

Autor

Nombre de la tesis

Año



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Estudio de la correlación entre contenido de
Nitrógeno Fósforo y Potasio en hojas de jitomate y color

Tesis

**Que como parte de los requisitos para
obtener el Grado de**

Maestro en Ingeniería en Biosistemas

Presenta

Leslie Yunen Villegas Rosas

Dirigido por:

Dr. Genaro Martín Soto Zarazúa

Querétaro, Qro. a _____



Dirección General de Bibliotecas y Servicios Digitales
de Información



Estudio de la correlación entre contenido de
Nitrógeno Fósforo y Potasio en hojas de jitomate y
color

por

Leslie Yunen Villegas Rosas

se distribuye bajo una [Licencia Creative Commons
Atribución-NoComercial-SinDerivadas 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/).

Clave RI: IGMAC-309252



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Maestría en Ingeniería en Biosistemas

Estudio de la correlación entre contenido de Nitrógeno Fósforo y Potasio en hojas de jitomate y color

TESIS

Que como parte de los requisitos para obtener el grado de:

Maestro en Ingeniería en Biosistemas

Presenta:

Leslie Yunen Villegas Rosas

Dirigido por:

Dr. Genaro Martín Soto Zarazúa

SINODALES

Dr. Genaro Martín Soto Zarazúa

Presidente

Firma

Dr. Manuel Toledano Ayala

Secretario

Firma

Dr. Humberto Aguirre Becerra

Vocal

Firma

Dr. Luis Miguel Contreras Medina

Suplente 1

Firma

Dr. Gonzalo Macías Bobadilla

Suplente 2

Firma

Nombre y Firma
Director de la Facultad

Nombre y Firma
Director de Investigación y
Posgrado

Centro Universitario
Querétaro, Qro.

19 de septiembre de 2023

DEDICATORIA

A mi peculiar familia

AGRADECIMIENTOS

A todos los que hicieron este proyecto posible. Trabajadores del campus, profesores, compañeros de grado, generación, de campus, y de facultad. A todos los doctores y catedráticos que tendieron la mano ya sea física o intelectualmente para el desarrollo. A el alumnado y gente de campus Amazcala que ayudaron a adaptarme, sobrevivir, y prosperar a un lugar tan extraño como el campus. Sin ustedes esto no habría sido posible.

A mi tía Gabriela quien me dio asilo y fue confidente, amiga, soporte, y mamá. A Raúl, Has, sin ti la experimentación no habría sido completada. A mis compañeros de generación quienes fueron una constante y pilar en la aventura, que ahora concluimos, llamada maestría en biosistemas.

ÍNDICE

Capítulo 1	12
1.1 INTRODUCCION	12
1.2 ANTECEDENTES CIENTÍFICOS	14
1.3 ANTECEDENTES TECNOLÓGICOS	16
1.4 MONITOREO TECNOLÓGICO	21
1.5 COMERCIALMENTE DISPONIBLE	22
1.5 DESCRIPCIÓN DEL PROBLEMA	24
1.6 JUSTIFICACIÓN	26
1.7 HIPÓTESIS Y OBJETIVOS	28
Hipótesis	28
Objetivo general.....	28
Objetivos particulares	28
Capítulo 2	29
2 FUNDAMENTACIÓN TEÓRICA	29
2.1 NPK en plantas de Tomate	29
2.1.1 Nitrógeno, N.....	29
2.1.2 Fósforo, P.....	30
2.1.3 Potasio, K.....	31
2.2 Regresión e índices de correlación.....	32
2.3 Imágenes RGB.....	36
Capítulo 3	39
3 METODOLOGÍA	39
3.1 Materiales	39
3.2 Métodos	39

<i>Capítulo 4 RESULTADOS Y DISCUSIÓN</i>	49
5 CONCLUSIÓN	59
BIBLIOGRAFÍA	60

FIGURAS

Figura 3.1 Diagrama de metodología	39
Figura 3.2 imagen satelital del sitio experimental (invernadero)	40
Figura 3.3 Plantulas injertadas, previo a trasplante	41
Figura 3.4 Frutos obtenidos en el invernadero experimental bajo observancia de buenas prácticas	42
Figura 3.5 Hoja de jitomate muestreada	43
Figura 3.6 Análisis de muestras, UAQ Campus Amealco.....	45
Figura 3.7 Preparación de muestras, UAQ Campus Amazcala	46
Figura 4.1 Imagen original CCF12072023_0001	49
Figura 4.2 Imagen procesada CCF12072023_0001	50
Figura 4.3 Regresión rojo, nitrógeno	53
Figura 4.4 Regresión rojo, potasio.....	54
Figura 4.5 Regresión rojo, potasio.....	54
Figura 4.6 Regresión verde, nitrógeno	55
Figura 4.7 Regresión verde, fósforo	56
Figura 4.8 Regresión verde, potasio	56
Figura 4.9 Regresión azul, nitrógeno.....	57
Figura 4.10 Regresión azul, fósforo	58
Figura 4.11 Regresión azul, potasio	58

TABLAS

Tabla 2.1 Contenido de nutrientes en hojas de jitomate y sus funciones (Sanju et al, 2003).....	32
Tabla 3.1 Formulación de la solución nutritiva utilizada en el cultivo	41
Tabla 3.2 Diluciones para lecturas y factores de corrección	48
Tabla 4.1 Estadísticos de lecturas del extracto celular	51

ABREVIATURAS Y SIGLAS

Azul: Canal azul

DGCI: Índice de color verde oscuro

G: Canal verde

K: Potasio

N: Nitrógeno

NPK: Nitrógeno, fósforo, y potasio

P: Fósforo

R: Canal rojo

RGB: Modelo de color rojo, verde, y azul

RESUMEN

Una de las principales causas de disminución en la productividad o pérdida del cultivo son las deficiencias nutricionales; entre estas, destacan las de nitrógeno, fósforo, y potasio. Debido a esto, este proyecto sienta bases para una cadena de desarrollo tecnológica que culmine en una tecnología capaz de detectar deficiencias y excesos nutrimentales en cultivos de tomate in situ, de alta eficiencia, y bajo costo. En esta etapa, se estudió la correlación entre los colores de una hoja de tomate y contenido de nitrógeno, fósforo, y potasio (NPK). Las muestras se recolectaron de un invernadero para producción comercial perteneciente a la UAQ Campus Amazcala. Se recolectó el tercer foliolo de la hoja ocho de 100 plantas distintas en etapa de fructificación y llenado de fruto. Las hojas fueron capturadas por medio de un scanner Brother MFC-7860DW para estandarizar las condiciones de iluminación y radiancia evitando así ruido en el análisis. Para la estimación de NPK en savia se maceró la hoja con agua desionizada, el sobrenadante se analizó en un espectrofotómetro HANNA para análisis de nutrientes. Se crearon nueve gráficas de dispersión para estudiar la correlación entre el color promedio de la hoja y el contenido de nutrientes; se iteró con cinco modelos de línea de tendencia buscando el mejor ajuste entre estos. De las nueve combinaciones color-nutriente ninguna tuvo un R cuadrado superior al objetivo, 0.7 por lo que se rechaza la hipótesis y se propone buscar distintas metodologías de análisis de imagen para cuantificar NPK en hojas por medio de procesamiento de imagen. No se encontró una correlación cuantificable entre el contenido de nitrógeno, fósforo, y potasio de una hoja de tomate y valores RGB promedio de una imagen de hoja de tomate

Palabras clave: deficiencias nutricionales, procesamiento de imagen, NPK, modelo de correlación

SUMMARY

Nitrogen, phosphorus, and potassium (NPK) are the main causes of production decrease in tomato. Therefore, aims to study the correlation between RGB color values and BPK content in a tomato leaf to kick off a technology development process oriented towards a high efficiency and low cost in situ deficiency technology.

Leaf samples were collected from a greenhouse used for commercial production belonging to the UAQ Campus Amazcala. The third leaflet of the leaf was collected from eight. 100 different plants were sampled one leaf per plant, in t stage of fruiting and fruit filling. To standardize illumination and radiance to avoid npise in the analysis; leaves were recorded using a Brother MFC-7860DW scanner. For the estimation of NPK in sap, the leaves were macerated with deionized water, the supernatant was analyzed in a HANNA spectrophotometer for nutrient analysis. Nine scatter plots were created to study the correlation between average leaf color and nutrient content; iterated with five trend line models looking for the best fit between them. Of the nine color-nutrient combinations, none had an R square higher than the objective, 0.7; thus the hypothesis is rejected, and it is proposed to search for different image analysis methodologies to quantify NPK in leaves through image processing. No quantifiable correlation was found between the nitrogen, phosphorus, and potassium content of a tomato leaf and average RGB values of a tomato leaf image.

Keywords: nutritional deficiencies, image processing, NPK, correlation model

Capítulo 1

1.1 INTRODUCCION

México es un referente en el mercado mundial del tomate, cuyas exportaciones se dirigen principalmente a Estados Unidos, con un superávit comercial de 2,306 millones de dólares en 2021, y ventas a países como Canadá, Japón, Emiratos Árabes, Emiratos Árabes Unidos, Bélgica y Singapur, entre otros mercados (Forbes, 2022). Durante el periodo de 2003 a 2017, en México se produjeron en promedio 2.5 millones de toneladas de tomate rojo y se generan por año 14,759 millones de pesos (SIAP, 2020). Es uno de los cultivos más rentables para el país, ha registrado un crecimiento promedio de 9.5% en los últimos 10 años. Al cierre de 2020 se obtuvo un volumen de 3.27 millones de toneladas, en una superficie de más de 45,000 hectáreas y un consumo per cápita de 13.4 kilogramos (SADER, 2020).

Representa 3.4% del PIB agrícola nacional y 22.55% de la producción total de hortalizas en el país (SAGARPA 2016). A pesar de que se satisface la demanda nacional más un excedente de importación, para en 2030 se estima un aumento en la demanda mundial de 8.92 a 11.8 MMT (SAGARPA, 2016). Esto representa un aumento acumulado de 32.1%. Tan solo la demanda nacional debe incrementarse de 3,35 MMt a 7,56 MMt; crecimiento acumulado de 125.8%. Por lo tanto es preponderante incursionar la maximización de recursión para eficientar la producción. A 2023, el tomate se mantiene como la hortaliza de mayor producción, ya que se cultiva para atender la demanda nacional y la exportación.

El estrés por deficiencia nutricional es un desorden fisiológico que afecta la calidad y cantidad del producto (Mall, 2021). El fenómeno debe ser identificado antes de que se visualicen sus síntomas para obtener el máximo rendimiento y productos de mejor calidad. Existen dos clases de nutrientes para las plantas: macronutrientes y micronutrientes. Los macronutrientes son los componentes básicos de componentes celulares cruciales como proteínas y ácidos nucleicos; como sugiere su nombre, se requieren en grandes cantidades. El nitrógeno, el fósforo, el magnesio y el potasio son algunos de los macronutrientes más importantes (Morgan, 2013).

El nitrógeno es generalmente el más importante y también el principal factor limitante para el crecimiento de los cultivos y la productividad agrícola (Anas, 2020). Constituye compuestos orgánicos vitales para las plantas y contribuye a la fructificación,

productividad y rentabilidad económica, pero puede disminuir la firmeza de la fruta (Marschner et al, 2012). A pesar de ser absorbido en menor cantidad y tener menores concentraciones en el tejido vegetal, el fósforo es sumamente importante en la formación y crecimiento de las raíces, además de incrementar la calidad comercial del fruto (Mueller et al., 2013; Nowaki et al., 2017). El potasio es el nutriente más requerido por el tomate (Prado et al., 2011) y contribuye a los procesos de fotosíntesis, activación enzimática y síntesis de proteínas (Rebouças Neto et al., 2016). Se debe recomendar un equilibrio entre la disponibilidad de nutrientes, la dosis de fertilizante y el tiempo de aplicación para reducir el riesgo de contaminación ambiental y aumentar la eficiencia del uso de fertilizantes por parte de la planta cultivada. De este modo, la adopción y mantenimiento de dosis balanceadas de NPK, además de incrementar la productividad y concentración de sólidos solubles, puede incrementar el rendimiento de pulpa, firmeza de frutos de tomates industriales, entre otros (Almeida et al, 2019).

A pesar de su relevancia, hoy en día, las deficiencias en campo se detectan de manera visual y, de ser posible, se estima la deficiencia o exceso mediante estudios de laboratorio que pueden tomar semanas y elevan significativamente el costo de producción. La medición directa de la concentración de NPK en las hojas mediante un procedimiento de laboratorio es laboriosa, destructiva, requiere mucho tiempo y es costosa (Nachimuthu et al., 2007). Dichos procedimientos tienen un uso limitado como herramienta de diagnóstico para optimizar la cobertura de NPK debido a la gran demora entre el muestreo y la obtención de resultados (Yang et al., 2003).

El procesamiento de imágenes es un método no destructivo para diversas aplicaciones agrícolas que se puede implementar de manera efectiva con mayor precisión. Los síntomas de deficiencia visual, la prueba del suelo, la prueba del tejido vegetal y las respuestas de los cultivos a los fertilizantes químicos o abonos orgánicos son los cuatro métodos para identificar los trastornos de los nutrientes en las plantas de cultivo; esto permite evaluar el estado de N de la planta por medio de imágenes. El pigmento de clorofila en las hojas absorbe el rojo, el azul y una pequeña proporción de las longitudes de onda verdes que inciden en las plantas. Debido a que la concentración de N en los tejidos afecta la síntesis de clorofila en las plantas, una deficiencia de N en el tejido puede disminuir la concentración de clorofila y aumentar la reflectancia de las longitudes de onda rojas, azules y verdes de las

plantas (Francini, 2019). Por lo tanto, se puede realizar una evaluación indirecta del estrés por N que experimentan las plantas midiendo la reflectancia de las longitudes de onda roja, azul y verde de una hoja. Las imágenes se componen de píxeles que almacenan información sobre la intensidad de la luz reflejada de un objeto. Procesos similares ocurren con cada uno de los nutrientes restantes.

En consecuencia, en este proyecto se determina la relación entre contenido de NPK y valores RGB de una hoja para plantear las bases para desarrollar una herramienta económica, rápida y confiable para la estimación del contenido de NPK, no destructiva, sin alterar a la planta, y de bajo costo. Reduciendo así el intervalo entre toma de muestra y resultados a la par de optimizar los procesos de atención al cultivo y minimizar el tiempo de procesamiento de dos semanas a minutos.

1.2 ANTECEDENTES CIENTÍFICOS

El diagnóstico nutricional basado en la tecnología de procesamiento de imágenes digitales no solo es conveniente y rápido, sino también asequible porque no requiere una tecnología costosa de procesamiento de datos. En consecuencia, este método se ha utilizado ampliamente en los últimos años. Los investigadores han analizado imágenes de hojas utilizando tecnología de procesamiento de imágenes digitales para proporcionar apoyo para diagnosticar el estado nutricional de los cultivos (Li et al, 2011). El color de las hojas ha sido reconocido como uno de los indicadores más sensibles de las deficiencias de nutrientes (Blinn et al, 1988), y el nitrógeno está directamente relacionado con el color de las hojas porque es un componente clave de la molécula de clorofila. Anteriormente, los investigadores encontraron una relación entre el contenido de nitrógeno y el color de las hojas que aparece en las imágenes. Blinn y col. (Blinn, 1988) utilizó fotografías aéreas para evaluar la necesidad de fertilizantes en las plantaciones de pino piñonero. Scharf y col. (Scharf, 2002) estableció un modelo lineal entre el valor G / B del dosel del maíz y la aplicación mínima de nitrógeno. Después de más de 30 años de desarrollo, se han aplicado técnicas no destructivas para evaluar el nitrógeno mediante imágenes digitales en arroz (*Oryza glaberrima* L.), trigo (*Triticum aestivum* L.), maíz (*Zea mays* L.), algodón (*Gossypium* spp.) y algunas otras verduras. Lee y col. (Lee et al, 2013) extrajo la cobertura del dosel y diez tipos de indicadores

de color para el arroz; informaron que esos indicadores pueden coincidir con precisión con las diferencias causadas por variedades y gradientes. Para estimar la cantidad requerida de fertilizante nitrogenado, Intaravanne et al. Propusieron un analizador de color de hojas de arroz basado en Android. (Intaravanne et al, 2015); La idea clave de este enfoque es capturar y procesar simultáneamente los datos de imágenes en color bidimensionales (2-D) de las hojas de arroz y su entorno. En un experimento con trigo, Baresel et al (Baresel et al, 2019) utilizó tanto análisis de imágenes como mediciones de clorofila para realizar una detección no destructiva. Los resultados mostraron que las mediciones de clorofila no pueden reflejar la biomasa, mientras que el análisis de imágenes puede reflejar tanto la biomasa como el contenido de nitrógeno de las hojas.

