3128.87	3.22	3409.22	3.58
2759.24	2.36	3863.71	3.98	2213.30	2.48	3103.10	3.56	2540.27	2.62
2850.18	3.24	3205.04	3.5	2856.62	3.24	2811.59	3.16	2204.93	2.08
3110.40	3.6	3514.24	4.26	4147.44	4.68	4230.11	4.8	2168.15	2.1
3362.22	3.4	2867.77	3.4	3185.70	2.96	4101.76	4.44	3011.48	3.46

Del análisis de varianza se obtuvieron los datos de la tabla 4.10, donde los T_i son los niveles de riego de las plantas de *Opuntia*, generándose los valores de F, del valor P y el coeficiente de determinación R^2 para cada análisis.

Cuadro 4.10. Resultados del análisis de varianza de las masas y áreas de plantas.

Tratamientos	T1	T2	T3	T4	T5
Valor F	14.77	5.76	0.05	28.83	14.77
Valor P	0.018	0.074	0.827	0.006	0.018
R^2	0.787	0.59	0.013	0.880	0.887

En el Cuadro 4.11 se dan las ecuaciones resultantes de la regresión de PLSR entre las masas y las áreas de las plantas regadas al 100% (m_1), al 75% (m_2), al 50% (m_3), al 25% (m_4) y sin riego (m_5), donde la variable m_i son las masas y Áreas_i son las áreas de *Opuntia*, para cada tratamiento.

Cuadro 4.11. Modelos de regresión para los cinco tratamientos de riego.

Tratamiento 1	$m_1 = 0.217869 + 0.000024 * \text{Áreas}_1$
Tratamiento 2	$m_2 = -0.815492 + 0.001287 * \text{Áreas}_2$
Tratamiento 3	$m_3 = 2.54105 + 0.00014 * \text{Áreas}_3$
Tratamiento 4	$m_4 = -1.29079 + 0.00144 * \text{Áreas}_4$
Tratamiento 5	$m_5 = 0.217869 + 0.000924 * \text{Áreas}_5$

Adicionalmente, se obtuvieron los índices NDVI, calculados a partir de los valores RGB de las imágenes obtenidas, mediante la ecuación 3; usando un programa en Matlab 2019a, donde NIR son valores del infrarrojo cercano; R representa los valores del rojo (Figura 4.5). En la Figura 4.6 se muestra la gráfica de los índices de las 30 plantas de *Opuntia*, observando poca variación en los valores. El análisis ANOVA mostró que no hubo diferencias significativas ($F= 0.31$ y $P=0.869$), y la prueba de Tukey nos indicó que no había diferencia significativa de medias, con 95% de confianza de los valores NDVI analizados.

$$NDVI = \frac{NIR-R}{NIR+R} \quad (4.5)$$

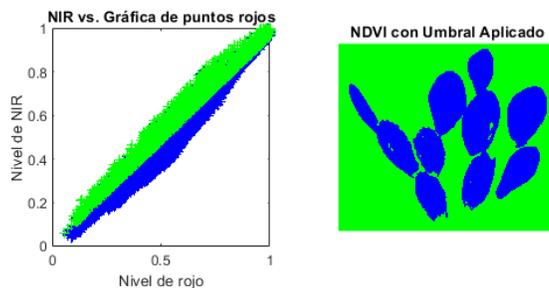


Figura 4.5. Índices NDVI para una planta de *Opuntia*.

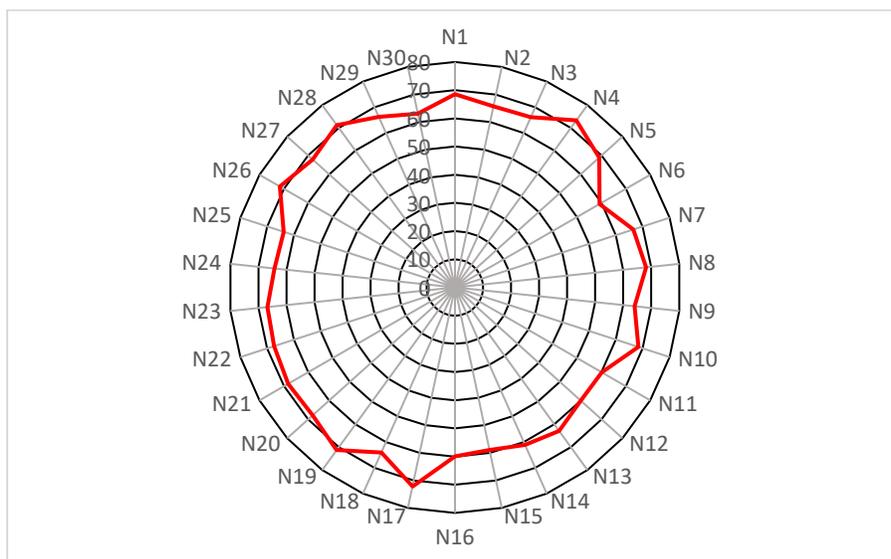


Figura 4.6. Valores de NDVI de las 30 plantas de *Opuntia*.

IV. CONCLUSIONES

Se obtuvieron resultados satisfactorios con altos coeficientes de determinación del modelado de la prolina y las clorofilas *a* y *totales*. En el modelo de prolina se observa que los coeficientes más importantes se encuentran entre 530nm a 600nm, siendo ahí donde se da la más alta reflectancia de los cladodios; en cuanto a la clorofila *a*, los coeficientes más altos se dan a 550nm y a 750nm; los coeficientes más altos en los análisis de clorofilas *totales* se encuentran en 600nm y 700nm, coincidiendo con lo encontrado por Lu *et al.* (2021). El resultado del ANOVA no mostró diferencias significativas en los valores medios de prolina, después de cuatro meses de sequía. Al analizar cladodios de 5 meses, se observó un incremento del valor medio de la prolina en un 35%, coincidiendo con lo encontrado por Carrillo y Gibon (2011) y

Zegbe-Domínguez (2021), aunque la resistencia de *Opuntia* a la sequía es muy alta y los índices del inicio de la sequía no son claros del todo. Algo similar ocurrió con las clorofilas, que no mostraron diferencias significativas, pero a los 5 meses los cladodios maduros tuvieron valores menores a la unidad o casi cero, mientras que en nopalitos frescos fue de 5.41 ppm para clorofila *a*; 2.17 para clorofila *b* y 7.58 para las clorofilas *totales* (Figura 3.1), coincidiendo con Becerril & Valdivia (2006). Por otra parte, la disminución del espesor de los cladodios en porcentajes de 41% en la parte central, es un indicador de la aproximación a la sequía, coincidiendo con Goldstein *et al.* (1991), y con Liguori *et al.* (2014) en que en la parte del cladodio madre no hubo mucho cambio (19%). La pérdida de peso de las plantas en 2 kg es otro indicador de acercamiento a la sequía de *Opuntia*, coincidente con lo encontrado por Singh & Singh (2003). Aunque el cambio de coloración después de cuatro meses del experimento mostró que no hubo diferencias significativas de acuerdo con el análisis de varianza realizado en las imágenes hiperespectrales, al evaluar los modelos encontrados, se pueden calcular los valores de los coeficientes β_i de las imágenes hiperespectrales, cuando alguna de las características químicas tienda a algún valor de nuestro interés, o su tendencia a ser cero. En el estudio de imágenes RGB, se encontraron modelos lineales con coeficientes de determinación de 0.59 a 0.87, siendo prometedora esta metodología de análisis tanto morfológica como de predicción de alguna característica de interés.

BIBLIOGRAFÍA

1. Adams, W. W., and Terashima, I. (Eds.). (2018). *The Leaf: A Platform for Performing Photosynthesis* (Vol. 44). Springer.
1. (1999). Acumulación de prolina en raíces de dos cultivares de nopal *Opuntia* spp. bajo tensión por calor.
2. Aguilar, C. N.; Rodríguez, H. R.; Saucedo, P. S. y Jasso, C. D. 2008. Fitoquímicos Sobresalientes del Semidesierto mexicano: de la planta a los químicos naturales y a la biotecnología. Ed. Path Design Saltillo, Coahuila, México. 579 p.
3. Aguilera, P. A., Fernández, A., Roperó, R. F., & Molina, L. (2013). Groundwater quality assessment using data clustering based on hybrid Bayesian networks. *Stochastic environmental research and risk assessment*, 27(2), 435-447.
4. Ahmad, J., Jan, B., Farman, H., Ahmad, W., & Ullah, A. (2020). Disease detection in plum using convolutional neural network under true field conditions. *Sensors*, 20(19), 5569.
5. Ahmed, H. A., Yu-Xin, T., & Qi-Chang, Y. (2020). Optimal control of environmental conditions affecting lettuce plant growth in a controlled environment with artificial lighting: A review. *South African Journal of Botany*, 130, 75-89.
6. Alam, A. T. M. J., Saadat, A. H. M., Rahman, M. S., & Barkotulla, M. A. B. (2014). Spatial analysis of rainfall distribution and its impact on agricultural drought at Barind region, Bangladesh. *Computational Intelligence*.
7. Amatya, S., Karkee, M., Alva, A. K., Larbi, P., & Adhikari, B. (2012). Hyperspectral imaging for detecting water stress in potatoes. In *2012 Dallas, Texas, July 29-August 1, 2012* (p. 1). American Society of Agricultural and Biological Engineers.
8. Amigo, J. M., Babamoradi, H., & Elcoroaristizabal, S. (2015). Hyperspectral image analysis. A tutorial. *Analytica chimica acta*, 896, 34-51.
9. Andrade-Garda, J. (Ed.). (2013). *Basic chemometric techniques in atomic spectroscopy*. Royal Society of Chemistry.

