

COLEGIO DE POSTGRADUADOS

INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN EN CIENCIAS
AGRÍCOLAS

CAMPUS MONTECILLO

POSTGRADO DE EDAFOLOGÍA

**DIAGNÓSTICO DE DEFICIENCIAS DE NITRÓGENO Y
MAGNESIO CON IMÁGENES DIGITALES**

TESIS

MACIEL REYES FLORES

**PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER
EL GRADO DE**

MAESTRO EN CIENCIAS

Montecillo, Texcoco, estado de México

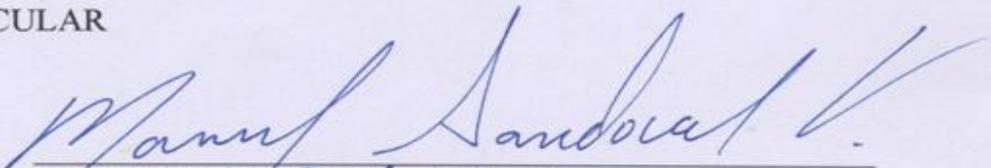
Septiembre de 2013

La presente tesis titulada: **Diagnóstico de deficiencias de nitrógeno y magnesio con imágenes digitales** realizada por el alumno: **Maciel Reyes Flores**, bajo la dirección del Consejo Particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS
EDAFOLOGÍA

CONSEJO PARTICULAR

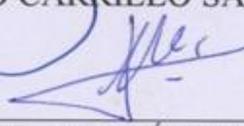
CONSEJERO


DR. MANUEL SANDOVAL VILLA

ASESOR


DR. JOSÉ ALFREDO CARRILLO SALAZAR

ASESOR


M.C. JORGE MANUEL VALDÉZ CARRAZCO

Montecillo, Texcoco, Estado de México, Septiembre de 2013

AGRADECIMIENTOS

A dios por prestarme la vida y darme la fuerza para lograr este sueño anhelado y guiarme en todo momento por el camino correcto.

Un profundo agradecimiento al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el financiamiento brindado para realizar los estudios de posgrado.

Al Dr. Manuel Sandoval Villa por la confianza brindada en este trabajo de investigación y por sus valiosas sugerencias en el escrito final.

Al Dr. José Alfredo Carrillo por la disposición que en todo momento me brindó en la elaboración de este trabajo.

Al M.C. Jorge Manuel Valdez Carrasco por la disposición y ánimo mostrado en todo momento.

Al Dr. Porfirio Ramírez Vallejo por facilitar las semillas de frijol para la realización de la investigación.

A la M. C. Juliana Padilla Cuevas por las facilidades prestadas en el Laboratorio de Fertilidad de Suelos y a Diana, Guille y Francisco por el apoyo técnico brindado al realizar las determinaciones químicas.

A los buenos profesores y amigos que de alguna manera influyeron en mi formación durante el periodo de la Maestría.

Maciel Reyes Flores

DEDICATORIAS

A mi padre Edwin Reyes Moreno por ser un gran hombre, un ejemplo a seguir y por la confianza que en todo momento me tuvo a pesar de la distancia, y a mi madre Bariflor Flores González por depositar su confianza en mí y por esas oraciones que tanto me han bendecido.

A mis abuelos Ángela Moreno Villatoro[†] y Adolfo Reyes Maldonado[†] quienes se sienten orgullosos de lo logrado en donde quiera que estén, gracias por educarme “Malita” siempre los recuerdo.

A mis abuelos José Antonio Flores Molina y Elvira González Mejía por su apoyo y cariño brindado.

A mis hermanos: Marvin, Angelita y Roxana por su cariño y quienes forman parte importante de mi vida.

DEDICATORIA ESPECIAL

A mí querida esposa e hijo:

Linda y Maximiliano

Por ser el motor que me impulsa a seguir adelante en los tropiezos de la vida.