El desarrollo de modelos de color, dispositivos y tecnologías de inteligencia artificial ha hecho que el procesamiento de imágenes sea más conveniente y se han propuesto muchos métodos nuevos. Romualdo y col. (Romuealdo et al, 2018) utilizó técnicas de visión artificial y procesamiento de imágenes digitales para realizar diagnósticos del estado nutricional de nitrógeno en el maíz; este enfoque puede identificar deficiencias de nutrientes en varias etapas del desarrollo de la planta, especialmente en las primeras etapas de crecimiento. Confalonieri et al. (Confalonieri et al, 2015) Contenido estimado de nitrógeno de las hojas y las plantas utilizando un método de índice de color verde oscuro gris al 18% (DGCI). En comparación con el DGCI y el DGCI corregido, el nuevo método es considerablemente más estable en cuanto a veracidad y precisión. En India se desarrolló una aplicación basada en procesamiento de imágenes y redes convolucionales para la detección de enfermedades del arroz y deficiencias de nutrientes (Nayak et, al, 2023). Se utilizaron imágenes de teléfonos inteligentes para clasificar 12 enfermedades del arroz y síntomas de deficiencia de NPK; el sistema tuvo un buen desempeño para múltiples ocurrencias de enfermedades en una planta. Similar a esto, se desarrolló un sistema de detección y diagnóstico basado en un sistema difuso tipo 2; a través de este enfoque se logró una precisión de hasta 91% (Trung et al, 2022). El prototipo detecta y sugiere soluciones para tratar síntomas patológicos manifestados por plantas de tomate. La detección de deficiencias no solo se ha enfocado en hojas, nuevos estudios utilizan procesamiento de imagen para detección en frutos; se desarrolló un sistema basado en visión artificial para la detección de deformidades causadas por deficiencias; la prueba de muestras en una etapa temprana ayuda a continuar con la

producción o detenerla en función del resultado de un sistema de reconocimiento basado en visión por computadora. Se utiliza un clasificador de máquina de vectores de soporte (SVM) para identificar defectos y reconocer la causa y etapa (Yoghesh, 2019).

1.3 ANTECEDENTES TECNOLÓGICOS

Existen muchas patentes relacionadas a la detección de nitrógeno en plantas. Sin embargo, no se encontraron patentes que midiera a la par fósforo y potasio. Se mencionan las principales a continuación.

El mayor número de patentes relacionadas con análisis de imagen orientado hacia la detección o estimación de nutrición, pertenecen a la universidad de Jiangsu, China. La patente CN102788796B (Jiangsu, 2012) describe un dispositivo de diagnóstico de nutriente y un método de diagnóstico de nutriente para el nitrógeno de los cultivos basado en la integración de información múltiple de imágenes de alto espectro e imágenes fluorescentes. Lleva a cabo un análisis no destructivo de la nutrición de nitrógeno de productos agrícolas mediante el análisis de imágenes fluoroscópicas de hiperiones EO-1. La patente CN202383064U (Jiangsu, 2012) divulga un modelo de utilidad de dispositivo de diagnóstico rápido del nivel de nutrición de cultivos y un método basado en una tecnología de imagen de espectro de polarización, que se relacionan con el campo técnico del diagnóstico del nivel de nutrición de cultivos. El dispositivo comprende principalmente una computadora, un controlador, un módulo de medición de polarización, un módulo de generación de luz paralela de polarización, un mecanismo rotatorio de control eléctrico de muestra, una plataforma X-Y manual, un soporte y una placa de objeto. Se realiza un análisis según el espectro de polarización reflejado y dispersado por todos los puntos de la superficie de un objeto de cultivo para investigar el impacto de los cambios de las microestructuras tisulares en las superficies y en el interior de las hojas del cultivo sobre el grado de polarización, establecer el relación correspondiente entre el nivel de nutrición y una dirección de polarización y entre el grado de polarización y la distribución del espectro de reflexión basado en las microestructuras, y diagnosticar de forma precisa y cuantitativa el nivel de nutrición del cultivo. En comparación con un método de detección tradicional, se amplía el espacio característico efectivo, se espera que mejore la precisión de predicción del nivel de

nutrición del cultivo y se realiza la detección rápida de alta precisión del nivel de nutrición del cultivo. La patente CN101915738A (Jiangsu, 2010) se refiere a un método y un dispositivo para detectar rápidamente la información nutricional principal durante el crecimiento de un árbol de té basado en una técnica de imagen hiperespectral. El método comprende los siguientes pasos: en primer lugar, medir realmente el contenido de tres elementos nutricionales principales, como N, P y K, de muestras de hojas y formar una base de datos utilizando el resultado de medición como resultado de medición de referencia; en segundo lugar, adquirir datos de imágenes hiperespectrales de las muestras de hojas del árbol del té en diferentes bandas de ondas de luz visible e infrarrojo cercano y transferir los datos a un ordenador utilizando una tarjeta de adquisición de imágenes; en tercer lugar, preprocesar los datos para completar la extracción de características correspondiente y asociar las variables características con el contenido de N, P y K medido en la base de datos establecida para construir un modelo predictivo del contenido de N, P y K de la hoja; y finalmente, realizar la correspondiente adquisición de datos y extracción de características sobre las muestras a medir y predecir el contenido de N, P y K de la hoja utilizando el modelo construido. El método y el dispositivo tienen las ventajas de alta velocidad de detección, operación simple y conveniente, información más completa y mejora en la precisión y estabilidad del resultado de detección. La patente CN102788752B (Jiangsu, 2011) da a conocer un dispositivo de detección no destructiva y un método de información interna de cultivos basado en la tecnología de espectro. El método consta de los siguientes pasos: se establece una base de datos de conocimientos y se establece la base de datos de conocimientos relacionada con todas las muestras de cultivos para un cultivo que necesita medirse; los datos de imagen y los datos de espectro de un dosel de cultivo se adquieren en una computadora; los datos de imagen adquiridos son preprocesados por el ordenador y se extrae una característica de imagen igual que una muestra de entrenamiento; la computadora lleva a cabo la extracción de características de banda de onda igual que la muestra de entrenamiento en los datos de espectro adquiridos; la computadora lleva a cabo la fusión en la función de imagen extraída, la función de banda de onda y la base de datos de conocimiento, la prueba de detección se lleva a cabo utilizando una muestra de prueba, se proporciona el contenido de nitrógeno y agua de la muestra de cultivo analizada actual y se muestra un resultado de detección por la computadora De acuerdo con la invención, el

período de crecimiento en el que se encuentra el cultivo y cuál es el contenido de nitrógeno se pueden juzgar automáticamente mediante la información del espectro, y se ofrece al usuario una mayor comodidad de uso.

A continuación se describen patentes adquiridas por distintas Universidades. Patente US20160171680A1 (Stanford, 2015) describe un sistema y método para estimar para un área tan pequeña como un campo individual a partir de una imagen satelital. El sistema genera simulaciones de rendimientos de cultivos en una región que incluye el área mediante la aplicación de combinaciones de diferentes parámetros a modelos de rendimiento de cultivos. Las cantidades observables para los rendimientos simulados se determinan a partir de las simulaciones. Las simulaciones y las propiedades observables se utilizan para entrenar un modelo estadístico para la región que tiene dos o más variables. Se obtienen imágenes captadas por un satélite que incluyen al menos una parte del área. A continuación, se determina la información de cultivos a partir de las imágenes y la información meteorológica asociada con las fechas en que se obtienen las imágenes capturadas. Luego, el modelo estadístico se aplica a la información del cultivo y la información del clima para determinar una estimación del rendimiento del cultivo. La patente WO2014100856A1 (Universidad de Sídney, 2013) se refiere a un método y dispositivo para analizar una hoja para proporcionar datos sobre el contenido de la hoja y/o las dimensiones de dicha hoja. El dispositivo comprende un escáner óptico que tiene una fuente de energía, un botón de encendido/escaneo y una apertura de escaneo. El dispositivo está adaptado para pasar sobre la hoja y capturar una imagen de al menos una parte de la hoja. Luego, un procesador adecuado procesa la imagen resultante del escáner óptico para producir datos sobre el contenido de la hoja y/o las dimensiones de la hoja. En una realización, el procesador puede aplicar una pluralidad de algoritmos para proporcionar datos sobre el tamaño de la hoja, el contenido de nutrientes y/o el estado de clorofila de la hoja.

A partir de 2018, las patentes se enfocan hacia la aplicación de IIoT y redes neuronales para procesamiento de imagen para diagnóstico y asesoramiento. La mayoría de los programas se encuentran en sistemas de cultivo y pueden estar o no acoplados a sensores. El documento WO2021198731A1 (Soroush, 2020) describe un método para desarrollar la recopilación de datos de las características físicas de las plantas mediante métodos de imágenes para productos agrícolas y hortícolas específicos que se utilizarán junto con

cualquier método de aprendizaje automático, visión artificial y aprendizaje profundo (todos los algoritmos de aprendizaje profundo) para diagnosticar plantas físicas. La matriz de píxeles de la imagen se define mediante técnicas de aprendizaje profundo para modelos preaprendidos de valores de píxeles y la biblioteca de imágenes comprende imágenes de las características físicas de los productos agrícolas y hortícolas. La patente US11663414B2 (Bongartz, 2020) describe un sistema de control agrícola, que integra sistema agrícola controlado, un dispositivo de iluminación agrícola y un método para la gestión agrícola. Además, comprende una pluralidad de líneas de procesamiento para cultivar plantas de un tipo de planta dado, en el que una primera línea de procesamiento en la pluralidad de líneas de procesamiento está configurada para mover una primera pluralidad de plantas a través del sistema agrícola a lo largo de una ruta; y aplicar una primera condición de crecimiento a la primera pluralidad de plantas para satisfacer un primer parámetro de agente activo para la primera pluralidad de plantas. El sistema de agricultura controlada está configurado para poder analizar los parámetros medidos a través de imagen y sensores e inferir una enfermedad o plaga. Además, el sistema agrícola controlado también puede configurarse para poder predecir el rendimiento en función de los parámetros medidos. US11195015B2 (Bao, 2021) describe un ecosistema de cultivo y cultivo de plantas basado en IoT. Para controlar las condiciones dentro de la cámara, integra sensores capaces de detectar la humedad, la temperatura, las propiedades de las hojas, las propiedades del suelo o la presencia de un organismo en la planta. A través de una cámara es posible capturar una imagen de hoja y determinar las propiedades del suelo en función de la imagen de la hoja. A la par, a través del análisis de la hoja es posible clasificar el organismo y recomendar un tratamiento para el organismo. El sistema puede comunicarse a través de la red celular 5G. Esta patente se deriva de la US20200020165A1 (Bao, 2018) que solo incluía incluye un cuerpo con un procesador, una cámara y un transceptor inalámbrico acoplado al procesador. La invención CN114051811A (Wang, 2021) se refiere a un sistema de preparación de fertilizantes basado en la discriminación corporal de plántulas, que comprende: el mecanismo de adquisición de cantidades se utiliza para adquirir el número de plántulas en tiempo real y el número de plántulas en tiempo real y calcular la suma de las número de plántulas en tiempo real y número de plántulas en tiempo real para obtener el número total de plántulas; El mecanismo de mezcla de fertilizantes está conectado con el mecanismo de adquisición de cantidad y se

utiliza para determinar el porcentaje de plantas de semillero en tiempo real con respecto al número total de plántulas y determinar el volumen de fertilizante delgado y el volumen de fertilizante espeso requerido por mezcla en función de la específica valor numérico del porcentaje para obtener el abono mezclado; y el dispositivo de procesamiento de contenido se usa para acumular el número de cada patrón de plántulas en la tercera imagen procesada para servir como el número de plántulas en tiempo real. De acuerdo con la invención, el volumen del fertilizante delgado y el volumen del fertilizante espeso requerido por la regulación se pueden determinar de acuerdo con el número de plántulas y el número de plántulas de cultivos plantados realmente, de modo que se aplique el fertilizante después de la regulación. al terreno de cultivo, y se mejora la pertinencia y la eficacia de la aplicación del fertilizante. La invención CN114158336A divulga un sistema de control de optimización integrado de agua y fertilizantes y un método, en el que el sistema de control comprende un módulo de monitoreo, un módulo sensor, una puerta de enlace de adquisición inalámbrica y un módulo de control de agua y fertilizantes; el módulo de monitoreo toma fotografías de las plantas en el invernadero y procesa las fotografías para obtener información sobre el crecimiento de las plantas; el módulo sensor recopila datos del suelo en el invernadero y procesa los datos del suelo para obtener la condición del suelo en el invernadero; la puerta de enlace de adquisición inalámbrica está conectada respectivamente con el módulo de monitoreo, el módulo sensor y el módulo de control de agua y fertilizantes, y envía la información de crecimiento de las plantas y la condición del suelo en el invernadero al módulo de control de agua y fertilizantes; y el módulo de control de agua y fertilizantes genera automáticamente una estrategia de riego de agua y fertilizantes basada en la información recibida para completar el control integrado de optimización de agua y fertilizantes. La invención puede monitorear dinámicamente el proceso de crecimiento de la planta y hacer una estrategia correspondiente a tiempo para mantener la planta creciendo en el entorno más adecuado. Por último, la invención CN114158336A (Zhang, 2020) divulga un sistema de control de optimización integrado de agua y fertilizantes y un método, en el que el sistema de control comprende un módulo de monitoreo, un módulo sensor, una puerta de enlace de adquisición inalámbrica y un módulo de control de agua y fertilizantes; el módulo de monitoreo toma fotografías de las plantas en el invernadero y procesa las fotografías para obtener información sobre el crecimiento de las plantas; el módulo sensor

recopila datos del suelo en el invernadero y procesa los datos del suelo para obtener la condición del suelo en el invernadero; la puerta de enlace de adquisición inalámbrica está conectada respectivamente con el módulo de monitoreo, el módulo sensor y el módulo de control de agua y fertilizantes, y envía la información de crecimiento de las plantas y la condición del suelo en el invernadero al módulo de control de agua y fertilizantes; y el módulo de control de agua y fertilizantes genera automáticamente una estrategia de riego de agua y fertilizantes basada en la información recibida para completar el control integrado de optimización de agua y fertilizantes. La invención puede monitorear dinámicamente el proceso de crecimiento de la planta y hacer una estrategia correspondiente a tiempo para mantener la planta creciendo en el entorno más adecuado.

1.4 MONITOREO TECNOLÓGICO

El análisis de deficiencias se puede realizar por tres métodos; análisis de suelo, análisis de planta, y observación visual. Entre estos, predomina la detección visual (Rahman, 2020). El análisis del suelo y el análisis de la planta se pueden llevar a cabo mediante pruebas de laboratorio. Los síntomas de deficiencias generalmente son visibles en hojas y frutos; incluyen clorosis marginal, clorosis intervenal, clorosis uniforme, bordes distorsionados, reducción en el tamaño de la hoja, necrosis, etc. Estos síntomas comúnmente utilizados para encontrar la respuesta a nutrientes (Jeyalakshmi, 2017).

El análisis visual es un análisis cualitativo que se lleva a cabo directamente observando el crecimiento de las plantas, el color de las hojas y las texturas de las hojas, frutos, tallos u otras partes del árbol. Sin embargo, este método requiere de capacitación, habilidades, y equipos especiales aunado a acciones que dañan las plantas para obtener las muestras, tiene altos costos y debe repetirse regularmente (Dezordi et al., 2016). Los resultados de las pruebas se conocerán después de días o semanas, aunque la condición de la planta empeorará e incluso causará la muerte. Para superar las pérdidas y recuperar los costos, las deficiencias de nutrientes deben detectarse lo antes posible para que los agricultores puedan tomar el tratamiento correctivo adecuado

La detección y clasificación automática de los trastornos de las plantas ha recibido una atención considerable en las últimas dos décadas. Se han utilizado muchos tipos de

tecnologías para recopilar la información requerida para la automatización, incluida la espectroscopia de impedancia eléctrica (Jinyang et al., 2016), espectroscopia de reflectancia (Elvanidi et al., 2018), microespectroscopia infrarroja por transformada de Fourier (Butler et al., 2017) y espectroscopia de fluorescencia de clorofila (Schmidt et al. al., 2013). Las imágenes digitales, que siempre han estado entre las principales fuentes de datos, se han vuelto cada vez más dominantes a medida que se generaliza el uso de técnicas basadas en el aprendizaje profundo (Singh et al., 2018, Barbedo, 2018, Barbedo, 2018, Hossain 2019, Gayathri 2020). En temas de sanidad vegetal se han aplicado diferentes tipos de imágenes, entre ellas la fluorescencia clorofílica (Gorbe y Calatayud, 2012), térmica (Costa et al., 2013), multiespectral (Borhan et al., 2017) e hiperespectral (Yu et al., 2014). Aunque esos tipos de imágenes a menudo pueden transmitir más información que las imágenes convencionales rojo-verde-azul (RGB) (Bock et al., 2010), estas últimas se han empleado con más frecuencia debido al bajo costo, la portabilidad y la disponibilidad de las respectivas cámaras. Teniendo en cuenta que las técnicas de aprendizaje profundo en general requieren grandes cantidades de datos para el entrenamiento, esas ventajas se vuelven más prominentes y, a menudo, superan las ganancias eventuales del uso de bandas espectrales distintas del rango visible. Jose et al, 2021 logró detectar deficiencias nutricionales mediante el uso de redes neuronales con alta precisión. De acuerdo con el nutriente, el método presentó una eficiencia del 87.3% al detectar y clasificar deficiencias. Similar, Shukla et al, 2021 logró una eficiencia similar a nivel campo al combinar IOT e imágenes obtenidas a través de un UAV. Enfocado a tomate, Ceballos et al, 2020, logró mediante un modelo de redes convolucionales 86.57% de eficacia en la detección de deficiencias. Sin embargo, estos son métodos de detección, no cuantitativos.