10. Andriyas, S., & McKee, M. (2014). Exploring irrigation behavior at Delta, Utah using hidden Markov models. *Agricultural Water Management*, 143, 48-58.
11. Aneiros, G., Cao, R., Fraiman, R., Genest, C., & Vieu, P. (2019). Recent advances in functional data analysis
12. Aponte, H. (2017). Productividad de *Limnobium laevigatum* (Hydrocharitaceae) bajo condiciones de laboratorio. *Polibotánica*, (44),157-166. <https://doi.org/10.18387/polibotanica.44.12>
13. Asaari, M. S. M., Mertens, S., Dhondt, S., Inzé, D., Wuyts, N., & Scheunders, P. (2019). Analysis of hyperspectral images for detection of drought stress and recovery in maize plants in a high-throughput phenotyping platform. *Computers and Electronics in Agriculture*, 162, 749-758.
14. Asaari, M. S. M., Mishra, P., Mertens, S., Dhondt, S., Inzé, D., Wuyts, N., & Scheunders, P. (2018). Close-range hyperspectral image analysis for the early detection of stress responses in individual plants in a high-throughput phenotyping platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 138, 121-138.
15. Atas, M., Yardimci, Y., & Temizel, A. (2012). A new approach to aflatoxin detection in chili pepper by machine vision. *Computer and electronics in agricultura* 87 (2012) 129-141.
16. Babellahi, F., Paliwal, J., Erkinbaev, C., Amodio, M. L., Chaudhry, M. M. A., & Colelli, G. (2020). Early detection of chilling injury in green bell peppers by hyperspectral imaging and chemometrics. *Postharvest Biology and Technology*, 162, 111100.
17. Barbin, D. F., ElMasry, G., Sun, D. W., & Allen, P. (2012). Predicting quality and sensory attributes of pork using near-infrared hyperspectral imaging. *Analytica chimica acta*, 719, 30-42.
18. Bárcenas, Argüello, M. L. (1999). Acumulación de prolina en raíces de dos cultivares de nopal *Opuntia* spp. bajo tensión por calor.

19. Barrs, H., Weatherley, P., (1962). A re-examination of the relative turgidity technique for estimating water deficits in leaves. *Aust. J. Biol. Sci.* 15 (3), 413–428. doi: <http://dx.doi.org/10.1071/BI9620413>.
20. Basu, S., Ramegowda, V., Kumar, A., & Pereira, A. (2016). Plant adaptation to drought stress. *F1000Research*, 5.
21. Becerril, G. A., & Valdivia, C. B. P. (2006). Physiological alterations induced by drought stress on prickly pear (*Opuntia ficus-indica*). *Revista Fitotecnia Mexicana*, 29, 231-237.
22. Behmann, J., Steinrücken, J., & Plümer, L. (2014). Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 98-111.
23. Benelli, A., Cevoli, C., & Fabbri, A. (2020). In-field hyperspectral imaging: An overview on the ground-based applications in agriculture. *Journal of Agricultural Engineering*, 51(3), 129-139.
24. Bober, M. (2001). MPEG-7 visual shape descriptors. *IEEE Transactions on circuits and systems for video technology*. 11(6), 716-719.
25. Boente, G., Salibian-Barrera, M., & Vena, P. (2020). Robust estimation for semi-functional linear regression models. *Computational Statistics & Data Analysis*, 152, 107041.
26. Bouzoubaâ, Z., Essoukrati, Y., Tahrouch, S., Hatimi, A., Gharby, S., & Harhar, H. (2016). Phytochemical study of prickly pear from southern Morocco. *Journal of the Saudi Society of Agricultural Sciences*, 15(2), 155-161.
27. Brenes-Zeledón, C. (2019). Captura y formación de imágenes hiperespectrales mediante UAV's. *Revista Tecnología En Marcha*, 32(8), 24-34. <https://doi.org/10.18845/tm.v32i8.4561>.
28. Brewer, M., Lang, L., Fujimura, K., Dujmovic, N., Gray, S., & Van Der Knaap E. (2006). Development of a controlled vocabulary and software application to analyze fruit shape variation in tomato and other plant species. *Plant physiology* 141(1), 15-25.

29. Brugger, A., Behmann, J., Paulus, S., Luigs, H. G., Kuska, M. T., Schramowski, P., ... & Mahlein, A. K. (2019). Extending hyperspectral imaging for plant phenotyping to the UV-range. *Remote Sensing*, *11*(12), 1401.
30. Bruinsma, I. (1961). A comment on the spectrophotometric determination of chlorophyll. *Biochim. Biophys. Acta* *52*: 576-578.
31. Burnett, A. C., Anderson, J., Davidson, K. J., Ely, K. S., Lamour, J., Li, Q., & Serbin, S. P. (2021). A best-practice guide to predicting plant traits from leaf-level hyperspectral data using partial least squares regression. *Journal of Experimental Botany*.
32. Carillo, P., & Gibon, Y. (2011). Protocol: extraction and determination of proline. *PrometheusWiki*, 2011, 1-5.
33. Chavhan, G. H., Dandawate, Y. H., & Deshpande, M. S. (2021). A Comparative Analysis on Hyperspectral Imaging-Based Early Drought Stress Detection for Precision Agriculture in Indian Context. In *Proceedings of International Conference on Communication and Artificial Intelligence* (pp. 507-513). Springer, Singapore.
34. Chen, J., Chen, J., Zhang, D., Sun, Y., & Nanekaran, Y. A. (2020). Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture*, *173*, 105393.
35. Cheng, JH., Sun, DW., (2017). Partial Least Squares Regression (PLSR) Applied to NIR and HSI Spectral Data Modeling to Predict Chemical Properties of Fish Muscle. *Food Eng Rev* *9*, 36–49 (2017). <https://doi.org/10.1007/s12393-016-9147-1>.
36. Chessa, I. (2010). Cactus pear genetic resources conservation, evaluation and uses. *FAO Cactusnet Newsletter, Special*, (12), 43-53.
37. Cornet, D., Sierra, J., Tournebize, R., Gabrielle, B., & Lewis, F. I. (2016). Bayesian network modeling of early growth stages explains yam interplant yield variability and allows for agronomic improvements in West Africa. *European journal of agronomy*, *75*, 80-88.

38. Costa, L., Nunes, L., & Ampatzidis, Y. (2020). A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. *Computers and Electronics in Agriculture*, 172, 105334.
39. Covarrubias, M. A. L. (2018). Función de verosimilitud conjunta basada en distribuciones de probabilidad normal y multinomial para analizar la variabilidad fenotípica en el crecimiento de almeja de sifón *Panopea globosa*.
40. Cui, M., & Nobel, P. S. (1994). Gas exchange and growth responses to elevated CO₂ and light levels in the CAM species *Opuntia ficus-indica*. *Plant, Cell & Environment*, 17(8), 935-944.
41. D'Silva, P., & Bhuvaneswari, P. (2015). Various shape descriptors in image processing—a review. *International Journal of Science and Research (IJSR)*, 4(3), 2338-2342.
42. Dambergs, Bob, WenWen, Jiang, Nordestgaard, Simon, Wilkes, Eric, and Petrie, Paul, (2019), Digital solutions for grape quality measurement at the weighbridge. The Australian Wine Research Institute.
43. Dao, P. D., He, Y., & Proctor, C. (2021). Plant drought impact detection using ultra-high spatial resolution hyperspectral images and machine learning. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102364.
44. Dehbi, F., Hasib, A., Tilaoui, M., El Batal, H., Zaki, N., Ouattmane, A., ... and Ziad, A. (2013). Bioactive constituents, antioxidant activity and in vitro cancer cell cytotoxicity of moroccan prickly pear (*Opuntia ficus-indica* L.) juices. *Journal of Natural Sciences Research*, 3(14), 12-20.
45. Delgado-Vargas, F., Jiménez, AR, & Paredes-López, O. (2000). Pigmentos naturales: carotenoides, antocianinas y betalainas: características, biosíntesis, procesamiento y estabilidad. *Revisiones críticas en ciencia de los alimentos y nutrición*, 40 (3), 173-289.

46. Deni, S. M., Suhaila, J., Wan Zin, W. Z., & Jemain, A. A. (2010). Spatial trends of dry spells over Peninsular Malaysia during monsoon seasons. *Theoretical and applied climatology*, 99(3), 357-371.
47. Dhingra, O. D., & Sinclair, J. B. (2017). Basic plant pathology methods. *CRC press*.
48. Drapikowski, Paweł; Kazimierczak-Grygiel, Ewa; Korecki, Dominik; Wiland-Szymanowska Justyna, (2016). Verification of Geometric Model-Based Plant Phenotyping Methods for Studies of Xerophytic Plants, sensors.
49. Drennan, P. M., & Nobel, P. S. (2000). Responses of CAM species to increasing atmospheric CO₂ concentrations. *Plant, Cell & Environment*, 23(8), 767-781.
50. Drury, B., Valverde-Rebaza, J., Moura, M. F., & de Andrade Lopes, A. (2017). A survey of the applications of Bayesian networks in agriculture. *Engineering Applications of Artificial Intelligence*, 65, 29-42.
51. Eizentals, P., & Oka, K. (2016). 3D pose estimation of green pepper fruit for automated harvesting. *Computers and Electronics in Agriculture*, 128, 127-140.
52. Elavarasan, D., Vincent, D. R., Sharma, V., Zomaya, A. Y., & Srinivasan, K. (2018). Forecasting yield by integrating agrarian factors and machine learning models: A survey. *Computers and Electronics in Agriculture*, 155, 257-282.
53. El-Guezzane, C., El-Moudden, H., Harhar, H., Chahboun, N., Tabyaoui, M., & Zarrouk, A. (2021). A comparative study of the antioxidant activity of two Moroccan prickly pear cultivars collected in different regions. *Chemical Data Collections*, 31, 100637.
54. ElMasry, G., Barbin, D. F., Sun, D. W., & Allen, P. (2012). Meat quality evaluation by hyperspectral imaging technique: an overview. *Critical reviews in food science and nutrition*, 52(8), 689-711.
55. Elvanidi, A., Katsoulas, N., & Kittas, C. (2018). Automation for water and nitrogen deficit stress detection in soilless tomato crops based on spectral indices. *Horticulturae*, 4(4), 47.

56. Fàbregas, N., & Fernie, A. R. (2019). The metabolic response to drought. *Journal of Experimental Botany*, 70(4), 1077-1085.
57. Fahlgren, N., Gehan, M. A., & Baxter, I. (2015). Lights, camera, action: high-throughput plant phenotyping is ready for a close-up. *Current opinion in plant biology*, 24, 93-99.
58. FAO (2001). Plant production and protection paper, Cactus (*Opuntia spp.* as forage, 2001).
59. FAO. (2017). Crop ecology, cultivation and uses of cactus pear, Published by The Food and Agriculture Organization of the United Nations, and the International Center for Agricultural Research in the Dry Areas, Rome.
60. Farina, G. H. (2020). Aplicación de filtros cromáticos en el espacio de color para la detección y medición de formas en plantas de soja (Doctoral dissertation, Universidad Nacional de Mar del Plata. Facultad de Ingeniería, Argentina).
61. Fathi, A., & Tari, D. B. (2016). Effect of drought stress and its mechanism in plants. *International Journal of Life Sciences*, 10(1), 1-6.
62. Fathipour, H., Arefi, H., Shah-Hosseini, R., & Moghadam, H. (2019). Corn forage yield prediction using unmanned aerial vehicle images at mid-season growth stage. *Journal of Applied Remote Sensing*, 13(3), 034503.
63. Feret, J. B., François, C., Asner, G. P., Gitelson, A. A., Martin, R. E., Bidel, L. P., ... & Jacquemoud, S. (2008). PROSPECT-4 and 5: Advances in the leaf optical properties model separating photosynthetic pigments. *Remote sensing of environment*, 112(6), 3030-3043.
64. Fernández Ropero, R. M., Aguilera, P. A., Fernández, A., & Rumí, R. (2014). Redes bayesianas: una herramienta probabilística en los modelos de distribución de especies: *Ecosistemas*, 23(1), 54-60. <https://doi.org/10.7818/ECOS.2014.23-1.08>.
65. Ferrara, R., Viridis, S. G., Ventura, A., Ghisu, T., Duce, P., & Pellizzaro, G. (2018). An automated approach for wood-leaf separation from terrestrial LIDAR point clouds using the density based clustering algorithm DBSCAN. *Agricultural and forest meteorology*, 262, 434-444.

66. Field high-throughput phenotyping. (2014). The new crop breeding frontier. Available online: <http://repository.cimmyt.org/xmlui/bitstream/handle/10883/3209/98018.pdf?sequence=1> (accessed on 10 October 2014).
67. Fischer, A.M. (2012). The complex regulation of senescence. *Crit. Rev. Plant Sci.* 31 (2), 124–147.
68. Flores-Hernandez, A., Murillo-Amador, B., Garcia-Hernandez, J. L., & Fraga-Palomino, H. C. (2001). Proline concentration in young cladodes from nopal cultivars (*Opuntia megacantha*) exposed to heat stress. *Phyton-International Journal of Experimental Botany*, 15-24.
69. Fouquet Calderón, F. (2021). Inteligencia Artificial aplicada a la agricultura de precisión. Control de hongos en la planta de tomate. Universidad de Malaga.
70. Fukuda, S., Spreer, W., Yasunaga, E., Yuge, K., Sardud, V., & Müller, J. (2013). Random Forests modelling for the estimation of mango (*Mangifera indica* L. cv. Chok Anan) fruit yields under different irrigation regimes. *Agricultural water management*, 116, 142-150.
71. Gago, J., Douthe, C., Coopman, R. E., Gallego, P. P., Ribas-Carbo, M., Flexas, J., & Medrano, H. (2015). UAVs challenge to assess water stress for sustainable agriculture. *Agricultural water management*, 153, 9-19.
72. García Osuna, H. T. (2013). *Identificación de pectinas y mucílago de cuatro variedades de nopal (Opuntia ficus-indica L.) Miller y validación de su actividad hipoglucémica* (Doctoral dissertation, Universidad Autónoma de Nuevo León).
73. Garner, D., Crisosto, C. H., Wiley, P., & Crisosto, G. M. (2008). Measurement of pH and titratable acidity. *Central Valley Postharvest Newsletter*, 17(2), 2.
74. Glezakos, T. J., Moschopoulou, G., Tsiligiridis, T. A., Kintzios, S., & Yialouris, C. P. (2010). Plant virus identification based on neural networks with evolutionary preprocessing. *Computers and electronics in agriculture*, 70(2), 263-275.

75. Goldstein, G., Andrade, J. L., & Nobel, P. S. (1991). Differences in water relations parameters for the chlorenchyma and the parenchyma of *Opuntia ficus-indica* under wet versus dry conditions. *Functional Plant Biology*, 18(2), 95-107.
76. Goldstein, G., Ortega, J.K.E., Nerd, A., Nobel, P.S. (1991). Diel patterns of water potential components for the crassulacean acid metabolism plant *Opuntia ficus-indica* when well-watered or droughted. *Plant Physiol.* 95 (1), 274–280. doi: <http://dx.doi.org/10.1104/pp.95.1.274>.
77. Gomes, V., Mendes-Ferreira, A., & Melo-Pinto, P. (2021). Application of hyperspectral imaging and deep learning for robust prediction of sugar and pH levels in wine grape berries. *Sensors*, 21(10), 3459.
78. Gómez Llallahui, M. (2016). Efecto de una crema elaborada con el mucílago del cladodio del nopal “tuna” (*Opuntia ficus-indica* (L) Mill.) en la cicatrización de heridas en cobayos (*Cavia porcellus*) Ayacucho-2014.
79. Gomez, F. M. (2012). *Regulación de los pasos iniciales de la degradación de clorofila durante la senescencia foliar* (Doctoral dissertation, Universidad Nacional de La Plata).
80. Gorgoglione, A., Gregorio, J., Ríos, A., Alonso, J., Chreties, C., & Fossati, M. (2020). Influence of land use/land cover on surface-water quality of Santa Lucía river, Uruguay. *Sustainability*, 12(11), 4692.
81. Gosa, S. C., Lupo, Y., & Moshelion, M. (2019). Quantitative and comparative analysis of whole-plant performance for functional physiological traits phenotyping: new tools to support pre-breeding and plant stress physiology studies. *Plant science*, 282, 49-59.
82. Grajeda-Gonzalez, F., Contreras-Salazar, E. A. & Luna-Maldonado, A. I. (2015). Sistema de Procesamiento de Imágenes para Obtener los Parámetros del Color en Frutos de dos Variedades de Tomate. *Academic Journals*. 1156-1161.
83. Gregory, R. A., & Felker, P. (1992). Crude protein and phosphorus contents of eight contrasting *Opuntia* forage clones. *Journal of arid environments*, 22(4), 323-331.