1.5 COMERCIALMENTE DISPONIBLE

Los sensores recomendados para la medición indirecta del estado del N de la planta son costosos (por ejemplo, medidor de clorofila, desarrollo de análisis de plantas de suelo (SPAD), sensor de índice de vegetación de desviación normalizada (NDVI)). Además, algunas mediciones de sensores (por ejemplo, NDVI) pueden verse potencialmente confundidas por la señal del fondo cuando el dosel no está completamente cerrado, lo que

lleva a errores. Otros sensores para medir el estado de N de cultivos, incluidos CropScan, Greenseeker, Yara N-sensor y Fieldspec-Spectroradiometer, son más adecuados para la agricultura convencional y no para agricultura protegida. Adicional, en años recientes en Asia, se han desarrollado distintas cartas de color para determinar déficit nutricional en arroz (Bhupenchandra et al, 2021).

1.5 DESCRIPCIÓN DEL PROBLEMA

La información sobre el estado del NPK en las plantas se obtiene mediante inspección visual o análisis químicos, que son costosos, lentos y laboriosos. Además, estos métodos son destructivos, lo que impide su uso para el control continuo del contenido de NPK y, por lo tanto, de los recursos de NPK en el campo durante el crecimiento de la planta (Siedliska. Et al, 2021).

Para el análisis en laboratorio, existen procedimientos cromatográficos y colorimétricos están disponibles para el análisis de nutrientes tanto en plantas como en suelos. Por ejemplo, el nitrógeno total se puede determinar mediante la extracción de nitratos de muestras de plantas utilizando una solución de KCl 1 M (Sáez-Plaza et al., 2013). Sin embargo, todos estos métodos son destructivos, así como también requieren mucho tiempo y trabajo (Sánchez et al, 2020). También requieren el envío de muestras a laboratorios analíticos y el uso de productos químicos peligrosos, lo que hace que estos análisis sean costosos y tóxicos. Se necesitan métodos alternativos y eficientes para monitorear el contenido de NPK en las plantas.

Hoy en día, con la competencia de los mercados emergentes, la sinergia entre la agricultura y la tecnología puede proporcionar el impulso que falta hacia la sostenibilidad, ya que las huellas humanas en los ecosistemas apuntan a posibles desequilibrios en la capacidad de la Tierra para fijar el carbono (Peñuelas et al., 2013). En este contexto, el desarrollo de un sensor todo en uno para la evaluación de nitrógeno, fósforo y potasio (NPK) para la integración en un sistema en línea sería una herramienta ideal para permitir una gestión de cultivos más sostenible. Sin embargo, el conocimiento y la tecnología actuales no han sido capaces de desarrollar un sensor portátil e integrable capaz de medir estos tres parámetros clave tanto en el agua como en el suelo, de una manera simple, directa y rentable, manteniendo la precisión de las metodologías estándar (Monteiro-Silva et al., 2019).

Hoy en día no existe un modelo que describa numéricamente la relación entre el color de la hoja y el contenido de nitrógeno, fósforo, y potasio; los únicos registros disponibles son cartas de imágenes para identificar condiciones o deficiencias. Determinar la relación entre contenido de NPK y valores RGB de una hoja permitirá plantear las bases para desarrollar

una herramienta económica, rápida y confiable para la estimación del contenido de NPK, no destructiva, sin alterar a la planta, y de bajo costo. Reduciendo así el intervalo entre toma de muestra y resultados. Con esto se busca optimizar los procesos de atención al cultivo y minimizar el tiempo de procesamiento de dos semanas a minutos

1.6 JUSTIFICACIÓN

Además de su valor nutricional, el tomate se considera eje de los sabores de la cocina mexicana, constituye platillos de la gastronomía internacional y es de fundamental importancia para México. También es uno de los cultivos más rentables para el país, ha registrado un crecimiento promedio de 9.5% en los últimos 10 años. Al cierre de 2020 se obtuvo un volumen de 3.27 millones de toneladas, en una superficie de más de 45,000 hectáreas y un consumo per cápita de 13.4 kilogramos (SADER, 2022). Sin embargo, es un producto sumamente volátil en precios. Un alza significativa en precios afecta severamente la economía familiar y supone una amenaza para la seguridad alimentaria en México.

Hoy en día representa 3.4% del PIB agrícola nacional y 22.55% de la producción total de hortalizas en el país (SAGARPA 2016). En el contexto productivo, de las 51,861 hectáreas sembradas en 2016, el 95.7% de la superficie se encuentra mecanizada. 73.26% cuenta con una tecnología aplicada a la sanidad vegetal, mientras que 76,62% del territorio cuenta con asistencia técnica. México es el principal proveedor a nivel mundial de tomate. Tiene una participación en el mercado internacional de 25.11% del valor de las exportaciones mundiales. A pesar de que hoy en día se satisface el 100% de la demanda nacional más un excedente de importación, para en 2030 se estima un aumento en la demanda mundial de 8.92 a 11.8 MMT (SAGARPA, 2016). Esto representa un aumento acumulado de 32.1%. Tan solo la demanda nacional debe incrementarse de 3,35 MMt a 7,56 MMt; crecimiento acumulado de 125.8%. Por lo tanto es preponderante incursionar la maximización de recursión para eficientar la producción. A 2022, el tomate se mantuvo como la hortaliza de mayor producción, ya que se cultiva para atender la demanda nacional y la exportación (FORBES, 2022).

El nitrógeno constituye compuestos orgánicos vitales para las plantas y contribuye a la fructificación, productividad y rentabilidad económica (Marschner, 2012). Por otro lado, a pesar de ser absorbido en menor cantidad y tener menores concentraciones en el tejido vegetal, el fósforo es sumamente importante en la formación y crecimiento de las raíces, además de incrementar la calidad comercial del fruto (Mueller et al., 2013; Nowaki et al., 2017). El potasio es el nutriente más requerido por el tomate (Prado et al., 2011) y contribuye a los procesos de fotosíntesis, activación enzimática y síntesis de proteínas (Rebouças Neto

et al., 2016). Se debe recomendar un equilibrio entre la disponibilidad de nutrientes, la dosis de fertilizante y el tiempo de aplicación para reducir el riesgo de contaminación ambiental y aumentar la eficiencia del uso de fertilizantes por parte de la planta cultivada. De este modo, la adopción y mantenimiento de dosis balanceadas de NPK, además de incrementar la productividad y concentración de sólidos solubles, puede incrementar el rendimiento de pulpa, firmeza de frutos de tomates industriales, entre otros (Almeida et al, 2019).

Mediante la determinación entre la correlación entre valores RGB de una imagen y contenido de NPK de la hoja se da pie al desarrollo de un dispositivo capaz de estimar en segundo el contenido de nutrientes de una hoja. Dicho modelo, debe ser alimentado por medio de datos de entrada; en este trabajo se proponen los valores RGB de la fotografía in situ de la hoja.

El procesamiento de imágenes es un método no destructivo para diversas aplicaciones agrícolas que se puede implementar de manera efectiva con mayor precisión. Los síntomas de deficiencia visual, la prueba del suelo, la prueba del tejido vegetal y las respuestas de los cultivos a los fertilizantes químicos o abonos orgánicos son los cuatro métodos para identificar los trastornos de los nutrientes en las plantas de cultivo; esto permite evaluar el estado de N de la planta por medio de imágenes. El pigmento de clorofila en las hojas absorbe el rojo, el azul y una pequeña proporción de las longitudes de onda verdes que inciden en las plantas. Debido a que la concentración de N en los tejidos afecta la síntesis de clorofila en las plantas, una deficiencia de N en el tejido puede disminuir la concentración de clorofila y aumentar la reflectancia de las longitudes de onda rojas, azules y verdes de las plantas. Gracias a este fenómeno es posible realizar una evaluación indirecta del estrés por N que experimentan las plantas midiendo la reflectancia de las longitudes de onda roja, azul y verde de una hoja. Las imágenes se componen de píxeles que almacenan información sobre la intensidad de la luz reflejada de un objeto. Procesos similares ocurren con cada uno de los nutrientes restantes. Por lo tanto, al determinar un modelo de correlación para la detección de niveles NPK en hojas de tomate, se esperan resultados eficaces, confiables, e in situ.

1.7 HIPÓTESIS Y OBJETIVOS

Hipótesis

Existe una correlación cuantificable entre contenido de nitrógeno, fósforo, y potasio de una hoja de tomate y valores RGB promedio de una imagen de hoja de tomate.

Objetivo general

Determinar la correlación entre valores RGB de una imagen de hoja tomate y concentraciones de NPK en savia estimados por métodos espectrofotométricos.

Objetivos particulares

- a. Obtener 100 hojas de tomate en etapa de floración y cuajado de fruto
- b. Desarrollar una base de datos conformada por 100 imágenes de toma original obtenidas en un ambiente controlado, valores de la imagen descompuesta en RGB, y correspondiente contenido de NPK en savia estimados por métodos espectrofotométricos.
- c. Desarrollar un modelo de correlación entre el valor promedio por banda RGB de imágenes y contenido de NPK en savia de hojas de tomate.
- d. Comparar los resultados del modelo contra los valores estimados por medio de métodos espectrofotométricos.

Capítulo 2

2 FUNDAMENTACIÓN TEÓRICA

2.1 NPK en plantas de Tomate

2.1.1 Nitrógeno, N

Es el nutriente limitante para el crecimiento del tomate y, debido a la cantidad removida por el cultivo del suelo, se requiere suplementar en grandes cantidades (Souri et al, 2018). Las plantas pueden usar N en diferentes formas. Sus principales fuentes son el amonio (NH_4^+) y el nitrato (NO_3^-), aunque el último es fácilmente propenso a la lixiviación (Koh et al, 2020). La deficiencia de nitrógeno en suelo puede resultar en un crecimiento delgado, atrofiado, y amarilleo de las hojas en la base de la planta de tomate. Las hojas más jóvenes permanecen pequeñas y de color verde pálido; en casos severos, las hojas más viejas se vuelven amarillas y mueren prematuramente. Puede disminuir la producción de cantidad de frutas, tamaño de la fruta, calidad de almacenamiento, color y sabor del tomate. El nitrógeno es un componente de las proteínas y los aminoácidos, sin los cuales no serían posibles las funciones vitales en el crecimiento y la reproducción de las plantas. Si bien la deficiencia de N en el tomate puede resultar de la eliminación de N por la planta del suelo después de la cosecha de la biomasa vegetal aérea, ausencia de enmiendas del suelo, como abonos y fertilizantes, y pérdida de N por erosión, escorrentía y lixiviación, la adición de materiales vegetales con una alta relación C: N también puede acelerar la deficiencia debido a la inmovilización de N en el suelo (Sanjpu, 2003). Debe haber una cantidad adecuada de N en el suelo, no solo para un crecimiento y producción óptimos de tomate, sino también para producir suficiente follaje para proteger la fruta de la exposición al sol. Por otro lado, un nivel alto de N en el suelo puede promover un crecimiento vegetativo excesivo que puede retrasar el cuaje y la madurez de los frutos de tomate, reduciendo así la producción de tomate. También puede convertir las hojas más jóvenes en tamaños más pequeños y de color más oscuro, a menudo arrugadas o rizadas. Las puntas de las raíces pueden volverse marrones y morir y en casos severos, la mayor parte del sistema de raíces puede morir. Como el N aplicado al suelo a partir de abonos y fertilizantes se convierte fácilmente en NO_3^- para la absorción de la planta, una alta tasa de fertilización con N puede dar como resultado una gran

cantidad de NO₃ residual que se acumula en el suelo después de la cosecha de la cosecha (Salim et al, 2019). Debido a que el NO₃ es soluble en agua, una alta concentración de NO₃ residual puede aumentar el potencial de lixiviación de N del suelo y contaminar las aguas subterráneas. El problema puede ser grave en suelos arenosos que tienen una mayor infiltración de agua y una menor capacidad de retención de NO₃ en comparación con los suelos arcillosos. El tipo de fertilizante N aplicado también puede influir en la producción de tomate porque el NH₄-N puede ser tóxico para el crecimiento del tomate en comparación con el NO₃ -N.

El estado del nitrógeno en las hojas se puede evaluar indirectamente en el estado de la clorofila, ya que la mayor parte del nitrógeno de la hoja se asimila en la clorofila (Buchanpendra et al, 2020). El estado de la clorofila está correlacionado con el estado del nitrógeno de la hoja, también fue informado por Evans, 1983, se puede acceder al contenido de nitrógeno del cultivo a través del examen físico del color de la hoja.

2.1.2 Fósforo, P

El fósforo promueve el crecimiento de las raíces del tomate y por lo tanto ayuda en el establecimiento temprano de la planta inmediatamente después del trasplante o la siembra. (Siedliska, et al, 2021). El fósforo es un componente de los ácidos nucleicos. Ayuda en la producción de una gran cantidad de flores en el crecimiento temprano de tomates y el cuajado temprano de frutos y semillas. Como resultado, aumenta el número y la producción de frutos de tomate, con un mayor contenido total de sólidos solubles y acidez. También mejora el color de la piel y la pulpa, el sabor, la resistencia y el contenido de vitamina C. La deficiencia de P da como resultado un retraso en el crecimiento de los tomates con tallos delgados y color verde oscuro en la superficie superior de las hojas que contienen venas violáceas. Las hojas más viejas muestran senescencia prematura con tintes amarillos y violáceos (Sanjou, 2003). Aunado a esto, la deficiencia perturba la producción de clorofila, provocando la clorosis de las hojas. La deficiencia prolongada de P puede resultar en la acumulación de antocianinas, lo que en consecuencia conduce a una decoloración púrpura en la superficie de la hoja (Magalhães et al, 2022). A diferencia del N, el suelo absorbe fuertemente el P. Como resultado, la mayoría de los suelos contienen abundantes cantidades de P, ya que apenas se

filtra fuera del perfil del suelo. Debido a que los tomates absorben una cantidad relativamente menor de P que las cantidades de N y K, la concentración de P en el tomate también es menor.

Como resultado, se agrega al suelo una menor proporción de P procedente de abonos y fertilizantes. Debido a su naturaleza relativamente inmóvil en comparación con otros nutrientes, la aplicación de bandas de P a lo largo de las hileras es deseable para su máxima disponibilidad para las plantas. Los fertilizantes fosfatados solubles en agua, como el nitrofosfato o el superfosfato triple, son deseables para el tomate por su rápida disponibilidad. En comparación con la mayoría de los demás nutrientes, el nivel excesivo de P en el suelo es menos dañino para el tomate. Sin embargo, puede reducir la disponibilidad de algunos micronutrientes, como Fe, Zn, Mn y Cu, al disminuir su solubilidad en el suelo y su translocación dentro de la planta

2.1.3 Potasio, K

Similar al nitrógeno, el tomate absorbe K en grandes cantidades debido a que la concentración de K en el tomate es más alta que la concentración de otros nutrientes. El potasio promueve al crecimiento vigoroso del tomate y estimula la floración temprana y el cuajado de los frutos, aumentando así el número y la producción de tomates por planta. La nutrición de potasio puede afectar la calidad del fruto del tomate. Winsor observó que el porcentaje de tomates maduros de manera desigual y frutos de forma irregular y huecos disminuyó con el aumento de la tasa de K. Por el contrario, la acidez titulable del jugo de tomate aumentó con el aumento de la tasa de K (Sanjou, 2003).