84. Guiboileau, A., Sormani, R., Meyer, C., & Masclaux-Daubresse, C. (2010). Senescence and death of plant organs: nutrient recycling and developmental regulation. *Comptes rendus biologiques*, 333(4), 382-391.
85. Guolan, Lu; Baowei Fei, (2014); Medical hyperspectral imaging: a review; *Journal of Biomedical Optics* 19(1), 010901, 1-18.
86. Gutiérrez, A. (2020). Caracterización morfológica de tres genotipos criollos promisorios de *Theobroma cacao* L., EN PANAMÁ. *Ciencia Agropecuaria*, (30), 150-169.
87. Hartig, S. M. (2013). Basic image analysis and manipulation in ImageJ. *Current protocols in molecular biology*, 102(1), 14-15.
88. Hassan, S. (2018). Soil Volume: The Effect of Pot Size on Roots and Canopy Growth Performance of Cactus Pear. Conference: IX international congress on cactus pear and cochineal "CAM crops for a hotter and drier world". pp (79).
89. Hassan, S., Inglese, P., Liguori, G., Sortino, G., Ates, S., & Louhaichi, M. (2017). The effect of soil volume on the growth of roots and canopy of *Opuntia ficus-indica*. In *IX International Congress on Cactus Pear and Cochineal: CAM Crops for a Hotter and Drier World 1247* (pp. 103-108).
90. Huang, Hui; Liu, Li; Michael O. Ngadi (2013); Recent Developments in Hyperspectral Imaging for Assessment of Food Quality and Safety; *Sensors* 2014, 14, 7248-7276; doi:10.3390/s140407248.
91. Huang, P., Luo, X., Jin, J., Wang, L., Zhang, L., Liu, J., & Zhang, Z. (2018). Improving high-throughput phenotyping using fusion of close-range hyperspectral camera and low-cost depth sensor. *Sensors*, 18(8), 2711.
92. Huang, T., Yang, R., Huang, W., Huang, Y., & Qiao, X. (2018). Detecting sugarcane borer diseases using support vector machine. *Information processing in agriculture*, 5(1), 74-82.
93. Huang, X., Huang, G., Yu, C., Ni, S., & Yu, L. (2017). A multiple crop model ensemble for improving broad-scale yield prediction using Bayesian model averaging. *Field Crops Research*, 211, 114-124.
94. Hyams, D. G. (2010). CurveExpert basic. *Release 1.4*.

95. Il, H. J., Kim, H. K., & Oh, W. G. (2015, January). Study on performance of MPEG-7 visual descriptors for deformable object retrieval. In *2015 21st Korea-Japan Joint Workshop on Frontiers of Computer Vision (FCV)* (pp. 1-5). IEEE.
96. INEGI (2009). Prontuario de información geográfica municipal de los Estados Unidos Mexicanos, General Escobedo, Nuevo León Clave geoestadística 19021.
97. INEGI. (2011). Anuario estadístico de Nuevo León. Instituto Nacional de Estadística y Geografía. Gobierno del Estado de Nuevo León. ISSN 0188-8471. 594 p.
98. INEGI. (2015). Google Earth 7.1.5.1557. Compilation date 5/20/2015. Serverkh.google.com. Google Inc. 2015. (Google 2015 – INEGI 2015).
99. Ip, R. H., Ang, L. M., Seng, K. P., Broster, J. C., & Pratley, J. E. (2018). Big data and machine learning for crop protection. *Computers and Electronics in Agriculture*, 151, 376-383.
100. Ivorra Martínez, E. (2015). Desarrollo de técnicas de visión hiperespectral y tridimensional para el sector agroalimentario (Doctoral dissertation, Universitat Politècnica de València).
101. Iwata, H., Niikura, S., Matsuura, S., Takano, Y., & Ukai, Y. (2004). Interaction between genetic effects and soil type in diallel analysis of root shape and size of Japanese radish (*Raphanus sativus* L.). *Breeding Science*, 54(4), 313-318.
102. Izzo, R. R. (2019). Combining Hyperspectral Imaging and Small Unmanned Aerial Systems for Grapevine Moisture Stress Assessment. Rochester Institute of Technology.
103. Jacquemoud, S., & Ustin, S. L. (2001, January). Leaf optical properties: A state of the art. In *8th International Symposium of Physical Measurements & Signatures in Remote Sensing* (pp. 223-332). CNES Aussois France.
104. Johnstone, J. (2019). LCH and Lab colour and gradient picker <http://davidjohnstone.net/pages/lch-lab-colour-gradient-picker>, accessed on 01 June 2020.

105. Kalegowda, P., Haware, D. J., Rajarathnam, S., & Shashirekha, M. N. (2015). Minerals of cactus (*Opuntia dillenii*): cladode and fruit. *Current Science*, 2295-2298.
106. Kamruzzaman, M., ElMasry, G., Sun, D. W., & Allen, P. (2012). Non-destructive prediction and visualization of chemical composition in lamb meat using NIR hyperspectral imaging and multivariate regression. *Innovative Food Science & Emerging Technologies*, 16, 218-226.
107. Kaur, J., Cihacek, L. J., & Chatterjee, A. (2018). Estimation of nitrogen and sulfur mineralization in soils amended with crop residues contributing to nitrogen and sulfur nutrition of crops in the North Central US. *Communications in Soil Science and Plant Analysis*, 49(18), 2256-2266.
108. Kausch, W. (1965). Beziehungen zwischen Wurzelwachstum, Transpiration und CO₂ -Gaswechsel bei einigen Kakteen. *Planta*, 66(3), 229-238.
109. Kawamura-Aoyama, C., Fujiwara, K., Shinohara, M., & Takano, M. (2014). Study on the hydroponic culture of lettuce with microbially degraded solid food waste as a nitrate source. *Japan Agricultural Research Quarterly: JARQ*, 48(1), 71-76.
110. Keshava, N. (2003). A survey of spectral unmixing algorithms. *Lincoln laboratory journal*, 14(1), 55-78.
111. Khadr, M. (2016). Forecasting of meteorological drought using Hidden Markov Model (case study: The upper Blue Nile River basin, Ethiopia). *Ain Shams Engineering Journal*, 7(1), 47-56.
112. Kim, K., Yoo, K., Ki, D., Suh Son, I., Joo Oh, K., & Park, J. (2011). Decision-Tree-based data mining and rule induction for predicting and mapping soil bacterial diversity; *Environmental Monitoring and Assessment*, 178, 595-610.
113. Kim, Y., & Lee, G. (2017). Stochastic precipitation generator with hidden state covariates. *Asia-Pacific Journal of Atmospheric Sciences*, 53(3), 353-359.

114. Kovačević, M., Bajat, B., & Gajić, B. (2010). Soil type classification and estimation of soil properties using support vector machines. *Geoderma*, 154(3-4), 340-347.
115. Ji, K., Wen, R., Ren, Y., & Dhakal, Y. P. (2020). Nonlinear seismic site response classification using K-means clustering algorithm: Case study of the September 6, 2018 Mw6. 6 Hokkaido Iburi-Tobu earthquake, Japan. *Soil Dynamics and Earthquake Engineering*, 128, 105907.
116. Kusumiyati, K., Hadiwijaya, Y., Putri, I. E., & Munawar, A. A. (2021). Enhanced visible/near-infrared spectroscopic data for prediction of quality attributes in Cucurbitaceae commodities. *Data in brief*, 39, 107458.
117. Landa Salgado, Patricia; Hernández Anguiano, Ana María; Vargas Hernández, Mateo; Eslava Campos, Carlos A.; Chaidez Quiroz, Cristóbal; Patel. Jitu.; Persistencia de Salmonella Typhimurium en nopal verdura (*Opuntia ficus-indica*); *Rev. Fitotec. Mex.* Vol. 36 (2): 147 - 153, 2013.
118. Laouadi, M., Tennah, S., Moula, N., Antoine-Moussiaux, N., & Kafidi, N. (2020). Caracterización morfológica de cabras indígenas en el área de Laghouat en Argelia. *Archivos de zootecnia*, 69(267), 272-279.
119. Laouadi, M., Tennah, S., Moula, N., Antoine-Moussiaux, N., & Kafidi, N. (2020). Caracterización morfológica de cabras indígenas en el área de Laghouat en Argelia. *Archivos de zootecnia*, 69(267), 272-279.
120. Lavadiya, D. N., Sajid, H. U., Yellavajjala, R. K., & Sun, X. (2021). Hyperspectral imaging for the elimination of visual ambiguity in corrosion detection and identification of corrosion sources. *Structural Health Monitoring*. 14759217211041690.
121. Lee, J., Durst, R. W., and Wrolstad, R. E. (2005). Determination of total monomeric anthocyanin pigment content of fruit juices, beverages, natural colorants, and wines by the pH differential method: collaborative study. *Journal of AOAC international*, 88(5), 1269-1278.
122. Leon, K., Mery, D., Pedreschi, F., & Leon, J. (2006). Color measurement in L* a* b* units from RGB digital images. *Food research international*, 39(10), 1084-1091.

123. Leroux, C., Jones, H., Clenet, A., Dreux, B., Becu, M., & Tisseyre, B. (2018). A general method to filter out defective spatial observations from yield mapping datasets. *Precision Agriculture*, 19(5), 789-808.
124. Li, L., Zhang, Q., & Huang, D. (2014). A review of imaging techniques for plant phenotyping. *Sensors*, 14(11), 20078-20111.
125. Liguori, G., Inglese, G., Pernice, F., Sortino, G., & Inglese, P. (2013). CO₂ uptake of *Opuntia ficus-indica* (L.) Mill. whole trees and single cladodes, in relation to plant water status and cladode age. *Italian Journal of Agronomy*, 8(1), e3-e3.
126. Liguori, G., Inglese, P., Sortino, G., & Inglese, G. (2014). Dry matter accumulation and seasonal partitioning in mature *Opuntia ficus-indica* (L.) Mill. fruiting trees. *Italian Journal of Agronomy*, 9(1), 44-47.
127. Lim, J. H., & Kim, S. D. (2013). Induction of drought stress resistance by multi-functional PGPR *Bacillus licheniformis* K11 in pepper. *The plant pathology journal*, 29(2), 201.
128. Lim, P.O., & Nam, H.G. (2007). Aging and senescence of the leaf organ. *J. Plant Biol.* 50(3), 291–300.
129. Liu, D., Ma, J., Sun, D. W., Pu, H., Gao, W., Qu, J., & Zeng, X. A. (2014). Prediction of color and pH of salted porcine meats using visible and near-infrared hyperspectral imaging. *Food and Bioprocess Technology*, 7(11), 3100-3108.
130. Liu, J., & Wang, X. (2021). Plant diseases and pest's detection based on deep learning: a review. *Plant Methods*, 17(1), 1-18.
131. Liu, S., Wang, X., Liu, M., & Zhu, J. (2017). Towards better analysis of machine learning models: A visual analytics perspective. *Visual Informatics*, 1(1), 48-56.
132. López Portocarrero, C. A. (2019). Aplicacion de imágenes hiperespectrales para la detección temprana de roya amarilla (*Hemileya vastatrix*) en café (*Coffea arábica*), en el Distrito de Limbamba, Provincia Rodríguez de Mendoza Región Amazonas.

133. López-Borja, E. N., de Lourdes Romo-Campos, R., Arreola-Nava, H. J., Urias, A. M., & Loza-Cornejo, S. (2017). Variación morfológica en *Opuntia jaliscana* (Cactaceae). In *Anales del Jardín Botánico de Madrid* (Vol. 74, No. 1, pp. 1-11). Consejo Superior de Investigaciones Científicas.
134. Lowe, A., Harrison, N., & French, A. P. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. *Plant methods*, 13(1), 1-12.
135. Lu, C. Y., Rustia, D. J. A., & Lin, T. T. (2019). Generative adversarial network-based image augmentation for insect pest classification enhancement. *IFAC-PapersOnLine*, 52(30), 1-5.
136. Lu, Q., Si, W., Wei, L., Li, Z., Xia, Z., Ye, S., & Xia, Y. (2021). Retrieval of water quality from uav-borne hyperspectral imagery: A comparative study of machine learning algorithms. *Remote Sensing*, 13(19), 3928.
137. Luna, E., Meza, J. A., & Zegbe, J. A. (2021). El riego modifica el contenido de fenoles totales y capacidad antioxidante de los cladodios de nopal tunero. XI Reunión Nacional de Investigación Agrícola. Memoria. Ciudad de México, 10-12 nov. 2021.
138. Mahlein, A. K., Hammersley, S., Oerke, E. C., Dehne, H. W., Goldbach, H., & Grieve, B. (2015). Supplemental blue LED lighting array to improve the signal quality in hyperspectral imaging of plants. *Sensors*, 15(6), 12834-12840.
139. Majumdar, J., & Mahato, A. (2018). Comparison of SIFT & SURF Corner Detector as Features and other Machine Learning Techniques for Identification of Commonly used Leaves. *International Research Journal of Engineering and Technology (IRJET) Vol, 5*, 387-392.
140. Maki-Díaz, G., Peña-Valdivia, C. B., García-Nava, R., Arévalo-Galarza, M. L., Calderón-Zavala, G., & Anaya-Rosales, S. (2015). Características físicas y químicas de nopal verdura (*Opuntia ficus-indica*) para exportación y consumo nacional. *Agrociencia*, 49(1), 31-51.

141. Mandal, S., Choudhury, B. U., & Satpati, L. N. (2015). Monsoon variability, crop water requirement, and crop planning for kharif rice in Sagar Island, India. *International journal of biometeorology*, 59(12), 1891-1903.
142. Martel, E., Lazcano, R., López, J., Madroñal, D., Salvador, R., López, S., & Sarmiento, R. (2018). Implementation of the principal component analysis onto high-performance computer facilities for hyperspectral dimensionality reduction: Results and comparisons. *Remote Sensing*, 10(6), 864.
143. Matese, A., & Di Gennaro, S. F. (2015). Technology in precision viticulture: A state of the art review. *International Journal of Wine Research*, 7, 69-81.
144. Mayer, J. A., & Cushman, J. C. (2019). Nutritional and mineral content of prickly pear cactus: A highly water-use efficient forage, fodder and food species. *Journal of Agronomy and Crop science*, 205(6), 625-634.
145. Mayer, J. A., Wone, B. W., Alexander, D. C., Guo, L., Ryals, J. A., & Cushman, J. C. (2021). Metabolic profiling of epidermal and mesophyll tissues under water-deficit stress in *Opuntia ficus-indica* reveals stress-adaptive metabolic responses. *Functional Plant Biology*, 48(7), 717-731.
146. Mazumdar, B. C., & Majumder, K. (2003). Determination of chemical constituents. *Methods of Physico-Chemical Analysis of Fruits*, Daya Publishing house, Delhi, 93-139.
147. McCaig, T. N. (2002). Extending the use of visible/near-infrared reflectance spectrophotometers to measure colour of food and agricultural products. *Food Research International*, 35(8), 731-736.
148. McGuire, R. G. (1992). Reporting of objective color measurements. *HortScience*, 27(12), 1254-1255.
149. Meraz-Maldonado, N., Valle-Guadarrama, S., Hernández-Morales, J., Anaya-Rosales, S., Rodríguez-Maciel, J.C., & Leyva-Ruelas, G. (2012). Quality of three sizes of prickly pear cactus stems (*Opuntia ficus-indica* L. ATLI-XCO). *African J. Agric. Res.*, 7 (32), 4512–4520. doi: <http://dx.doi.org/10.5897/ajar12.956>.

150. Mishra, P., Asaari, M. S. M., Herrero-Langreo, A., Lohumi, S., Diezma, B., & Scheunders, P. (2017). Close range hyperspectral imaging of plants: A review. *Biosystems Engineering*, 164, 49-67.
151. Misra, D., Oommen, T., Agarwal, A., Mishra, S. K., & Thompson, A. M. (2009). Application and analysis of support vector machine-based simulation for runoff and sediment yield. *Biosystems engineering*, 103(4), 527-535.
152. Moghimi, A. (2019). Integrating Hyperspectral Imaging and Artificial Intelligence to Develop Automated Frameworks for High-throughput Phenotyping in Wheat. (Doctoral dissertation, University of Minnesota).
153. Mokoboki, K., & Sebola, N. (2017). Chemical composition and feed intake of *Opuntia cladodes* varieties offered to goats. *Journal of Animal & Plant Science*, 32(1), 5096-5103.
154. Molina Velázquez, M. 2001. Caracterización, ordenación y clasificación numérica en nopal (*Opuntia ficus spp.*), mediante atributos morfológicos y fisicoquímicos, tesis de posgrado.
155. Mondragón-Jacobo, C., & Pérez-González, S. (Eds.). (2001). Cactus (*Opuntia spp.*) as forage (Vol. 169). Food & Agriculture Org.
156. Morales-Morales, A. E., Andueza-Noh, R. H., Márquez-Quiroz, C., Benavides-Mendoza, A., Tun-Suarez, J. M., González-Moreno, A., & Alvarado-López, C. J. (2019). Caracterización morfológica de semillas de frijol caupí (*Vigna unguiculata* L. Walp) de la Península de Yucatán. *Ecosistemas y recursos agropecuarios*, 6(18), 463-475.
157. Munné-Bosch, S., & Alegre, L. (2004). Die and let live leaf senescence contributes to plant survival under drought stress. *Functional Plant Biology*, 31(3), 203-216.
158. Nadeem, M., Li, J., Yahya, M., Sher, A., Ma, C., Wang, X., & Qiu, L. (2019). Research progress and perspective on drought stress in legumes: A review. *International Journal of Molecular Sciences*, 20(10), 2541.
159. Nahvi, B., Habibi, J., Mohammadi, K., Shamshirband, S., & Al Razgan, O. S. (2016). Using self-adaptive evolutionary algorithm to improve the