El potasio es necesario en el movimiento de las estomas para la regulación del agua en la planta. Ayuda a activar las enzimas y es necesario para el metabolismo y la translocación de los carbohidratos, el metabolismo del nitrógeno y la síntesis de proteínas, y la regulación de la concentración de savia celular. También aumenta las concentraciones de ácidos cítrico y málico, sólidos totales, azúcares y caroteno en los frutos de tomate, por lo tanto, mejorando su calidad de almacenamiento. La deficiencia de potasio da como resultado un chamuscado marginal marrón con clorosis interveinal y amarillamiento en hojas de tomate y entrenudos acortados (Penn, 2022). Las hojas se tornan más pequeñas y se nota un cambio de color de verde oscuro a amarillo claro y tamaños de plantas más pequeñas (Thornburg et al, 2020). Los síntomas aparecen primero en las hojas más viejas y comienzan a extenderse

por toda la planta a medida que madura. Las frutas maduran de manera desigual. La deficiencia también puede resultar en un menor contenido de licopeno, un componente que puede prevenir el cáncer de próstata en humanos. La deficiencia puede aparecer rápidamente en tomates cultivados en turba y compost de turba y arena con bajo contenido de K debido a la inundación o la aplicación de fuertes riego (Qi et al, 2019). El nivel excesivo de K en el suelo apenas puede tener un efecto directo sobre los tomates, pero puede reducir la disponibilidad de Mg en el suelo. Igual que en el N, el K es soluble en agua y puede filtrarse del perfil del suelo al agua subterránea. Aunque no se conoce el peligro para la salud de una alta concentración de K en el agua potable, es importante reducir la lixiviación de K en el agua subterránea para reducir el costo de la fertilización y mejorar la calidad del agua. Como resultado, es necesario realizar análisis periódicos del suelo o de la planta antes de aplicar fertilizante de K al tomate para que la cantidad adecuada de K esté disponible para una producción óptima y se pueda reducir la lixiviación.

<i>Nutriente</i>	<i>Contenido</i> ($mg \cdot Kg^{-1}$)	<i>Función</i>
<i>N</i>	48000	Constituyente de proteínas y aminoácidos
<i>P</i>	5000	Constituyente de ácido nucleicos
<i>K</i>	55000	Activas enzimas (e.g. piruvato kinasas); regula el PH de el fruto

Tabla 2.1 Contenido de nutrientes en hojas de jitomate y sus funciones (Sanju et al, 2003)

2.2 Regresión e índices de correlación

Las técnicas más utilizadas para investigar la relación entre dos variables cuantitativas son la correlación y la regresión. La correlación cuantifica la fuerza de la relación lineal entre un par de variables, mientras que la regresión expresa la relación en forma de ecuación. Por ejemplo, en pacientes que acuden a una unidad de urgencias y accidentes (A&E), podríamos usar la correlación y la regresión para determinar si existe una relación entre la edad y el nivel de urea, y si el nivel de urea se puede predecir para una edad determinada (Bewick, 2003)

El coeficiente de correlación es una medida estándar de asociación o relación entre dos características Y y X. La mayoría de los científicos igualan que Y y X están correlacionados para significar que Y y X están asociados, relacionados o dependientes entre sí. Sin embargo, la correlación es solo una medida de la fuerza de una relación lineal. Para referencia posterior, sea ρ la correlación entre Y y X en la población y sea r la correlación muestral. Se define r a continuación. La correlación de la población se define de forma análoga a partir de los datos de la población (UNM, 2015).

Suponga que cada uno de los n individuos muestreados se mide en dos características cuantitativas llamadas Y y X. Los datos son pares de observaciones (X1, Y1), (X2, Y2), . . . (Xn, Yn), donde (Xi, Yi) es el par (X, Y) del i-ésimo individuo de la muestra. La correlación muestral entre Y y X, también llamada coeficiente de correlación del momento del producto de Pearson, es:

$$r = \frac{S_{XY}}{S_X S_Y} = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i (X_i - \bar{X})^2 \sum_i (Y_i - \bar{Y})^2}}$$

Donde SXY es la covarianza muestral entre Y y X, y SY y SX son las desviaciones estándar para las muestras Y y X. Aquí hay ocho propiedades importantes de r (UNM, 2015)

1. $-1 \leq r \leq 1$.
2. Si Yi tiende a aumentar linealmente con Xi, entonces $r > 0$.
3. Si Yi tiende a disminuir linealmente con Xi, entonces $r < 0$.
4. Si existe una relación lineal perfecta entre Yi y Xi con pendiente positiva, entonces $r = +1$.
5. Si existe una relación lineal perfecta entre Yi y Xi con pendiente negativa, entonces $r = -1$.
6. Cuanto más cerca estén los puntos (Xi, Yi) llegan a formar una línea recta, cuanto más se acerca r a ± 1 .
7. La magnitud de r no cambia si la muestra X o Y se transforma linealmente (es decir, pies a pulgadas, libras a kilogramos, Celsius a Fahrenheit).
8. La correlación no depende de qué variable se llama Y y cuál se llama X

Si r está cerca de ± 1 , entonces existe una fuerte relación lineal entre Y y X en la muestra. Esto sugiere que podríamos predecir con precisión Y a partir de X con una ecuación

lineal (es decir, regresión lineal). Si r está cerca de 0, existe una relación débil entre Y y X , lo que sugiere que una ecuación lineal proporciona poca ayuda para predecir Y a partir de X . En la figura 3 se muestran distintos tamaños de r para ilustrar correlación. Cabe mencionar que $r = 0$ no implica que Y y X no estén relacionados en la muestra. Solo implica que no están relacionados linealmente.

Se ha encontrado que la respuesta a distintas concentraciones de NPK sobre fructificación, altura de la planta, y materia seca es no lineal (Gallardo, 2020) (Urbieta, 2021). Estos factores a su vez inciden en el color de la hoja. De este modo, al modificar las concentraciones de nutrientes es posible encontrarse con casos de hórmesis donde la exposición a una dosis baja de un agente químico, nutriente en este caso, o factor ambiental que es dañino en dosis más altas induce un efecto beneficioso adaptativo en la célula u organismo. La hórmesis representa un obstáculo en la modelación de un fenómeno debido al comportamiento asimétrico de la curva de respuesta; obligan al modelador a usar modelos polinomiales capaces de representar el fenómeno.

Los modelos de regresión polinomial son útiles en situaciones en las que la relación entre una variable de respuesta y las variables predictoras es curvilínea. La regresión polinomial ajusta la relación no lineal en un modelo de regresión lineal de mínimos cuadrados al descomponer las variables predictoras en un polinomio de k -ésimo orden. El orden del polinomio determina el número de inflexiones en la línea ajustada curvilínea. Un polinomio de segundo orden forma una expresión cuadrática (curva parabólica) con un único máximo o mínimo, un polinomio de tercer orden forma una expresión cúbica con un máximo y un mínimo relativos (Goh, 2017).

La regresión polinomial ilustra una estrategia general para extender la regresión lineal a fin de ajustar las líneas curvas a los datos de respuesta. Por ejemplo, se puede ajustar una ecuación cúbica a los datos usando el modelo:

$$Y_i = \theta_0 + \theta_1 X_i + \theta_2 X_i^2 + \theta_3 X_i^3 + \epsilon_i.$$

Aquí, las potencias de X son entradas en diferentes columnas de la matriz X, y la estructura lineal de asegura que esto sea formalmente equivalente al modelo clásico. De manera similar, se pueden manejar interacciones entre dos tipos diferentes de variables explicativas, digamos X_{i1} y X_{i2} , al incluir términos de la forma $X_{i1}X_{i2}$, donde X_{i1} y X_{i2} son elegidos por el investigador para capturar mejor el tipo de interacción esperada.

La regresión logística se utiliza cuando las variables de respuesta son binarias pero las explicativas no lo son. Este sería el caso si se midiera si un alambre de acero se rompe bajo una carga de 50 kg, donde las variables explicativas podrían ser el radio de sección transversal y el porcentaje de cromo. Entonces se puede usar el modelo:

$$P[Y_i = 1] = \frac{\exp(X_i^T \theta)}{1 + \exp(X_i^T \theta)},$$

donde $Y_i = 1$ si el i -ésimo cable se rompe, y X_i es el vector de variables explicativas para el i -ésimo cable. Para justificar los métodos de regresión lineal, se utiliza la transformación:

$$p_i = \ln \frac{P[Y_i = 1]}{1 - P[Y_i = 1]}$$

para obtener el modelo lineal $p_i = X_i^T \theta$. Al ajustar este modelo, es conveniente si hay múltiples medidas en cada combinación de valores para las variables explicativas; entonces se pueden usar las proporciones observadas transformadas de unos como las observaciones en (1). De lo contrario, se pueden utilizar promedios locales transformados de los valores de Y_i . Cualquiera de los enfoques da un modelo lineal, donde la varianza del error depende de X_i . Una forma de estimar θ en el caso de regresión logística es mediante mínimos cuadrados ponderados.

El uso de variables ficticias amplía enormemente el alcance de la regresión lineal. Aquí se puede modelar el efecto de variables explicativas categóricas en combinación con variables explicativas continuas. Por ejemplo, suponga que uno mide la temperatura de los elementos calefactores de dos proveedores diferentes en función de la potencia eléctrica suministrada.

La variable explicativa continua es la potencia y la variable categórica es el proveedor. Si se define la variable X_{1i} como 1 si el i -ésimo elemento es del primer proveedor y de lo contrario se establece en 0, entonces se puede usar la forma de regresión lineal del modelo en (1) para ajustar automáticamente el efecto del proveedor. Se necesita juicio para decidir ajustar los términos de interacción con variables ficticias y para manejar situaciones con más de dos categorías por variable

2.3 Imágenes RGB

Los colores que los humanos y la mayoría de los animales perciben en un objeto están determinados por la naturaleza de la luz reflejada por el objeto. Por ejemplo, los objetos verdes reflejan la luz con longitudes de onda principalmente en el rango de 500 a 570 nm mientras absorben la mayor parte de la energía en otras longitudes de onda (Mac Namee, 2014).

Se utilizan 3 cualidades básicas para describir la calidad de una fuente de luz cromática:

- Radiancia; la cantidad total de energía que fluye desde la fuente de luz (medida en vatios)
- Luminancia; la cantidad de energía que un observador percibe de la fuente de luz (medido en lúmenes)
- Brillo; noción que encarna la intensidad de la luz en partes del espectro (prácticamente inconmensurable)

El modelo de color es un método para especificar colores de forma estándar y el modelo de color está representado por un sistema de coordenadas tridimensional en el que

cada color está representado por un solo punto dentro de sistemas tridimensionales. En el caso del sistema visual humano, las células de los bastones (en el ojo) son sensibles a las ondas de luz de baja intensidad reconociendo imágenes binarias, mientras que las células de los conos son sensibles a las ondas de luz roja, verde y azul, reconociendo así imágenes coloreadas (Kour, 2015). Por lo tanto, los colores rojo, verde y azul se denominan colores primarios, mientras que el cian, el amarillo y el magenta se conocen como colores secundarios porque estos colores secundarios se obtienen mezclando dos colores primarios (la combinación de verde y azul da como resultado cian). Los modelos de color de imagen se centran únicamente en la representación de imágenes y se concentran principalmente en la calidad de los datos de imagen. Por ejemplo, RGB, CMY, HSI, etc.

El sistema de color RGB es el sistema de color más común para la imagen digital. Describe un color usando tres valores diferentes (rojo, verde, azul). La representación del negro más oscuro es (0, 0, 0) y el blanco más brillante es (255, 255, 255) (Liu, 2021). Cuando se introducen en un monitor, estas imágenes se combinan para crear una imagen en color compuesta. El número de bits utilizados para representar cada píxel en el espacio RGB se denomina profundidad de píxel (Azad, 2017).

Si se considera una imagen RGB en la que cada una de las imágenes roja, verde y azul es una imagen de 8 bits, cada píxel de color RGB [es decir, un triplete de valores (R, G, B) tiene una profundidad de 24 bits (3 planos de imagen por el número de bits por plano). El término imagen a todo color se utiliza a menudo para denotar una imagen en color RGB de 24 bits. El número total de colores en una imagen RGB de 24 bits es $(2 \text{ elevado a } 8) \text{ cubo completo} = 16.777.216$.

Es importante notar que adquirir una imagen en color es básicamente el proceso que se muestra en la figura 1. También es posible adquirir una imagen en color utilizando tres filtros, sensibles al rojo, verde y azul, respectivamente. Cuando vemos una escena en color con una cámara monocromática equipada con uno de estos filtros, el resultado es una imagen monocromática cuya intensidad es proporcional a la respuesta de ese filtro (Azad, 2017).

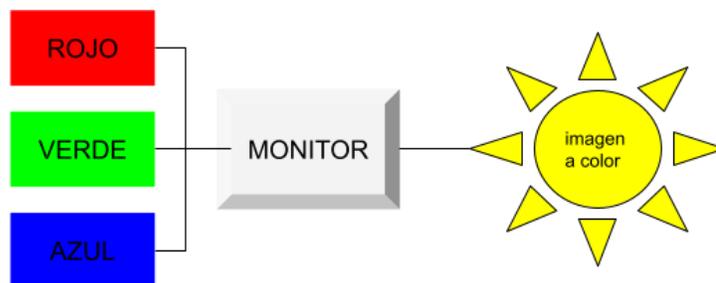


Figura 2.1 Proceso de obtención de una imagen RGB

RGB es útil para implementaciones de hardware y se relaciona con la forma en que funciona el sistema visual humano (Zhang, 2020). El análisis de imagen RGB es el procesamiento más común en el campo de la visión por computadora. Se ha utilizado ampliamente en aplicaciones industriales y para la vida diaria (Song, 2023). Refleja directamente las propiedades físicas de la pantalla en color real a la par de estar íntimamente relacionada con la reflectancia de las moléculas. Los componentes de color rojo, verde y azul están altamente correlacionados.

Sin embargo, las cámaras RGB son susceptibles a las condiciones de campo y, por lo tanto, pueden afectar los resultados de detección y localización. Además, las cámaras RGB solo pueden adquirir información bidimensional (2D) de la escena sin la ayuda de técnicas estereoscópicas (Fu, 2020).

Capítulo 3

3 METODOLOGÍA

3.1 Materiales

Las hojas de tomate se obtuvieron de plantas cultivadas en la UAQ Campus Amazcala. Por otro lado, los kits para detección de nitrógeno, fósforo y potasio se adquirieron de HANNA.

La metodología se dividió según los objetivos de la investigación (Figura 3.1)

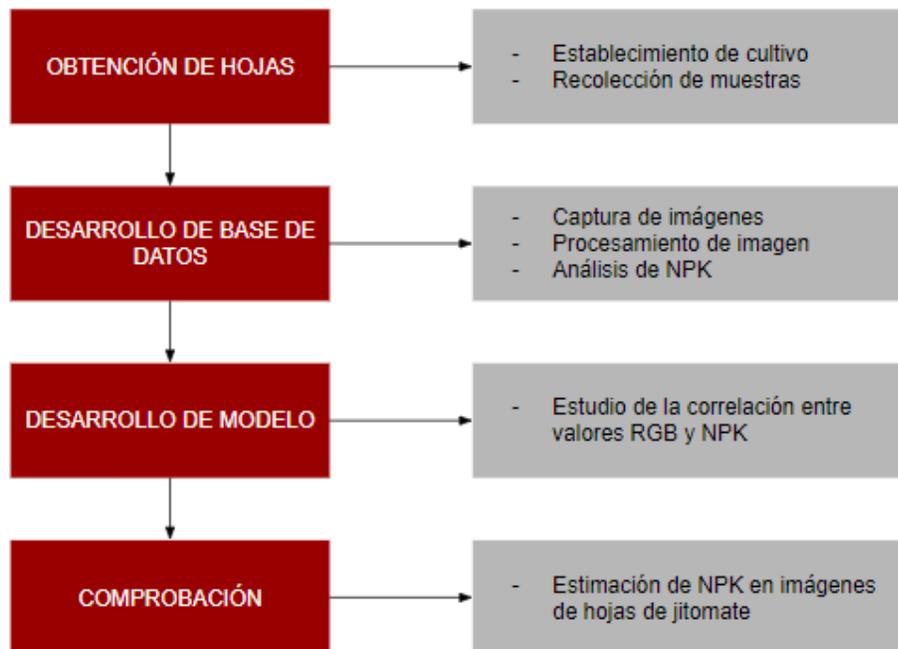


Figura 3.1 Diagrama de metodología

3.2 Métodos

3.2.1 Obtención de 100 hojas de tomate en etapa de floración y cuajado de fruto

3.2.1.1 Locación y características del invernadero

Las muestras se obtuvieron de un invernadero de alta tecnología, perteneciente a la Facultad de Ingeniería de la Universidad Autónoma de Querétaro Campus Amazcala, ubicado en Amazcala, El Marqués, Querétaro Latitud, 20°, 42'18'' N; longitud, 100° 15'33'' W; altura 1.9212 metros sobre el nivel del mar. En el interior de la estructura se han registraron temperaturas que entre los 26 y 30 °C.