- performance of an extreme learning machine for estimating soil temperature. *Computers and Electronics in Agriculture*, 124, 150-160.
160. Naik, H. S., Zhang, J., Lofquist, A., Assefa, T., Sarkar, S., Ackerman, D., & Ganapathysubramanian, B. (2017). A real-time phenotyping framework using machine learning for plant stress severity rating in soybean. *Plant methods*, 13(1), 1-12.
 161. Nascimento, N. C. D., & Fett-Neto, A. G. (2010). Plant secondary metabolism and challenges in modifying its operation: an overview. *Plant secondary metabolism engineering*, 1-13.
 162. Nefzaoui, A., & Ben Salem, H. (2001). *Opuntia*: a strategic fodder and efficient tool to combat desertification in the WANA (West Asia/North Africa) region. FAO Plant Production and Protection Paper (FAO).
 163. Newton, G., & Kendrick, B. (1990). Image processing in taxonomy. *Sydowia*, 42, 246-272.
 164. Niu, C., Tan, K., Jia, X., & Wang, X. (2021). Deep learning-based regression for optically inactive inland water quality parameter estimation using airborne hyperspectral imagery. *Environmental Pollution*, 286, 117534.
 165. Nobel, P. S. (1988). *Environmental Biology of Agaves and Cacti*. Cambridge University Press, New York.
 166. Nobel, P. S. (2001). *Ecophysiology of Opuntia ficus-indica. Opuntia as Forage*, FAO Plant Production and Protection Paper, 169.
 167. Nobel, P. S. (2006). Parenchyma–chlorenchyma water movement during drought for the hemiepiphytic cactus *Hylocereus undatus*. *Annals of Botany*, 97(3), 469-474.
 168. Nobel, P. S. (2011). *Sabiduría del desierto, agaves y cactus: CO₂, agua, cambio climático/Desert wisdom/agaves and cacti* (No. 625.9525 N664s Ej. 1 024989). Biblioteca Básica de Agricultura.
 169. Nobel, P. S., & De la Barrera, E. (2003). Tolerances and acclimation to low and high temperatures for cladodes, fruits and roots of a widely cultivated cactus, *Opuntia ficus-indica*. *New Phytologist*, 157(2), 271-279.

170. Nobel, P. S., & Hartsock, T. L. (1984). Physiological responses of *Opuntia ficus-indica* to growth temperature. *Physiologia Plantarum*, 60(1), 98-105.
171. Nobel, P. S., & Israel, A. A. (1994). Cladode development, environmental responses of CO₂ uptake, and productivity for *Opuntia ficus-indica* under elevated CO₂. *Journal of Experimental Botany*, 45(3), 295-303.
172. Nobel, P. S., & McDaniel, R. G. (1988). Low temperature tolerances, nocturnal acid accumulation, and biomass increases for seven species of agave. *Journal of Arid Environments*, 15(2), 147-155.
173. Nobel, P.S. (1991). Ecophysiology of roots of desert plants, with special emphasis on agaves and cacti. In: Y. Waisel, A. Eshel, and U. Kafkafi, eds., *Plant Roots: The Hidden Half*. Marcel Dekker, New York. Pp. 839-866.
174. Nobel, P.S. (1995). Environmental biology. p.36-48, in: G. Barbera, P. Inglese and E. Pimienta-Barrios (eds) *Agro-ecology, cultivation and uses of cactus pear*. FAO Plant Production and Protection
175. Nobel, P.S. (1999). Photosynthetic characteristics of CAM succulents with high productivity. In: G. Garab, ed. *Photosynthesis: Mechanisms and Effects*, Vol. V. Kluwer Academic Publishing, Dordrecht, The Netherlands. Pp. 3955-3960.
176. Nobel, P.S. (2003). *Environmental Biology of Agaves and Cacti*. Cambridge University Press, Cambridge, UK.
177. Nobel, P.S., & Hartsock, T.L. (1984). Physiological responses of *Opuntia ficus-indica* to growth temperature. *Physiol. Plant.* 60, 98–105. doi: <http://dx.doi.org/10.1111/j.1399-3054.1984.tb04257.x>.
178. Nobel, S., Abrahmsen, L., & Oppermann, U. (2001). Metabolic conversion as a pre-receptor control mechanism for lipophilic hormones. *European Journal of Biochemistry*, 268(15), 4113-4125.
179. North, G. B., Moore, T. L., & Nobel, P. S. (1995). Cladode development for *Opuntia ficus-indica* (Cactaceae) under current and doubled CO₂ concentrations. *American Journal of Botany*, 82(2), 159-166.
180. O'brien, R. M. (2007). A caution regarding rules of thumb for variance inflation factors. *Quality & quantity*, 41(5), 673-690.

181. Orona Castillo, Ignacio; Flores Hernández, Arnoldo Rivera González, Miguel; Guillermo Martínez, J.; Espinoza Arellano, J. de Jesús; Productividad del agua en el cultivo de nopal con riego por goteo en la comarca lagunera; *Terra Latinoamericana*, vol. 21, núm. 2, abril-junio, 2003, pp. 195-201, Sociedad Mexicana de la Ciencia del Suelo, A.C. Chapingo, México.
182. Ozgen, M., Reese, RN, Tulio, AZ, Scheerens, JC y Miller, AR (2006). Método modificado del ácido 2,2-azino-bis-3-etilbenzotiazolina-6-sulfónico (ABTS) para medir la capacidad antioxidante de frutas pequeñas seleccionadas y comparación con el poder antioxidante reductor férrico (FRAP) y 2,2'-difeníl-1-picrilhidrazilo (DPPH) métodos. *Revista de química agrícola y alimentaria*, 54 (4), 1151-1157.
183. Paoletti, M., Haut, J., Plaza, J., & Plaza, A. (2019). Estudio Comparativo de Técnicas de Clasificación de Imágenes Hiperespectrales. *Revista Iberoamericana de Automática e Informática industrial*, 16(2), 129 - 137. doi:<https://doi.org/10.4995/riai.2019.11078>.
184. Pérez-Cacho, M. R., Galán-Soldevilla, H., García, J. C., & Montes, A. H. (2006). Sensory characterization of nopalitos (*Opuntia spp.*). *Food research international*, 39(3), 285-293.
185. Perez-Caro, Wilmer A., González-Veloza, José J.F. (2021) Relación de los factores del suelo asociados con la presencia y ausencia de *Fusarium Oxysporum* en el cultivo de la uchuva (*Physalis Peruviana L.*). Recuperado de: <http://hdl.handle.net/11371/4332>.
186. Perez-Sanz, F., Navarro, P. J., & Egea-Cortines, M. (2017). Plant phenomics: An overview of image acquisition technologies and image data analysis algorithms. *GigaScience*, 6(11), gix092.
187. Phasinam, K., Kassanuk, T., & Shabaz, M. (2022). Applicability of internet of things in smart farming. *Journal of Food Quality*, 2022.
188. Philibert, A., Loyce, C., & Makowski, D. (2013). Prediction of N₂O emission from local information with Random Forest. *Environmental pollution*, 177, 156-163.

189. Pi, W., Du, J., Bi, Y., Gao, X., & Zhu, X. (2021). 3D-CNN based UAV hyperspectral imagery for grassland degradation indicator ground object classification research. *Ecological Informatics*, 62, 101278.
190. Pieruschka, R., & Schurr, U. (2019). Plant phenotyping: past, present, and future. *Plant Phenomics*, 2019.
191. Pimienta, E. (1990). El Nopal Tunero. Guadalajara, Mexico: Univ. Guadalajara Publisher. Mexico. 246 pp.
192. Pimienta-Barrios, E., Loera-Quezada, M., & Lopez-Amezcuca, L. L. (1993). Estudio anatómico comparativo en colectas del subgénero *Opuntia*. *Agrociencia*, 4(3), 7-19.
193. Pimienta-Barrios, E., Zanudo-Hernandez, J., Rosas-Espinoza, V. C., Valenzuela-Tapia, A., & Nobel, P. S. (2005). Young daughter cladodes affect CO₂ uptake by mother cladodes of *Opuntia ficus-indica*. *Annals of Botany*, 95(2), 363-369.
194. Pinto, J., Rueda-Chacón, H., & Arguello, H. (2019). Classification of Hass avocado (persea americana mill) in terms of its ripening via hyperspectral images. *TecnoLógicas*, 22(45), 111-130.
195. Rahmat, S. N., Jayasuriya, N., & Bhuiyan, M. A. (2017). Short-term droughts forecast using Markov chain model in Victoria, Australia. *Theoretical and Applied Climatology*, 129(1), 445-457.
196. Rainville, D., Durand, A., Fortin, F. A., Tanguy, K., Maldague, X., Panneton, B., & Simard, M. J. (2014). Bayesian classification and unsupervised learning for isolating weeds in row crops. *Pattern Analysis and Applications*, 17(2), 401-414.
197. Ramadan, M. F., Ayoub, T. E. M., & Rohn, S. (2021). *Opuntia spp.*: Chemistry, Bioactivity and Industrial Applications.
198. Raveh, E., & Nobel, P. S. (1999). CO₂ uptake and water loss accompanying vernalization for detached cladodes of *Opuntia ficus-indica*. *International journal of plant sciences*, 160(1), 92-97.

199. Raveh, E., Gersani, M., & Nobel, P. S. (1995). CO₂ uptake and fluorescence responses for a shade-tolerant cactus *Hylocereus undatus* under current and doubled CO₂ concentrations. *Physiologia Plantarum*, 93(3), 505-511.
200. Retamal, N., Durán, J. M., & Fernández, J. (1987). Seasonal variations of chemical composition in prickly pear (*Opuntia ficus-indica* (L.) miller). *Journal of the Science of Food and Agriculture*, 38(4), 303-311.
201. Rhee, J., & Im, J. (2017). Meteorological drought forecasting for ungauged areas based on machine learning: Using long-range climate forecast and remote sensing data. *Agricultural and Forest Meteorology*, 237, 105-122.
202. Rhoades, J. D. (1992). The use of saline waters for crop production (No. 628.167 F3). FAO.
203. Rice-Evans, C., Miller, N., & Paganga, G. (1997). Antioxidant properties of phenolic compounds. *Trends in plant science*, 2(4), 152-159.
204. Rodríguez-Martínez, N. (2019). Análisis comparativo de imágenes normales versus IRF, para detectar deshidratación en plantas usando redes neuronales.
205. Rodríguez, Armida & Fortiz, Judith (2017); Calidad de nopal fresco cortado envasado con películas plásticas durante el almacenamiento a baja temperatura; *Revista Mexicana de Ciencias Agrícolas*; 10.29312/remexca.v7i4.255.
206. Roperó, R. M. F., Aguilera, P. A., Fernández, A., & Rumí, R. (2014). Redes bayesianas: una herramienta probabilística en los modelos de distribución de especies. *Ecosistemas*, 23(1), 54-60.
207. Rossi Neto, J., de Souza, Z. M., de Medeiros Oliveira, S. R., Kölln, O. T., Ferreira, D. A., Carvalho, J. L. N., ... & Franco, H. C. J. (2017). Use of the decision tree technique to estimate sugarcane productivity under edaphoclimatic conditions. *Sugar Tech*, 19(6), 662-668.
208. Roushangar, K., & Alizadeh, F. (2018). A multiscale spatio-temporal framework to regionalize annual precipitation using k-means and self-organizing map technique. *Journal of Mountain Science*, 15(7), 1481-1497.

209. Rumpf, T., Mahlein, A. K., Steiner, U., Oerke, E. C., Dehne, H. W., & Plümer, L. (2010). Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance. *Computers and electronics in agriculture*, 74(1), 91-99.
210. Rustia, D. J. A., Chao, J. J., Chiu, L. Y., Wu, Y. F., Chung, J. Y., Hsu, J. C., & Lin, T. T. (2021). Automatic greenhouse insect pest detection and recognition based on a cascaded deep learning classification method. *Journal of Applied Entomology*, 145(3), 206-222.
211. Rustia, D. J. A., Lin, C. E., Chung, J. Y., & Lin, T. T. (2018, May). A real-time multi-class insect pest identification method using cascaded convolutional neural networks. In *Proceedings of the 9th International Symposium on Machinery and Mechatronics for Agriculture and Biosystems Engineering (ISMAB), Jeju, Korea (Vol. 28)*.
212. SAGARPA. (2015). Estudio de factibilidad para el establecimiento de cultivo de nopal (*Opuntia*) en tierras ociosas en los estados de Aguascalientes, San Luis Potosí, Guanajuato y Zacatecas con fines alimenticios, energéticos y ambientales.
213. Sánchez-Méndez, A. G., & Arguijo-Hernández, S. P. (2018). Análisis de imágenes multiespectrales para la detección de cultivos y detección de plagas y enfermedades en la producción de café. *Res. Comput. Sci.*, 147(7), 309-317.
214. Sankaran, S. (2016). High-Throughput Crop Phenotyping Technologies. *Resource Magazine*, 23(3), 24-25.
215. Santiago-Lorenzo, Ma. del Rocío, López-Jiménez, Alfredo, Saucedo-Veloz, Crescenciano, Cortés-Flores, José I., Jaén-Contreras, David, & Suárez-Espinosa, Javier. (2016). Composición nutrimental del nopal verdura producido con fertilización mineral y orgánica. *Revista fitotecnia mexicana*, 39(4), 403-407.
216. Sari, D. K., Hermawan, E. T., & Hudman, G. (2005). Study On Vegetation Cover Change in The Province of South Kalimantan Using RGB-NDVI Unsupervised Classification Method. In *Map Asia Conference. Jakarta*.

217. Saussure, S., Plantegenest, M., Thibord, J. B., Larroudé, P., & Poggi, S. (2015). Management of wireworm damage in maize fields using new, landscape-scale strategies. *Agronomy for Sustainable Development*, 35(2), 793-802.
218. Shah, M., Fazil, S. M., Ali, S. R., Pandey, Y., Faisal, S., & Mehraj, I. (2017). Modeling of runoff using curve expert for Dachigam-Telbal catchment of Kashmir valley, India. *Journal of Current Microbiology and Applied Sciences*, 6(11), 3822-3826.
219. Shakeel, P. M., Baskar, S., Dhulipala, V. R., & Jaber, M. M. (2018). Cloud based framework for diagnosis of diabetes mellitus using K-means clustering. *Health information science and systems*, 6(1), 1-7.
220. Shicheng, Q., Youwen, T., Qinghu, W., Shiyuan, S., & Ping, S. (2021). Nondestructive detection of decayed blueberry based on information fusion of hyperspectral imaging (HSI) and low-field nuclear magnetic resonance (LF-NMR). *Computers and Electronics in Agriculture*, 184, 106100.
221. Shoop, M. C., Alford, E. J., & Mayland, H. F. (1977). Plains pricklypear is a good forage for cattle. *Journal of Range Management*, 30(1), 12-17.
222. SIAP. (2018). Producción Agrícola 2018, Ciclo: Ciclicos – Perennes, Modalidad: Riego + Temporal, Cultivo: Nopalitos (<https://nube.siap.gob.mx/cierreagricola/>).
223. SIAP. (2021). Servicio de Información Agroalimentaria y Pesquera Producción Agrícola 2018, Ciclo: Ciclicos – Perennes, Modalidad: Riego + Temporal, Cultivo: Nopalitos (<https://nube.siap.gob.mx/cierreagricola/>), accessed on 15 July 2020.
224. Singh, R. S., & Singh, V. (2003). Growth and Development Influenced by Size, Age, and Planting Methods of Cladodes in Cactus Pear (*Opuntia ficus-indica* (L.) Mill.).
225. Singh, V., Sharma, N., & Singh, S. (2020). A review of imaging techniques for plant disease detection. *Artificial Intelligence in Agriculture*, 4, 229-242.

226. Snyman, H. A. (2014). Influence of water stress on root development of *Opuntia ficus-indica* and *O. robusta*. *Arid Land Research and Management*, 28(4), 447-463.
227. Sofy, M. R., Sharaf, A. E. M., Osman, M. S., & Sofy, A. R. (2017). Physiological changes, antioxidant activity, lipid peroxidation and yield characters of salt stressed barely plant in response to treatment with Sargassum extract. *International Journal of Advanced Research in Biological Sciences*, 4(2), 90-109.
228. Sonnadara, D. U. J., & Jayewardene, D. R. (2015). A Markov chain probability model to describe wet and dry patterns of weather at Colombo. *Theoretical and applied climatology*, 119(1), 333-340.
229. Stanaway, M. A., Mengersen, K. L., & Reeves, R. (2011). Hierarchical Bayesian modelling of early detection surveillance for plant pest invasions; *Environmental and Ecological Statistics*; 18(3), 569–591.
230. Sun, Z., Di, L., Zhang, C., Fang, H., Yu, E., Lin, L., & Liu, Z. (2017, August). Establish cyberinfrastructure to facilitate agricultural drought monitoring. In *2017 6th International Conference on Agro-Geoinformatics* (pp. 1-4). IEEE.
231. Supriyatna, A., Carolina, I., Widiati, W., & Nuraeni, C. (2020, March). Rice productivity analysis by province using K-means cluster algorithm. In *IOP Conference Series: Materials Science and Engineering* (Vol. 771, No. 1, p. 012025). IOP Publishing.
232. Szuvandzsiev, P., Helyes, L., Lugasi, A., Szántó, C., Baranowski, P., & Pék, Z. (2014). Estimation of antioxidant components of tomato using VIS-NIR reflectance data by handheld portable spectrometer. *International Agrophysics*, 28(4).
233. Talemi, E. P., & Sedaghatoor, S. (2017). A study on biochemical properties of different parts of three *Opuntia* species (*Opuntia ficus-indica*, *O. microdasys*, and *O. basilaris*). *Journal of the Professional Association for Cactus Development*, 19, 32-44.