Figura 3.2 imagen satelital del sitio experimental (invernadero)

El invernadero tiene una superficie de 550 m^2 ; 55 metros de largo, 10 de ancho. La estructura de acero está recubierta por policarbonato. Debido a la radiación promedio del área, 5278 w/m^2 , se encaló previo al ciclo para evitar golpe de calor. El invernadero tiene piso de concreto y se encuentra completamente sellado.

3.2.1.2 Manejo agrícola

Para el estudio, se utilizó una variedad comercial; SVTJ7518 con multifort como portainjerto. SVTJ7518 (BAYER) es un tomate saladette indeterminado de planta vigorosa y alta productividad proclive a frutos extragrandes. Es una variedad desarrollada para cuñtivo en invernadero. Presenta resistencia a: ToMV:0-2/Fol:1-3/Sbl/SI/Ss/Va:1/Vd:1. Por otro lado, multifort es un portainjerto especialmente indicado para cultivos en suelo y sustrato artificial por su alta tolerancia contra las más frecuentes enfermedades del suelo. Híbrido de tipo indeterminado con un potente sistema radicular.



Figura 3.3 Plantulas injertadas, previo a trasplante

Las plántulas injertadas se trasplantaron a bolis de fibra de coco respetando la densidad recomendada por el proveedor, 22,000 plantas por Ha. El riego se realizó por medio de un sistema de goteo automatizado. Durante todo el ciclo se utilizó una nutrición para cultivo comercial:

<i>Sal</i>	<i>mg/L</i>
<i>Nitrato de calcio</i>	17.5
<i>Sulfato de potasio</i>	12
<i>Nitrato de magnesio</i>	13
<i>Cloruro de Calcio</i>	1
<i>Cloruro de potasio</i>	1
<i>Fosfato monopotásico</i>	0.7
<i>Fe</i>	1.45
<i>Mn</i>	0.75
<i>Cu</i>	0.25
<i>zn</i>	0.1
<i>Bo</i>	0.2

Tabla 3.1 Formulación de la solución nutritiva utilizada en el cultivo

La solución está diseñada para una conductividad eléctrica de 2.5 y pH de 5.5.

Para la conducción del cultivo se utilizó un sistema de tutoreo de ganchos con rafia. Se colocó a los 15 días del trasplante, donde se condujo la planta a tallo

3.2.1.3 Buenas prácticas agrícolas

A lo largo del cultivo, el personal de observó el Manual de Buenas Prácticas Agrícolas (SENASICA, 2007) así como el Manual de Buenas Prácticas Agrícolas para el Productor Hortofrutícola (FAO, 2012) bajo la supervisión del Maestro Adán Mercado. Las labores de planeación, riego, culturales, y de mantenimiento se llevaron a cabo por el personal del campus.



Figura 3.4 Frutos obtenidos en el invernadero experimental bajo observancia de buenas prácticas

3.2.1.4 Sanidad

Durante todo el ciclo se observó el principio de exclusión dentro del invernadero. Por medio de esto, se pretende evitar cualquier factor externo que pueda incidir en el estado de la hoja; entre estos, la aplicación de agroquímicos orientados a controlar plagas o malezas. Para esto se consideró:

- Sellado de hoyos en el invernadero
- Tapete de azufre a la entrada
- Mantener la antesala libre
- Desinfección de herramientas de poda y sistema de tutoreo
- Mantener ambas puertas cerradas todo el tiempo
- Lavado semanal del tanque
- Lavado de manos previo a la entrada
- Acceso solo con uso de overol sanitizado previamente
- Acceso con el cabello recogido
- Retiro manual de malezas
- Disposición inmediata de residuos

- Evitar visitas a otros invernaderos para minimizar el riesgo de contaminación cruzada
A la par, el invernadero cuenta con un ventilador a la entrada y área de lavado de manos para el personal.

3.2.1.5 Muestreo

Se muestrearon 100 folíolos; un folíolo por planta. Debido a la movilidad de los nutrientes, solo se consideraron hojas maduras. Se muestreó el tercer folíolo de la octava hoja. A la par, se excluyeron las primeras dos plantas del borde del invernadero; frente y lateral.



Figura 3.5 Hoja de jitomate muestreada

Para preservar la integridad de la muestra, posterior a la captura, las muestras se almacenaron congelación.

3.2.2 Desarrollo de una base de datos conformada por 100 imágenes de toma original obtenidas en un ambiente controlado, valores de la imagen descompuesta en RGB, y correspondiente contenido de NPK en savia estimados por métodos espectrofotométricos.

3.2.2.1 Captura de imágenes

Este fue un paso crítico ya que la calidad de la imagen puede afectar la precisión de los pasos de procesamiento posteriores. Las condiciones de iluminación pueden afectar el color de la hoja en la imagen. Si la imagen se toma con luz brillante, los valores RGB son

más altos que el color de la hoja original y la imagen se vuelve más brillante. Por el contrario, cuando la imagen se toma con poca luz, los valores RGB son menores que los colores originales, por lo que se vuelve más oscuro que el original. Por lo tanto, para controlar estos factores, a la par de homogenizar las condiciones de captura, se empleó un scanner Brother MFC-7860DW a una resolución de 600 x 2.400 ppp (desde vidrio de escáner. Durante la captura se utilizó un fondo blanco. Por otro lado, para evitar la marchitez debido a la oxidación; la captura de la imagen se realizó en un intervalo de 0 a 5 minutos posteriores al corte con la parte superior hacia arriba.

3.2.2.2 Procesamiento de imágenes digitales

Las imágenes fueron procesadas en la plataforma MATLAB 2021. El tratamiento inicial se enfocó en mejorar su calidad, mientras que el segundo en identificar las características de la imagen. Las imágenes de color compuestas se descompondrán en componentes de imagen de espectro rojo (R), imagen de espectro verde (G) e imagen de espectro azul (B). Para extraer la información de color y obtener diferentes características, todas las características de la imagen se segmentarán de su fondo. Por tanto, se utilizarán imágenes segmentadas para calcular los valores medios de las bandas RGB de las imágenes.

Se utilizó un método por lotes semiautomático. La imagen se procesa dos veces la primera en donde se limpia el fondo y obtiene una máscara de la hoja (MH), y la segunda en donde se obtiene el valor promedio RGB de MH.

Durante la primera etapa, se lee la imagen original como la imagen RGB (M0); se convierte a escala de grises (M1) y se binariza (M2). Para eliminar posibles objetos pequeños del fondo, M2 se abre dos veces, función `bwareaopen`, los agujeros se rellenan con el comando `imfill` (M3). Para concluir, se realiza una comparación lógica entre M0 y M3; los píxeles identificados como fondo se mandan a cero, El resultado es MH; una imagen RGB de una hoja caracterizada por un fondo completamente negro.

En el primer paso de la segunda etapa, la imagen de la hoja (MH) se separa en tres matrices (MR, MG, MB); una matriz por banda. El promedio de cada matriz se calculó como

la suma de los pixeles distintos a cero divididos entre el número de pixeles distintos a cero; se obtienen tres promedios R, G, B.

Para concluir, se guarda un montaje de M0 y MH en la carpeta destino con el mismo nombre de la imagen procesada como JPG. R,G,B se imprimen en un CSV separados por comas.

3.2.2.3 Análisis de contenido de NPK

Se analizó el contenido de nitrato, fosfatos y potasio en la savia de las hojas por medio de un fotómetro multiparamétrico compacto para uso en el laboratorio ambiental o en el campo HANNA, HI8332. El medidor es uno de los fotómetros más avanzados disponibles con un diseño óptico innovador que utiliza un detector de referencia y una lente de enfoque para eliminar errores de cambios en la fuente de luz y de imperfecciones en la cubeta de vidrio. Se utilizaron los kits de reactivos asociados al equipo. Cabe destacar que dada la naturaleza del experimento, cada hoja se procesó y analizó individualmente.



Figura 3.6 Análisis de muestras, UAQ Campus Amealco

3.2.2.3.1 Preparación de muestra

La savia para análisis se extrajo por medio de maceración en agua desionizada. Las muestras congeladas se pesaron y maceraron con agua desionizada en una relación 40:1 miligramos de muestra fresca por mililitro de agua durante un minuto. Se recuperaron 25 ml de macerado y se filtraron con papel Whatman #1, poro de 25 mc, para separar sólidos remanentes. Posteriormente, para evitar la interferencia de compuestos orgánicos en la lectura; el filtrado se limpió con carbón activado (HANNA HI93703-55); los sobres se utilizaron de acuerdo a las indicaciones del proveedor.

Para obtener 15 ml de muestra, se mezclaron 20 ml de filtrado con dos sobres de carbón activado; se agitó por un minuto. La solución se filtró nuevamente con papel Whatman #1. El resultante se guardó en tubos estériles rotulados y se almacenó en congelación para análisis. El proceso se utilizó para las 100 muestras.



Figura 3.7 Preparación de muestras, UAQ Campus Amazcala

3.2.2.3.2 Análisis de nitrato

El nitrato en savia se estimó por medio de un método adaptado de reducción de Cadmio (HANNA HI93728-01). En el método, la reacción entre el nitrato y el reactivo provoca un tinte ámbar en la muestra. La intensidad del color se determina con un fotómetro compatible (HANNA HI8332) y la concentración de nitrato se muestra en mg/L (ppm) como nitrato-nitrógeno ($\text{NO}_3\text{-N}$). EL reactivo está diseñado para usarse con muestras que tienen un rango esperado de 0,0 a 30,0 mg/L (ppm) de nitrato-nitrógeno. Los reactivos se utilizaron de acuerdo a las instrucciones del proveedor. Todas las muestras se leyeron en “nitrato rango bajo”; este setting tiene una resolución de 0.1 mg/l, precisión de $\pm 10\%$ de la lectura, y desviación de ± 0.1 mg/l.

Para un total de 6 ml, se diluyeron 4 ml de muestra con 2 ml de agua desionizada y se vació a la cubeta; la mezcla se leyó como blanco. Se añadió un sobre de reactivo y se agitó vigorosamente durante 10 segundos, se continuó mezclando por inversión por 50 segundos con cuidado de no introducir burbujas de aire. Se incubó en el equipo por 4 minutos y 30 segundos. La lectura se tomó con un diodo emisor de Luz a 525 nm. Ya que el instrumento visualiza directamente en el display la concentración en mg/l de nitrato-nitrógeno la lectura

se convirtió a mg/l de nitrato (NO_3^-), multiplicando por un factor de 4.43. El proceso se utilizó para las 100 muestras.

3.2.2.3.2 Análisis de fosfato

El fosfato en savia se estimó por el método de aminoácido (HANNA HI 93750-01). El método, es una adaptación de los Métodos estándar para el examen de agua y aguas residuales, 18.^a edición, método de aminoácidos. La reacción entre el fosfato y los reactivos provoca un tinte azul en la muestra. Al agregar los reactivos a la muestra, tiene lugar una reacción medible a través de el espectrómetro de acuerdo a la concentración de color producida. Los resultados se mostrarán en mg/L (ppm) de fosfato (PO_4^{3-}). Estos reactivos están diseñados para usarse con muestras que tienen un rango esperado de 0,0 a 30,0 mg/L de fosfato. Los reactivos se utilizaron de acuerdo a las instrucciones del proveedor. Todas las muestras se leyeron en “fosfato”; este setting tiene una resolución de 0.1 mg/l, precisión de $\pm 4\%$ de la lectura, y desviación de ± 0.1 mg/l.

Para un total de 10 ml, se diluyeron 3 ml de muestra con 7 ml de agua desionizada; se vació a la cubeta. La mezcla se leyó como blanco. Se añadieron 10 gotas de reactivo A (HANNA HI 93717A) y se añadió un sobre de reactivo B (HANNA HI93717B). Se mezcló suavemente hasta que se disolvió el reactivo. Se incubó en el equipo por 5 minutos. El equipo muestra directamente la concentración en mg/L de fosfato (PO_4) por lo que se anotó la lectura directamente. El proceso se utilizó para las 100 muestras.

3.2.2.3.2 Análisis de potasio

El nitrato en savia se estimó por el método de Tetraphenylborato (HANNA HI93751-01). La reacción entre el potasio y los reactivos provoca una turbidez en la muestra. Similar a los anteriores, al agregar los reactivos a la muestra, tiene lugar una reacción y se puede usar un medidor de sobremesa. Los reactivos están diseñados para usarse con muestras que tienen una concentración esperada entre 0,0 y 200 mg/L de potasio para fotómetros de mesa. Todas las muestras se leyeron en “potasio rango alto”; este setting tiene una resolución de 0.1 mg/l, precisión de $\pm 7\%$ de la lectura, y desviación de ± 0.1 mg/l.

Para un total de 10 ml, se diluyó 1 ml de muestra con 9 ml de agua desionizada; se vació a la cubeta y se agregaron 6 gotas del reactivo A (HANNA HI93751A). La mezcla se leyó como blanco. Se añadió un sobre del reactivo B (HANNA HI93751B) y se mezcló

gentilmente por un minuto. Se incubó en el equipo por 2 minutos. El equipo muestra directamente la concentración en mg/L de potasio (K) por lo que se anotó la lectura directamente. El proceso se utilizó para las 100 muestras.

3.2.3 Desarrollo de modelo de correlación entre el valor promedio por banda RGB de imágenes y contenido de NPK en savia de hojas de tomate.

3.2.3.1 Revisión de datos

Previo al análisis de datos, se corrigieron las lecturas considerando la dilución realizada en el análisis. Dado que la dilución fue distinta para cada nutriente se calculó un factor de dilución específico para cada nutriente. Se detallan en la tabla siguiente:

NUTRIENTE	DILUCIÓN	FACTOR DE CORECCIÓN
N (NITRATO)	4 ml en 6 ml	0.67
P (FOSFATO)	3 ml en 10 ml	0.33
K (POTASIO)	1 ml en 10 ml	0.1

Tabla 3.2 Diluciones para lecturas y factores de corrección

3.2.3.2 Regresiones color-nutriente

Se realizaron gráficos de dispersión banda-nutriente. En total se realizaron nueve gráficos; R-N, G-N, B-N, R-P, G-P, B-P, R-K, G-K, y B-K. En cada gráfico de dispersión se probaron líneas de tendencia. En cada gráfico se evaluaron líneas de tendencia lineal, logarítmica, polinomial de segundo grado, exponencial, y media móvil. Se consideró una R cuadrada de 0.7 como mínimo aprobatorio.

3.2.3 Comparación los resultados del modelo contra los valores determinados en laboratorio.

De acuerdo con la regla 70/30 se consideraron 45 muestras adicionales para evaluar los resultados de los modelos resultantes.

Capítulo 4 RESULTADOS Y DISCUSIÓN

4.1 Desarrollo de una base de datos conformada por 100 imágenes de toma original obtenidas a través de un scanner, valores de la imagen descompuesta en RGB, y correspondiente contenido de NPK estimados en laboratorio.

Se obtuvieron 100 imágenes de toma original a través de un scanner Brother MFC-7860DW correspondientes a 100 hojas de plantas distintas. Todas las plantas incluidas en el muestreo tuvieron un manejo agrícola estándar de acuerdo a la metodología. Para asegurar calidad, las imágenes se guardaron en formato TIF de 4958 x 6458 píxeles. Debido al ambiente controlado dentro del scanner, las imágenes comparten las mismas características de luz, radiancia, y reflectancia. De este modo se minimiza el ruido y variación al estimar valores de RGB.

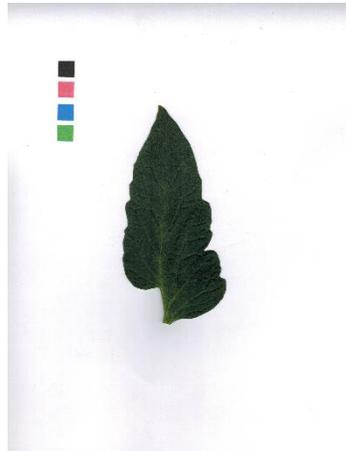


Figura 4.1 Imagen original CCF12072023_0001

Las imágenes se nombraron “CF”, “dia”, “mes”, “año”, y el número de imagen en el folder; las hojas se etiquetaron con el mismo nombre. Por otro lado, del procesamiento de imagen se obtuvieron dos resultados por imagen. En primer lugar, una imagen JPG que muestra la imagen original (M0), la imagen binarizada, el área de referencia, y el área contemplada como hoja (MH).

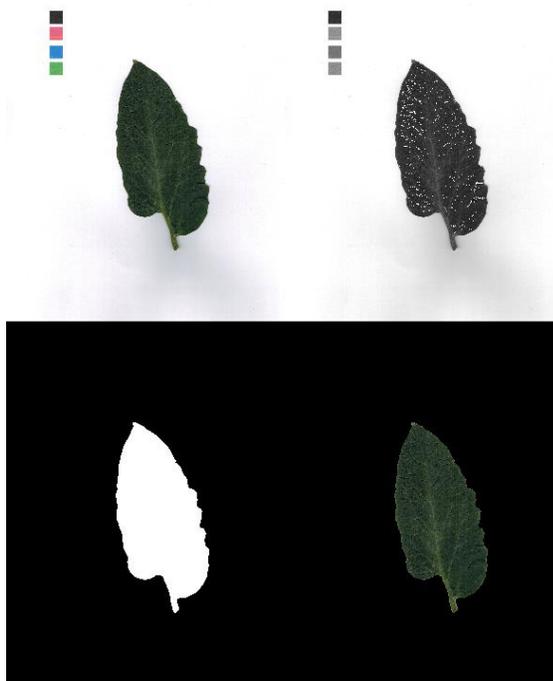


Figura 4.2 Imagen procesada CCF12072023_0001

En segundo lugar, un promedio de la banda roja (R), promedio de la banda azul (G), y promedio de banda verde (B). De esta forma se obtuvo un total de 200 imágenes, 100 originales y 100 resultantes del procesamiento, y 300 registros asociados a 100 imágenes.

4.1.1 Valores RGB

Los valores promedio de rojo obtenidos tienen un rango de 10.9 que va de 40.05 a 46.5. Esto representa estos valores se encuentran en el 5.6% de los valores posibles para la banda. La media es de 47.18 mientras que la desviación estándar es de 4.035. Por otro lado, los valores promedio de verde obtenidos tienen un rango de 18.85 que va de 56.85 a 75.69. Esto representa estos valores se encuentran en el 7.4% de los valores posibles para la banda. La media es de 47.18 mientras que la desviación estándar es de 4.211. Por último, los valores de B tuvieron menos variación que los dos anteriores. tienen un rango de 10.9 que va de 35.6 a 46.51. Esto representa estos valores se encuentran en el 4.2% de los valores posibles para la banda. La media es de 41.96 mientras que la desviación estándar es de 2.22

4.1.2 Valores NPK

La tabla presenta el promedio, mínimo, máximo, y desviación estándar de aniones y cationes del extracto celular, obtenidos en el ensayo.

	<i>N(NO₃⁻)</i>	<i>P(H₂PO₄⁻)</i>	<i>K⁺</i>
<i>PROMEDIO</i>	1551.7284	40.8432148	4514.444444
<i>MIN</i>	791.04	10.54	1,388.89
<i>MAX</i>	2,781.1	237.2	10,555.56
<i>RANGO</i>	1,990.0	226.6	9,166.67
<i>CV</i>	34.79	67.13	36.91

Tabla 4.1 Estadísticos de lecturas del extracto celular

La concentración de N (NO₃⁻) presenta un valor medio de 1551.7284 ppm, un valor mínimo de 791.04 ppm y un valor máximo de 2,781.1 ppm con un coeficiente de variación de 34.79 %. Estos valores son similares a los presentados por Landeral et al, (2014) en un cultivo de tomate con valores medios de 1 252 ppm aunque tiene un coeficiente de variación mayor al reportado de 17%. El coeficiente de variación es similar al presentado por Castro et al. (2000) (1 290 ppm) en un estudio realizado en plantas jóvenes de tomate con un coeficiente de variación de 33%, así como por Burgeño (1999) en cultivo de tomate bajo acolchado plástico.

Los valores medios, mínimos y máximos de la concentración de P (H₂PO₄) fueron de 40.84, 10.54, y 237.2 con un coeficiente de variación de 67.13%. Estos valores son similares a los presentados por Landeral et al, (2014) en tomate en invernadero en 2014 con un valor promedio de 40, 13 y 223 ppm, aunque el coeficiente de variación es superior comparado con el reportado de 91%. Los valores también coinciden con Bahrún et al.(2002) en un cultivo de maíz con valores medios de 102 ppm y un coeficiente de 30%.

Por último, los valores obtenidos para la concentración de K + muestran un promedio de 4 514 ppm, con un valor mínimo de 1388 ppm y un valor máximo de 10 555 ppm y un coeficiente de variación del 36.91 %. Estos valores son similares a los reportados por Landeral et al, (2014) promedio de 4.584 ppm, con un valor mínimo de 3 010 ppm y un valor máximo de 6 447 ppm y un coeficiente de variación del 16%. El coeficiente de variación es menor al presentado por Armenta (2001) (2.691ppm C.V. 62%) en cultivo de tomate, sin embargo, el promedio coincide con el valor óptimo propuesto por Burgueño (1999).

4.2 Modelación de la correlación entre el valor promedio por banda RGB de imágenes y contenido de NPK en hojas de jitomate

4.2.1 Regresiones color-nutriente

Se creó una gráfica de dispersión color-nutriente por cada combinación; esto resultó en nueve gráficos. Se iteró entre modelos de tendencia buscando el mejor ajuste para el valor R; el valor objetivo fue de 0.7. Se evaluaron líneas de tendencia exponencial, lineal, logarítmica, polinomial, y potencial.

4.2.1.1 Regresiones R-N, R-P, R-K

4.2.1.1.1 Regresión R-N,

El mejor ajuste se encontró en el modelo polinomial; la ecuación para la recta: $y = 10.18x^2 - 920.78x + 24964$. Sin embargo, la R^2 fue de 0.0089 menor al objetivo por lo que se descarta que exista una correlación significativa entre el valor promedio de rojo y el contenido de nitrógeno.

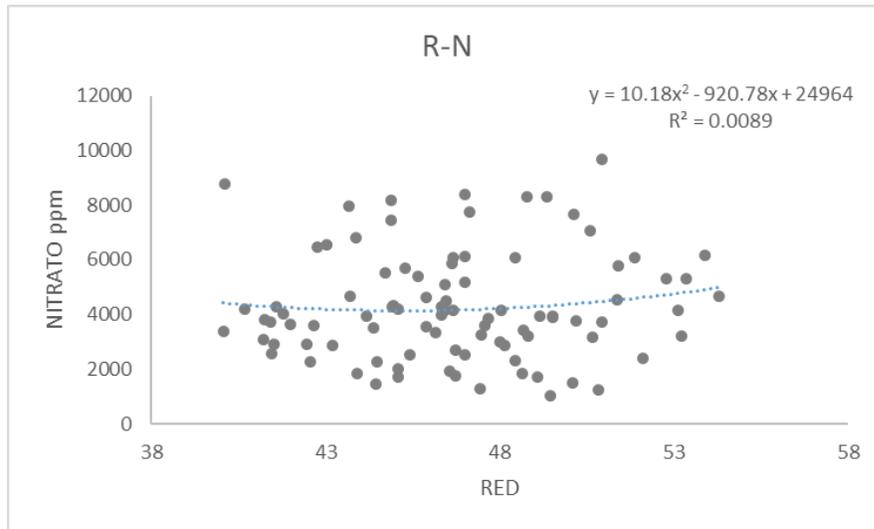


Figura 4.3 Regresión rojo, nitrógeno

4.2.1.1.2 Regresión R-P,

Nuevamente, el mejor ajuste se encontró en el modelo polinomial; la ecuación para fue la siguiente: $y = 2.7325x^2 - 273.65x + 7775.9$. Sin embargo, la R^2 fue de 0.0197 menor al objetivo por lo que se descarta que exista una correlación significativa entre el valor promedio de rojo y el contenido de potasio.

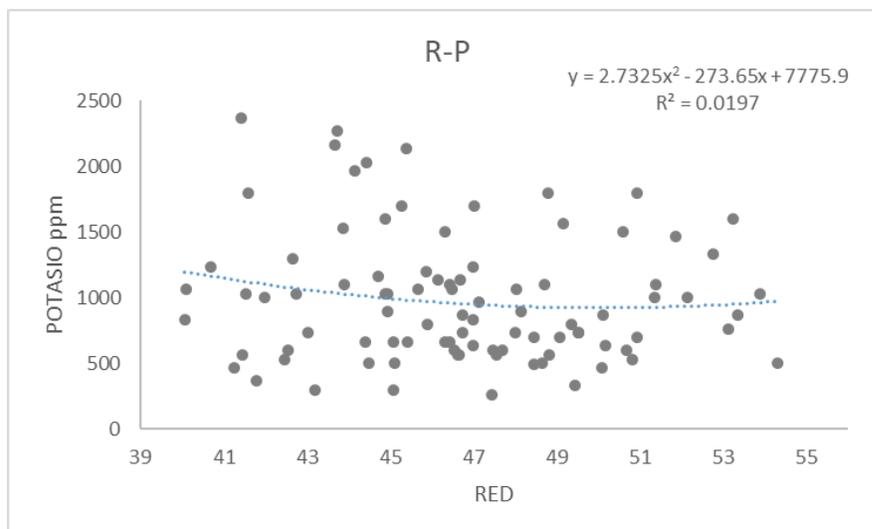


Figura 4.4 Regresión rojo, potasio

4.2.1.1.3 Regresión R-K,

En este caso, el mejor ajuste se encontró en el modelo exponencial. La ecuación para fue la siguiente: $y = 158852 e^{-0.015x}$. Sin embargo, la R^2 fue de 0.0118 menor al objetivo por lo que se descarta que exista una correlación significativa entre el valor promedio de rojo y el contenido de potasio.

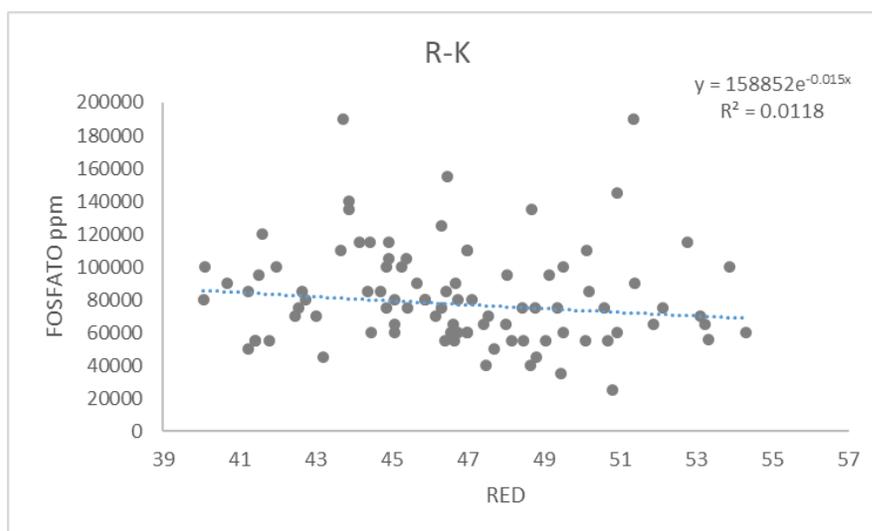


Figura 4.5 Regresión rojo, potasio

4.2.1.2 Regresiones G-N, G-P, G-K

4.2.1.2.1 Regresión G-N,

En este caso, los modelos lineales, logarítmicos, y polinomiales tuvieron ajustes similares. Sin embargo, el modelo polinomial tuvo un ajuste de cinco cifras mayor. La ecuación para la recta: $y = -0.0113x^2 + 1.8008x - 41.053$. Sin embargo, la R^2 fue de 0.0114 menor al objetivo por lo que se descarta que exista una correlación significativa entre el valor promedio de verde y el contenido de nitrógeno.

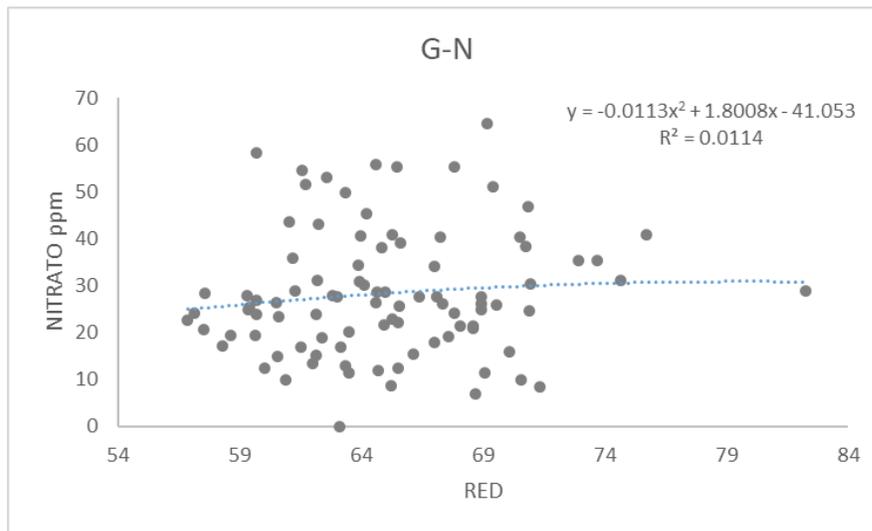


Figura 4.6 Regresión verde, nitrógeno

4.2.1.2.2 Regresión G-P,

Como en casos anteriores, el mejor ajuste se encontró en el modelo polinomial; la ecuación para fue la siguiente: $y = 0.8193x^2 - 119.28x + 5266.9$. Sin embargo, la R^2 fue de 0.0116 menor al objetivo por lo que se descarta que exista una correlación significativa entre el valor promedio de verde y el contenido de potasio.

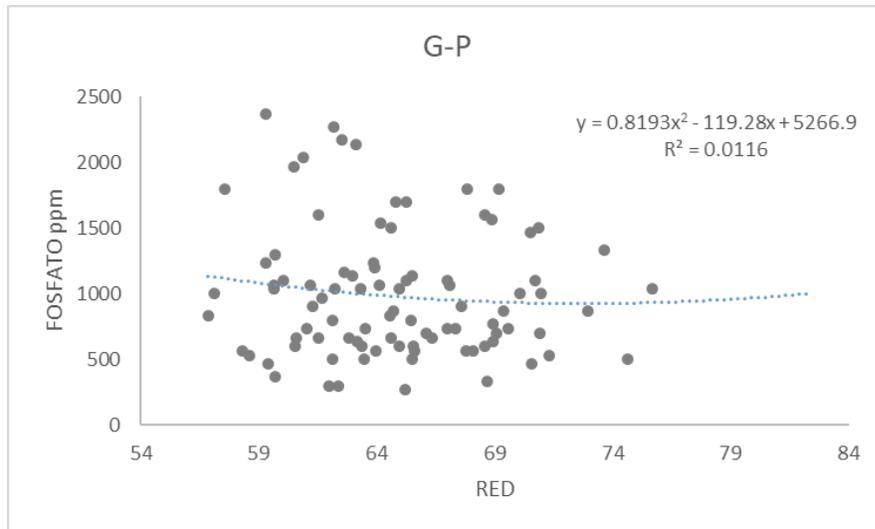


Figura 4.7 Regresión verde, fósforo

4.2.1.2.3 Regresión G-K,

El modelo polinomial presentó una R cuadrada de 0.0174 superior a las demás combinaciones de G. El modelo para la ecuación es: $y = 99.643x^2 - 13778x + 554974$. Dado que la r fue menor al objetivo se descarta que exista una correlación significativa entre el valor promedio de verde y el contenido de potasio.

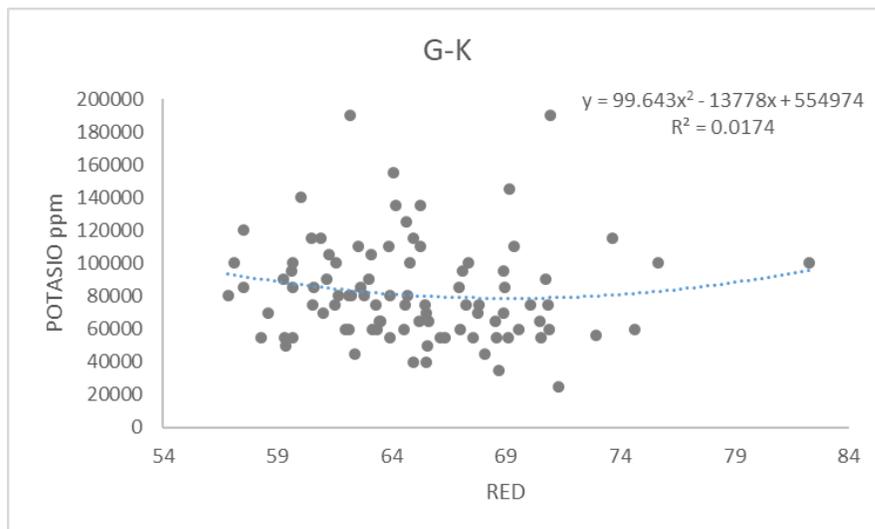


Figura 4.8 Regresión verde, potasio

4.2.1.3 Regresiones B-N, B-P, B-K

4.2.1.3.1 Regresión B-N,

Esta fue la combinación con mejor ajuste de todas las combinaciones; R cuadrada de 0.0413 sin embargo, continúa por debajo del objetivo. Se utilizó un modelo polinomial cuya ecuación fue: $y = 60.793x^2 - 5098.5x + 110900$. A pesar de esto, se descarta que exista una correlación significativa entre el valor promedio de azul y el contenido de nitrógeno.