234. Tejada, G., Velasquez, C., Aredo, V., Cruz-Tirado, J. P., & Siche, R. (2021). Predicción del contenido de almidón en queso fresco adulterado utilizando Regresión de Mínimos Cuadrados Parciales, Regresión Lineal Múltiple e Imágenes Hiperespectrales. *Journal of Agro-industry Sciences*, 3(1), 15-20.
235. Teles, F. F. F. (1977). Nutrient analysis of prickly pear (*Opuntia ficus-indica*, Linn). The University of Arizona.
236. Tettey, M., Oduro, F. T., Adedia, D., & Abaye, D. A. (2017). Markov chain analysis of the rainfall patterns of five geographical locations in the south eastern coast of Ghana. *Earth Perspectives*, 4(1), 1-11.
237. Thorp, K., Andrade-Sanchez, P., Gore, M., White, J., & French, A. (2012). Information Technologies for Field-Based High-Throughput Phenotyping. *Resource Magazine*, 19(5), 8-9.
238. Torres-Ponce, R. L., Morales-Corral, D., Ballinas-Casarrubias, M. D. L., & Nevárez-Moorillón, G. V. (2015). El nopal: planta del semidesierto con aplicaciones en farmacia, alimentos y nutrición animal. *Revista mexicana de ciencias agrícolas*, 6(5), 1129-1142.
239. Trevezas, S., Malefaki, S., & Cournède, P. H. (2014). Parameter estimation via stochastic variants of the ECM algorithm with applications to plant growth modeling. *Computational Statistics & Data Analysis*, 78, 82-99.
240. Tulbure, M. G., Broich, M., Stehman, S. V., & Kommareddy, A. (2016). Surface water extent dynamics from three decades of seasonally continuous Landsat time series at subcontinental scale in a semi-arid region. *Remote Sensing of Environment*, 178, 142-157.
241. Tyssso, V. (1987). UNSCRAMBLER, an interactive program for multivariate calibration and prediction. *Chemometrics and intelligent laboratory systems*, 2(1-3), 239-243.
242. Valencia, J. R., Murrugarra, C., Villa Zabala, C., & Tarazona-Díaz, M. P. (2018). Arquitectura de un Dispositivo no Invasivo para el Seguimiento de la Conservación de Alimentos en Empaques Inteligentes.
243. Van De Vijver, R., Mertens, K., Heungens, K., Somers, B., Nuyttens, D., Borra-Serrano, I., & Saeys, W. (2020). In-field detection of *Alternaria solani*

- in potato crops using hyperspectral imaging. *Computers and Electronics in Agriculture*, 168, 105106.
244. Vázquez Otero, M. (2019). *Análisis de imágenes hiperespectrales obtenidas con el sensor AHS* (Doctoral dissertation).
 245. Vázquez-Alvarado, R. E., Valdez-Cepeda, R. D., Blanco-Macías, F., Ojeda-Zacarías, M. D. C., & Martínez-López, J. R. (2009). Producción hidropónica de nopal verdura. *VIII Simposium-Taller Nacional y 1er. Internacional de "Producción y Aprovechamiento del Nopal*, 13-14.
 246. Veena Divya, K., Jatti, A., Joshi, R., & Meharaj, S. (2016). Image processing and parameter extraction of digital panoramic dental X-rays with ImageJ. In *International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)* (pp. 450-454).
 247. Verdú, S., Vázquez, F., Grau, R., Ivorra, E., Sánchez, A. J., & Barat, J. M. (2016). Detection of adulterations with different grains in wheat products based on the hyperspectral image technique: The specific cases of flour and bread. *Food Control*, 62, 373-380.
 248. Visa, S., Cao, C., Gardener, B. M., & Van Der Knaap, E. (2014). Modeling of tomato fruits into nine shape categories using elliptic fourier shape modeling and Bayesian classification of contour morphometric data. *Euphytica*, 200(3), 429-439.
 249. Vuong, V. L., Slaughter, D. C., Clair, D. S., Bosland, P., Kubond, B., & Kaur, A. (2018). High-Throughput Phenotyping Methods for Green Fruit. In *2018 ASABE Annual International Meeting* (p. 1). American Society of Agricultural and Biological Engineers.
 250. Wageningen University and Research. (2019). <https://www.wur.nl/en.htm>
 251. Waheed, T., Bonnell, R. B., Prasher, S. O., & Paulet, E. (2006). Measuring performance in precision agriculture: CART—A decision tree approach. *Agricultural water management*, 84(1-2), 173-185.
 252. Wang, J., Shi, T., Yu, D., Teng, D., Ge, X., Zhang, Z., ... & Wu, G. (2020). Ensemble machine-learning-based framework for estimating total nitrogen concentration in water using drone-borne hyperspectral imagery of

- emergent plants: A case study in an arid oasis, NW China. *Environmental Pollution*, 266, 115412.
253. Wang, N., Zhang, H., & Nobel, P. S. (1997). Phloem-xylem water flow in developing cladodes of *Opuntia ficus-indica* during sink-to-source transition. *Journal of Experimental Botany*, 48(3), 675-682.
 254. Were, K., Bui, D. T., Dick, Ø. B., & Singh, B. R. (2015). A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afromontane landscape. *Ecological Indicators*, 52, 394-403.
 255. Windarto, A. P., & Wanto, A. (2018, September). Data mining tools| rapidminer: K-means method on clustering of rice crops by province as efforts to stabilize food crops in Indonesia. In *IOP Conference Series: Materials Science and Engineering* (Vol. 420, No. 1, p. 012089). IOP Publishing.
 256. Winter, K., Medina, E., Garcia, V., Mayoral, M. L., & Muniz, R. (1985). Crassulacean acid metabolism in roots of a leafless orchid, *Campylocentrum tyrridion* Garay & Dunsterv. *Journal of Plant Physiology*, 118(1), 73-78.
 257. Wirth, M. A. (2001). Shape analysis and measurement. University of Guelph. CIS, 6320.
 258. Xu, S., Wang, M., Shi, X., Yu, Q., & Zhang, Z. (2021). Integrating hyperspectral imaging with machine learning techniques for the high-resolution mapping of soil nitrogen fractions in soil profiles. *Science of The Total Environment*, 754, 142135.
 259. Y. Jia, J. Wang, and L. Shang, "Research on Electric Braking Simulation Program of Rail Transit Based on MATLAB Simulation Technology," *2020 IEEE International Conference on Artificial Intelligence and Information Systems (ICAIS)*, 2020, pp. 494-499, doi: 10.1109/ICAIS49377.2020.9194864.
 260. Yang, X., Lu, M., Wang, Y., Wang, Y., Liu, Z., & Chen, S. (2021). Response mechanism of plants to drought stress. *Horticulturae*, 7(3), 50.

261. Yano, I. H., Alves, J. R., Santiago, W. E., & Mederos, B. J. (2016). Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier. *IFAC-PapersOnLine*, 49(16), 415-420.
262. Yao, J., Sun, D., Cen, H., Xu, H., Weng, H., Yuan, F., & He, Y. (2017). Phenotyping of Arabidopsis drought stress response using kinetic chlorophyll fluorescence and multicolor fluorescence imaging. *Frontiers in plant science*, 9, 603.
263. Yaron, D., & Olian, A. (2002). Application of Dynamic Programming in Markov Chains to the Evaluation of Water Quality in Irrigation. In *Economics of Water Resources, The Contributions of Dan Yaron* (pp. 63-72). Springer, Boston, MA.
264. Yendrek, C. R., Tomaz, T., Montes, C. M., Cao, Y., Morse, A. M., Brown, P. J., & Ainsworth, E. A. (2017). High-throughput phenotyping of maize leaf physiological and biochemical traits using hyperspectral reflectance. *Plant physiology*, 173(1), 614-626.
265. Yu, X., Liu, Q., Wang, Y., Liu, X., & Liu, X. (2016). Evaluation of MLSR and PLSR for estimating soil element contents using visible/near-infrared spectroscopy in apple orchards on the Jiaodong peninsula. *Catena*, 137, 340-349.
266. Zegbe-Domínguez, R.J.A., Melero-Meraz, V. Campos-Fajardo, M.G. (2021). Acumulación de prolina en cladodios productivos de nopal tunero sometido a riego suplementario. XI Reunión Nacional de Investigación Agrícola. Memoria. Ciudad de Mexico, 10-12 nov.2021.
267. Zhang, Z., Flores, P., Igathinathane, C., L Naik, D., Kiran, R., & Ransom, J. K. (2020). Wheat lodging detection from UAS imagery using machine learning algorithms. *Remote Sensing*, 12(11), 1838.
268. Žunić, J. (2012). Shape descriptors for image analysis. *Zbornik Radova*, (23), 5-38.
269. Zúñiga-Tarango, R., Orona-Castillo, I., Vázquez-Vázquez, C., Murillo-Amador, B., Salazar-Sosa, E., López-Martínez, J. D., ... & Rueda-Puente, E. (2009). Root growth, yield and mineral concentration of *Opuntia ficus-*

indica (L.) Mill. under different fertilization treatments. *Journal of the Professional Association for Cactus Development*, 11, 53-68.