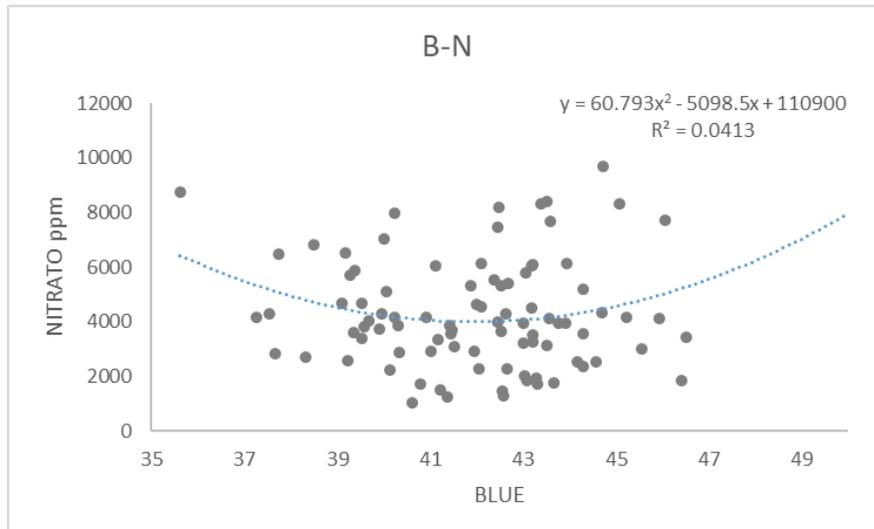


Figura 4.9 Regresión azul, nitrógeno

4.2.1.3.2 Regresión B-P,

Este gráfico presentó el segundo un ajuste similar al de potasio; R cuadrada de 0.0021. La ecuación para fue la siguiente: $y = -2.3916x^2 + 191.98x - 2844$. Dado que la R^2 es menor al objetivo por lo que se descarta que exista una correlación significativa entre el valor promedio de azul y el contenido de potasio.

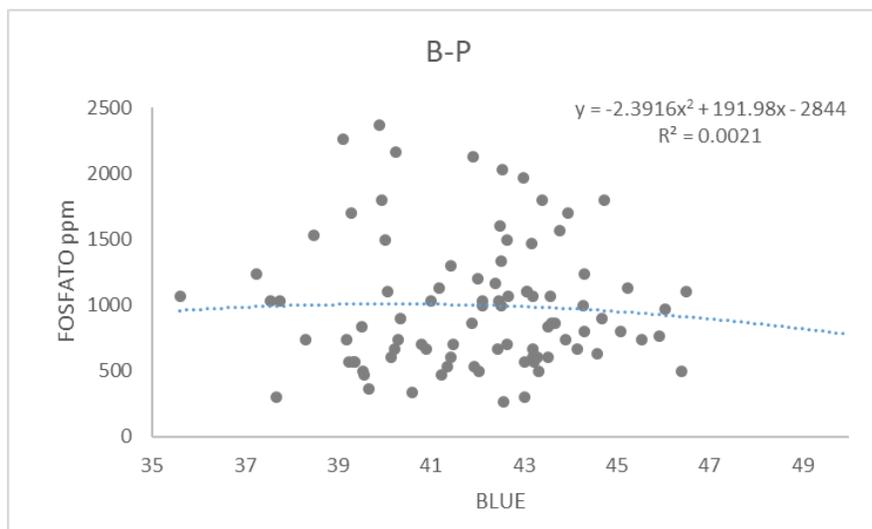


Figura 4.10 Regresión azul, fósforo

4.2.1.3.3 Regresión B-K,

El mejor ajuste se encontró en el modelo polinomial; la ecuación para fue la siguiente: $y = -2.3916x^2 + 191.98x - 2844$. Sin embargo, la R^2 fue de 0.0021 menor al objetivo por lo que se descarta que exista una correlación significativa entre el valor promedio de rojo y el contenido de potasio.

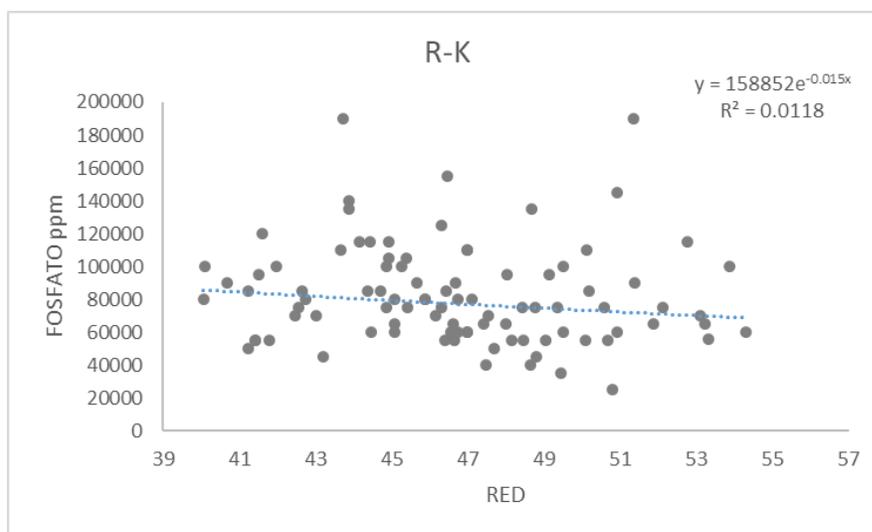


Figura 4.11 Regresión azul, potasio

4.3 Comparación los resultados del modelo contra los valores determinados en laboratorio

Dado que ninguna regresión tuvo un índice de correlación igual o superior al objetivo se omitió la comprobación del modelo.

5 CONCLUSIÓN

A pesar de que en estudios previos se encontró correlación entre el color de la hoja y el color, en el estudio realizado, ningún gráfico mostró un índice de correlación mayor o igual a 0.7. Por lo tanto, se rechaza la hipótesis planteada y se determina que no hay una relación cuantificable entre el contenido de nitrógeno, fósforo, y potasio de una hoja de tomate y valores RGB promedio de una imagen de hoja de tomate.

Si bien, en la literatura revisada se menciona el uso de otros modelos de color como CMYK o LAB ninguno de los desarrollos se enfoca en la detección cuantitativa de nitrógeno, fósforo, y potasio a la vez. A la par, dada la dispersión de datos encontrada, se encuentra que el cambio de modelo de color no generará un cambio sobre el comportamiento de los datos. Sin embargo, la información aquí presentada, sienta precedente para descartar metodologías para el desarrollo de tecnología cuantitativa. Esto no implica que no exista una relación, sino que se requiere buscar una metodología distinta para cuantificar el contenido de NPK mediante procesamiento de imagen.

BIBLIOGRAFÍA

- Shah, P. Gupta and Y. M. Ajar, "Macro-Nutrient Deficiency Identification in Plants Using Image Processing and Machine Learning," 2018 3rd International Conference for Convergence in Technology (I2CT), 2018, pp. 1-4, doi: 10.1109/I2CT.2018.8529789.
- Abdel-Mawgoud, A.M.R. & El-Greadly, N.H.M. & Helmy, Y.I. & Singer, S. (2007). Responses of Tomato Plants to Different Rates of Humic-based Fertilizer and NPK Fertilization. *Journal of Applied Sciences Research*. 3. 169-174.
- Adhikari, R., & Nemali, K. (2020). A Novel Method for Estimating Nitrogen Stress in Plants Using Smartphones. *Horticulturae*, 6(4), 74. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/horticulturae6040074>
- Ahmed K. AL-ANIMahdi M. ALI (2013).
- Alessandra Francini, Andrea Giro, Antonio Ferrante (2019). Biochemical and Molecular Regulation of Phenylpropanoids Pathway Under Abiotic Stresses. *Biochemical and Molecular Regulation of Phenylpropanoids Pathway Under Abiotic Stresses*
- Amin, Siti & Awang, Roslan. (2018). Automated Detection of Nitrogen Status on Plants: Performance of Image Processing Techniques. 1-4. 10.1109/SCORED.2018.8711334.
- An image processing based method to estimate crop requirements for nutrient fertiliser. <https://patents.google.com/patent/WO2014100856A1/en?q=nutrient+image+estimation>
- Anhui Agricultural University AHU (2020). Water and fertilizer integrated machine control system with crop nutrient demand analysis function and control method thereof. [https://patents.google.com/patent/CN111557159B/en?q=\(nutrient+image+plant\)&before=priority:20230621&after=priority:20180101&oq=\(nutrient+image+plant\)+before:priority:20230621+after:priority:20180101](https://patents.google.com/patent/CN111557159B/en?q=(nutrient+image+plant)&before=priority:20230621&after=priority:20180101&oq=(nutrient+image+plant)+before:priority:20230621+after:priority:20180101)
- Anshuman Nayak, Somsubhra Chakraborty, Dillip Kumar Swain (2023). Application of smartphone-image processing and transfer learning for rice disease and nutrient deficiency detection. *Smart Agricultural Technology*. <https://www.sciencedirect.com/science/article/pii/S2772375523000254>
- Anu Jose, S Nandagopalan, Vidya Ubalanka1 and Dhanya Viswanath1(2021). Detection and classification of nutrient deficiencies in plants using machine learning. *Journal of Physics*. <https://iopscience.iop.org/article/10.1088/1742-6596/1850/1/012050/pdf>
- Arshad Jalal, José Carlos de Oliveira Junior, Janaína Santos Ribeiro, Guilherme Carlos Fernandes, Giovana Guerra Mariano, Vanessa Dias Rezende Trindade, André Rodrigues dos Reis, *Hormesis in plants: Physiological and biochemical responses, Ecotoxicology and Environmental Safety*, Volume 207, 2021, 111225, ISSN 0147-6513, <https://doi.org/10.1016/j.ecoenv.2020.111225>.
- Arshad Jalal, José Carlos de Oliveira Junior, Janaína Santos Ribeiro, Guilherme Carlos Fernandes, Giovana Guerra Mariano, Vanessa Dias Rezende Trindade, André Rodrigues dos Reis, *Hormesis in plants: Physiological and biochemical responses, Ecotoxicology and Environmental Safety*, Volume 207, 2021, 111225, ISSN 0147-6513, <https://doi.org/10.1016/j.ecoenv.2020.111225>.
- Azad, Dr & Hasan, Md & K, Mohammed. (2017). Color Image Processing on Digital Image. *International Journal of New Technology and Research*. 3. 56-62.
- Balasubramaniam, P., Ananthi, V.P., 2016. Segmentation of nutrient deficiency in incomplete crop images using intuitionistic fuzzy C-means clustering algorithm. *Nonlinear Dynamics* 83 (1-2), 849-866
- Banks, D. L., & Fienberg, S. E. (2003). Statistics, Multivariate. *Encyclopedia of Physical Science and Technology*, 851–889. doi:10.1016/b0-12-227410-5/00731-6
- Bao TranHa Tran (2019). IoT-based farming and plant growth ecosystem. [https://patents.google.com/patent/US11195015B2/en?q=\(nitrogen+estimation+plant\)&oq=nitrogen+estimation+plant](https://patents.google.com/patent/US11195015B2/en?q=(nitrogen+estimation+plant)&oq=nitrogen+estimation+plant)
- Bao TranHa Trany (2018). Smart device. [https://patents.google.com/patent/US20200020165A1/en?q=\(image+processing+nutrient+estimation\)&oq=image+processing+nutrient+estimation&page=1](https://patents.google.com/patent/US20200020165A1/en?q=(image+processing+nutrient+estimation)&oq=image+processing+nutrient+estimation&page=1)
- Bewick, V., Cheek, L., & Ball, J. (2003). Statistics review 7: Correlation and regression. *Critical care (London, England)*, 7(6), 451–459. <https://doi.org/10.1186/cc2401>
- Bhupenchandra, Ingudam & Athokpam, Herojit & Singh, Nabachandra & Soibam, Helena & Chongtham, Sunil & Singh, Laishram & Sinyorita, Soibam & Devi, Elangbam & Bhagowati, Seema & Bora, Sasanka &

- Kumar, Amit & Ch, Premabati & Olivia, L. (2021). *Leaf color chart (LCC): An instant tool for assessing nitrogen content in plant: A review*. 10. 1100-1104.
- Bodale, I., Mihalache, G., Achiței, V., Teliban, G.-C., Cazacu, A., & Stoleru, V. (2021). *Evaluation of the Nutrients Uptake by Tomato Plants in Different Phenological Stages Using an Electrical Conductivity Technique*. *Agriculture*, 11(4), 292. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agriculture11040292>
 - o Cevallos, H. Ponce, E. Moya-Albor and J. Brieva, "Vision-Based Analysis on Leaves of Tomato Crops for Classifying Nutrient Deficiency using Convolutional Neural Networks," 2020 International Joint Conference on Neural Networks (IJCNN), Glasgow, UK, 2020, pp. 1-7, doi: 10.1109/IJCNN48605.2020.9207615.
 - Chen, L.S., Zhang, S.J., Wang, K., Shen, Z.Q., Deng, J.S., 2013. *Identifying of rice phosphorus stress based on machine vision technology*. *Life Science Journal* 10 (2), 2655
 - Cornell University. (2010). *Basic Concepts of Plant Nutrition*. NRCCA. <https://nrcca.cals.cornell.edu/nutrient/CA1/CA0104.php>
 - *Determination of soil nutrients (NPK) using optical methods: a mini review*. *Journal of Plant Nutrition*. 44. 1-14. 10.1080/01904167.2021.1884702.
 - E. Hossain, M. F. Hossain and M. A. Rahaman, "A Color and Texture Based Approach for the Detection and Classification of Plant Leaf Disease Using KNN Classifier," 2019 International Conference on Electrical, Computer and Communication Engineering (ECCE), Cox'sBazar, Bangladesh, 2019, pp. 1-6, doi: 10.1109/ECACE.2019.8679247.
 - *Econometrics and Statistics, Volume 13, 2020, Pages 125-136, ISSN 2452-3062,*
 - Evans JR. *Nitrogen and photosynthesis in the flag leaf of wheat (Triticum aestivum L.)*. *Plant Physiol* 1983;72:297- 302. <https://doi.org/10.1104/pp.72.2.297>.
 - Forbes (2022). *Producción de tomate mexicano creció 9.5% en la última década*. <https://www.forbes.com.mx/produccion-de-tomate-mexicano-crecio-9-5-en-la-ultimadecada/#:~:text=Seg%C3%BAn%20datos%20de%20la%20Sader,Unidos%2C%20B%C3%A9lgica%20y%20Singapur%2C%20entre>
 - Gallardo, M., Cuartero, J., Andújar de la Torre, L., Padilla, F. M., Segura, M. L., & Thompson, R. B. (2021). *Modelling nitrogen, phosphorus, potassium, calcium and magnesium uptake, and uptake concentration, of greenhouse tomato with the VegSyst model*. *Scientia Horticulturae*, 279, 109862. doi:10.1016/j.scienta.2020.109862
 - Goh, A. H. A., Ali, Z., Nor, N. M., Baharum, A., & Ahmad, W. M. A. W. (2017). *A quadratic regression modelling on paddy production in the area of Perlis*. doi:10.1063/1.4995942
 - Goldy R. *Michigan State University Extension* (2013). *Knowing nutrient mobility is helpful in diagnosing plant nutrient deficiencies*. https://www.canr.msu.edu/news/knowning_nutrient_mobility_is_helpful_in_diagnosing_plant_nutrient_deficiencies
 - Haider, T., Farid, M. S., Mahmood, R., Ilyas, A., Khan, M. H., Haider, S. T.-A., Chaudhry, M. H., et al. (2021). *A Computer-Vision-Based Approach for Nitrogen Content Estimation in Plant Leaves*. *Agriculture*, 11(8), 766. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agriculture11080766>
 - Hidetoshi Matsui, *Quadratic regression for functional response models*, <https://doi.org/10.1016/j.ecosta.2018.12.003>. (<https://www.sciencedirect.com/science/article/pii/S2452306219300024>)
 - Hu, W., Lu, Z., Meng, F., Li, X., Cong, R., Ren, T., Sharkey, T.D. and Lu, J. (2020), *The reduction in leaf area precedes that in photosynthesis under potassium deficiency: the importance of leaf anatomy*. *New Phytol*, 227: 1749-1763. <https://doi.org/10.1111/nph.16644>
 - Jiangsu University (2010). *Method and device for rapidly detecting nutritional information of tea tree based on hyperspectral imaging technique*. <https://patents.google.com/patent/CN101915738A/en?q=nutrient+crop+image+detection>
 - Jiangsu University (2011). *Nondestructive detection device and method for facility crop growth information*. <https://patents.google.com/patent/CN102384767A/en?q=nutrient+crop+image+detection>
 - Jiangsu University (2011). *Quick crop nutrition level diagnosis device based on polarization spectrum technology*. <https://patents.google.com/patent/CN202383064U/en?q=nutrient+crop+image+detection>
 - Jiangsu University (2012). *Non-destructive detection device and method of internal information of crops based on spectrum technology*. <https://patents.google.com/patent/CN102788752B/en?q=nutrient+crop+image+detection>

- Jiangsu University (2012). *Nutrient diagnosis device and nutrient diagnosis method for nitrogen of crops based on multi-information integration of high spectral images and fluorescent images*. <https://patents.google.com/patent/CN102788796B/en?q=nutrient+crop+image+estimation>
- Kamelia, L., Rahman, T. K. B. A., Saragih, H., & Haerani, R. (2020). *The Comprehensive Review on Detection of Macro Nutrients Deficiency in Plants Based on The Image Processing Technique*. 2020 6th International Conference on Wireless and Telematics (ICWT). doi:10.1109/icwt50448.2020.9243623
- Kechen Song a b c, Ying Zhao a b c, Liming Huang a b c, Yunhui Yan a b c, Qinggang Meng d. (2023). *RGB-T image analysis technology and application: A survey*. *Engineering Applications of Artificial Intelligence* Volume 120. <https://www.sciencedirect.com/science/article/abs/pii/S0952197623001033>
- Koch, M., Naumann, M., Pawelzik, E. et al. *The Importance of Nutrient Management for Potato Production Part I: Plant Nutrition and Yield*. *Potato Res.* 63, 97–119 (2020). <https://doi.org/10.1007/s11540-019-09431-2>
- Kour, Haneet. (2015). *Analysis on Image Color Model*. 4. 233-235.
- Lee, K.-J., Lee, B.-W., 2013. *Estimation of rice growth and nitrogen nutrition status using color digital camera image analysis*. *European Journal of Agronomy* 48, 57-65
- Leland Stanford Junior University (2015). *Systems and Methods for Satellite Image Processing to Estimate Crop Yield*. <https://patents.google.com/patent/US20160171680?q=nutrient+crop+image+estimation>
- Longsheng Fu a c d e, Fangfang Gao a, Jingzhu Wu b, Rui Li a, Manoj Karkee e, Qin Zhang e. (2020). *Application of consumer RGB-D cameras for fruit detection and localization in field: A critical review*. *Computers and Electronics in Agriculture*. <https://www.sciencedirect.com/science/article/abs/pii/S0168169920319530>
- Luz, P.H.C., Marin, M.A., Deveschio, F.F.S., Romualdo, L.M., Zuñiga, A.M.G., Oliveira, M.W.S., Herling, V.R., Bruno, O.M., 2018. *Boron Deficiency Precisely Identified on Growth Stage V Maize Crop Using Texture Image Analysis*. *Communications in Soil Science and Plant Analysis* 49 (2), 159–169
- Magalhães, L. P. de ., Trevisan, L. R., Gomes, T. M., & Rossi, F.. (2022). *USE OF DIGITAL IMAGES TO CLASSIFY LEAF PHOSPHORUS CONTENT IN GRAPE TOMATOES*. *Engenharia Agrícola*, 42(spe), e20210147. <https://doi.org/10.1590/1809-4430-Eng.Agric.v42npe20210147/2022>
- Maillard Anne, Diquélou Sylvain, Billard Vincent, Laîné Philippe, Garnica Maria, Prudent Marion, Garcia-Mina José-Maria, Yvin Jean-Claude, Ourry Alain. (2015). *Analysis on Image Color Model*. *Frontiers in Plant Science*. <https://www.frontiersin.org/article/10.3389/fpls.2015.00317>
- Maneesha Mall , Ritesh Kumar , Md. Qussen Akhtar . (2021). *Chapter 1 - Horticultural crops and abiotic stress challenges*. <https://www.sciencedirect.com/science/article/pii/B9780128228494000012>
- Mattson M. P. (2008). *Hormesis defined*. *Ageing research reviews*, 7(1), 1–7. <https://doi.org/10.1016/j.arr.2007.08.007>
- McCauley, C. Jones, and J. Jacobsen, 'Plant Nutrient Functions and Deficiency and Toxicity Symptoms', *Nutr. Manag. Modul.*, vol. 9, no. 9, pp. 1–16, 2011, doi: 10.1109/ISTC.2012.6325235.
- Muhammad Anas, Fen Liao, Krishan K. Verma, Muhammad Aqeel Sarwar, Aamir Mahmood, Zhong-Liang Chen, Qiang Li, Xu-Peng Zeng, Yang Liu & Yang-Rui Li (2020). *Fate of nitrogen in agriculture and environment: agronomic, eco-physiological and molecular approaches to improve nitrogen use efficiency*. <https://biolres.biomedcentral.com/articles/10.1186/s40659-020-00312-4>
- Nari Information and Communication Technology Co (2021). *Water and fertilizer integrated optimization control system and method*. [https://patents.google.com/patent/CN114158336A/en?q=\(nutrient+image+plant\)&before=priority:20230621&after=priority:20180101&dq=\(nutrient+image+plant\)+before=priority:20230621+after=priority:20180101](https://patents.google.com/patent/CN114158336A/en?q=(nutrient+image+plant)&before=priority:20230621&after=priority:20180101&dq=(nutrient+image+plant)+before=priority:20230621+after=priority:20180101)
- Nazia Salim & Ali Raza (2020) *Nutrient use efficiency (NUE) for sustainable wheat production: a review*, *Journal of Plant Nutrition*, 43:2, 297-315, DOI: 10.1080/01904167.2019.1676907
- Ospina R, Oscar, Anzola Vásquez, Héctor, Ayala Duarte, Olber, & Baracaldo Martínez, Andrea. (2020). *Validación de un algoritmo de procesamiento de imágenes Red Green Blue (RGB), para la estimación de proteína cruda en gramíneas vs la tecnología de espectroscopía de infrarrojo cercano (NIRS)*. *Revista de Investigaciones Veterinarias del Perú*, 31(2), e17940. <https://dx.doi.org/10.15381/ripev.v31i2.17940>
- Penn State (2023). *Potassium Deficiency*. *Plants Science*. <https://plantscience.psu.edu/research/labs/roots/methods/methods-info/nutritional-disorders-displayed/potassium-deficiency>
- Peñuelas, J.; Poulter, B.; Sardans, J.; Ciais, P.; Van der Velde, M.; Bopp, L.; Boucher, O.; Godderis, Y.; Hinsinger, P.; Llusia, J. *Human-induced nitrogen–phosphorus imbalances alter natural and managed*

- ecosystems across the globe. *Nat. Commun.* 2013, 4, 2934. [Google Scholar] [CrossRef] [PubMed] <https://www.mdpi.com/2227-9040/7/4/51#B4-chemosensors-07-00051>
- PetersTobias MENNEAlexei MELNITCHOUCK (2017). Efficient use of plant protection agents, nutrients, and the like in the growing of cultivated plants. <https://patents.google.com/patent/WO2018050592A1/en?q=nutrient+crop+image+estimation>
 - Pfau, T., Christian, N., Masakapalli, S.K. et al. The intertwined metabolism during symbiotic nitrogen fixation elucidated by metabolic modelling. *Sci Rep* 8, 12504 (2018). <https://doi.org/10.1038/s41598-018-30884-x>
 - Potdar, Revati & Shirolkar, Mandar & Verma, Alok & More, Pravin & Kulkarni, A.. (2021).
 - Rati Shukla, Gaurav Dubey, Pooja Malik, Nidhi Sindhwani, Rohit Anand, Aman Dahiya, Vikash Yadav* (2021). Detecting Crop Health using Machine Learning Techniques in
 - Runeckles, V. C. (1958). PHOSPHATE METABOLISM IN LEAVES: I. IDENTIFICATION OF SOME PHOSPHORYLATED COMPOUNDS IN WHEAT LEAVES. *Canadian Journal of Botany*, 36(5), 707–715. doi:10.1139/b58-064
 - Runeckles, V. C. (1958). PHOSPHATE METABOLISM IN LEAVES: I. IDENTIFICATION OF SOME PHOSPHORYLATED COMPOUNDS IN WHEAT LEAVES. *Canadian Journal of Botany*, 36(5), 707–715. doi:10.1139/b58-064
 - S. Gayathri, D. C. J. W. Wise, P. B. Shamini and N. Muthukumaran, "Image Analysis and Detection of Tea Leaf Disease using Deep Learning," 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC), Coimbatore, India, 2020, pp. 398-403, doi: 10.1109/ICESC48915.2020.9155850.
 - S. Jeyalakshmi and R. Radha, 'A Review On Diagnosis Of Nutrient Deficiency Symptoms in Plant Leaf Image Using Digital Image Processing', *ICTACT J. Image Video Process.*, vol. 7, no. 4, pp. 1515–1524, 2017, doi: 10.21917/ijivp.2017.0216.
 - SADER. 2021. Secretaría de Agricultura y Desarrollo Rural. Análisis de la balanza comercial agroalimentaria de México. <https://www.gob.mx/cms/uploads/attachment/file/627936/Balanza-Comercial-Agropecuaria-y-Agroindustrial-enero-2021.pdf>.
 - Sainju, Upendra & Dris, Ramdane & Singh, Bharat. (2003). Mineral nutrition of tomato. *Food, Agriculture & Environment*. 1.
 - Sanchez, L., Filter, C., Baltensperger, D., and Kurouski, D. (2020b). Confirmatory non-invasive and non-destructive differentiation between hemp and cannabis using a hand-held raman spectrometer. *RSC Adv.* 10, 3212–3216. doi: 10.1039/C9RA08225E <https://www.frontiersin.org/articles/10.3389/fpls.2020.573321/full#B25>
 - Shenzhen Dade Zonghe Technology Co ltd (2020). Multi-scale crop yield assessment method and system. <https://patents.google.com/patent/CN111898922A/en?q=nutrient+crop+image+estimation>
 - SIAP. 2020. Sistema de Información Agroalimentaria y Pesquera. Producción agropecuaria y pesquera. <https://www.gob.mx/siap/acciones-y-programas/produccion-agricola-33119>.
 - Siedliska, A., Baranowski, P., Pastuszka-Woźniak, J. et al. Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance. *BMC Plant Biol* 21, 28 (2021). <https://doi.org/10.1186/s12870-020-02807-4>
 - Smart Agriculture System. *Journal of Scientific & Industrial Research*. <http://op.niscpr.res.in/index.php/JSIR/article/view/44034/465479693>
 - Soroush SARABIMohammadreza MohammadiAli SARABIMehdi RAZPOUSH NAZARIAmeneh SHADLOAli SOLTANMORADIHanieh TAVASOLI (2020). An artificial-intelligence-based method of agricultural and horticultural plants' physical characteristics and health diagnosing and development assessment.. [https://patents.google.com/patent/WO2021198731A1/en?q=\(image+processing+nutrient+plant\)&before=priority:20230621&after=priority:20180101](https://patents.google.com/patent/WO2021198731A1/en?q=(image+processing+nutrient+plant)&before=priority:20230621&after=priority:20180101)
 - Souri, M. K., & Dehnavard, S. (2018). Tomato plant growth, leaf nutrient concentrations and fruit quality under nitrogen foliar applications. *Advances in Horticultural Science*, 32(1), 41–48. <https://www.jstor.org/stable/26525420>
 - Sun, G., Ding, Y., Wang, X., Lu, W., Sun, Y., & Yu, H. (2019). Nondestructive Determination of Nitrogen, Phosphorus and Potassium Contents in Greenhouse Tomato Plants Based on Multispectral Three-Dimensional Imaging. *Sensors*, 19(23), 5295. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/s19235295>
 - Talita Barbosa Abreu, Diógenes, Tavares de Oliveira, Fábio Henrique, Martins de Queiroga, Fábio, Costa Moura, Anderson Cley, Lyra de Carvalho, Simplicio, & Medeiros Tavares, Hernane Arllen. (2018). Accumulation of dry matter and macronutrients by the Caeté tomato under field conditions. *DYNA*, 85(207), 101-106. <https://doi.org/10.15446/dyna.v85n207.72277>

- Tewari, V.K. & Arudra, A.K. & Kumar, Satya Prakash & Pandey, V. & Chandel, Narendra. (2013). Estimation of plant nitrogen content using digital image processing. *Agricultural Engineering International: CIGR Journal*. 15. 78-86.
- Thornburg TE, Liu J, Li Q, Xue H, Wang G, Li L, Fontana JE, Davis KE, Liu W, Zhang B, Zhang Z, Liu M and Pan X (2020) Potassium Deficiency Significantly Affected Plant Growth and Development as Well as microRNA-Mediated Mechanism in Wheat (*Triticum aestivum* L.). *Front. Plant Sci.* 11:1219. doi: 10.3389/fpls.2020.01219
- Timo BongartzSebastian OlschowskiNorbert HaasGuido AngenendtMarek BurzaNorbert MaggCristin Dziekonski (2020). Controlled agricultural systems and methods of managing agricultural systems. <https://patents.google.com/patent/CN102788796B/en?q=nutrient+crop+image+es>
[https://patents.google.com/patent/US11663414B2/en?q=\(image+processing+nutrient+plant\)&before=priority:20230621&after=priority:20180101](https://patents.google.com/patent/US11663414B2/en?q=(image+processing+nutrient+plant)&before=priority:20230621&after=priority:20180101)
- Tran T-T, Choi J-W, Le T-TH, Kim J-W. A Comparative Study of Deep CNN in Forecasting and Classifying the Macronutrient Deficiencies on Development of Tomato Plant. *Applied Sciences*. 2019; 9(8):1601. <https://doi.org/10.3390/app9081601>
- University of Missouri System (2012). Method of predicting crop yield loss due to N-deficiency. <https://patents.google.com/patent/US8208680?q=nutrient+crop+image+estimation>
- Vibhute, Anup & Bodhe, Sk & More, Babasaheb. (2013). Nitrogen Estimation for Grapevine (In Veraison) Using RGB Color Image Processing. *Research and Reviews: Journal of Botanical Sciences*. 3. 4-7.
- Wiwart, M., Fordoński, G., Żuk-Golaszewska, K., & Suchowilska, E. (2009). Early diagnostics of macronutrient deficiencies in three legume species by color image analysis. *Computers and electronics in agriculture*, 65, 125-132. doi: 10.1016/j.compag.2008.08.003
- Xiong, X., Zhang, J., Guo, D., Chang, L., & Huang, D. (2019). Non-Invasive Sensing of Nitrogen in Plant Using Digital Images and Machine Learning for Brassica Campestris ssp. Chinensis L. *Sensors (Basel, Switzerland)*, 19(11), 2448. <https://doi.org/10.3390/s19112448>
- Xu, G., Zhang, F., Shah, S.G., Ye, Y., Mao, H., 2011. Use of leaf color images to identify nitrogen and potassium deficient tomatoes. *Pattern Recognition Letters* 32 (11), 1584-1590
- Yogesh, Dubey, A.K., Ratan, R. et al. Computer vision based analysis and detection of defects in fruits causes due to nutrients deficiency. *Cluster Comput* 23, 1817–1826 (2020). <https://doi.org/10.1007/s10586-019-03029-6>
- Zhang, J.; Xie, T.; Yang, C.; Song, H.; Jiang, Z.; Zhou, G.; Zhang, D.; Feng, H.; Xie, J. Segmenting Purple Rapeseed Leaves in the Field from UAV RGB Imagery Using Deep Learning as an Auxiliary Means for Nitrogen Stress Detection. *Remote Sens*. 2020, 12, 1403. <https://doi.org/10.3390/rs12091403>
- 王明建 (2021). Fertilizer blending system based on seedling body resolution. [https://patents.google.com/patent/CN114051811A/en?q=\(image+processing+nutrient+plant\)&before=priority:20230621&after=priority:20180101&page=1](https://patents.google.com/patent/CN114051811A/en?q=(image+processing+nutrient+plant)&before=priority:20230621&after=priority:20180101&page=1)