LOS AMO

Contenido

RESUMEN	x
ABSTRACT	xi
I. INTRODUCCIÓN GENERAL	1
II. REVISIÓN BIBLIOGRÁFICA	4
2.1. Nutrición Mineral de las Plantas	4
2.2. Requerimiento de nutrientes para las plantas cultivadas	7
2.3. Deficiencias Nutrimientales en las Plantas	8
2.4. Nitrógeno	11
2.4.1. Síntomas de deficiencias del nitrógeno.....	12
2.5. Magnesio	13
2.5.1. Síntomas de deficiencias del magnesio	14
2.6. Principios Básicos de la Percepción Remota	15
2.6.1. Percepción remota.....	15
2.6.2. Interacción de la radiación con la materia	16
2.6.3. Propiedades de la radiación electromagnética	18
2.6.4. Espectro electromagnético	20
2.6.5. Firma espectral.....	22
2.7. Redes neuronales artificiales	25
2.8. Aplicaciones del análisis de imágenes	27
2.8.1. Representación del color	28
2.8.2. Modelo RGB	31
2.8.3. Modelo CIELab.....	31
2.8.4. Textura.....	33

2.8.5. Procesamiento de imágenes digitales.....	35
III. LITERATURA CITADA	37
IV. OBJETIVOS E HIPÓTESIS	42
V. DIAGNÓSTICO DE DEFICIENCIAS DE NITRÓGENO Y MAGNESIO CON IMÁGENES DIGITALES.....	43
RESUMEN	43
SUMMARY	44
INTRODUCCIÓN	45
MATERIALES Y MÉTODOS	47
RESULTADO Y DISCUSIÓN.....	49
CONCLUSIONES	58
LITERATURA CITADA.....	59
VI. REDES NEURONALES PARA CLASIFICAR DEFICIENCIAS DE NITRÓGENO Y MAGNESIO MEDIANTE CARACTERÍSTICAS TEXTURALES Y DE COLOR	61
RESUMEN	61
ABSTRACT.....	62
INTRODUCCIÓN	63
MATERIALES Y MÉTODOS	66
RESULTADOS	72
DISCUSIÓN	79
CONCLUSIONES	83
REVISIÓN BIBLIOGRÁFICA	84
VII. DISCUSIÓN GENERAL	86
VIII. CONCLUSIONES GENERALES.....	89

LISTA DE CUADROS

Cuadro 1. Descripción de los tratamientos para generar deficiencias conjuntas y separadas de nitrógeno y magnesio en plántulas de frijol.	47
Cuadro 2. Efecto de la interacción nitrógeno-magnesio (N-Mg) en los tratamientos sobre la concentración promedio de N y Mg en hojas de frijol recientemente maduras	51
Cuadro 3. Modelos para estimar la concentración de nitrógeno y magnesio en hojas de frijol recientemente maduras.....	58
Cuadro 4. Descripción de los cinco tratamientos.	66
Cuadro 5. Descripción de los ocho tratamientos.	67
Cuadro 6. Combinación de variables utilizadas en el proceso de entrenamiento y validación considerando cinco clases de salida (0% de N - 100% Mg; 100% de N - 0% Mg; 25% de N - 25% Mg; 50% de N - 50% Mg; y 100% de N - 100% Mg).....	72
Cuadro 7. Estadísticas del arreglo matricial de las variables R, G, B y CIEa.....	74
Cuadro 8. Grado de atribución al tratamiento equivocado para la combinación de variables R, G, B y CIE-a.....	75
Cuadro 9. Combinación de variables utilizadas en el proceso de entrenamiento y validación considerando ocho clases de salida (0% de N - 0% Mg; 0% de N - 100% Mg; 100% de N - 0% Mg; 25% de N - 25% Mg; 25% de N - 50% Mg; 50% de N - 25% Mg 50% de N - 50% Mg; y 100% de N - 100% Mg).	76
Cuadro 10. Imágenes digitales de los distintos tratamientos evaluados.	77

LISTA DE FIGURAS

Figura 1. Interacción básica entre la energía electromagnética y un cuerpo de agua (Lillesand y Klefer, 1994).....	16
Figura 2. Reflectancia espectral generalizada para árboles de hoja caduca y coníferas (Lillesand y Klefer, 1994).	18
Figura 3. Naturaleza de una onda de un haz de radiación electromagnética. a) onda polarizada plana que se propaga en el eje x. b) oscilaciones del campo eléctrico (Skoog <i>et al.</i> , 2004).	20
Figura 4. Espectro electromagnético, donde se indican los procesos moleculares representativos que ocurren cuando se absorbe luz.	22
Figura 5. Firma espectral de una vegetación sana (Chuvienco, 1995).....	23
Figura 6. Firmas espectrales de maíz etapa V4 con diferentes niveles de nitrógeno (Brizuela, 2007).	24
Figura 7. Firma espectral típica de distintas cubiertas (Chuvienco, 1995)	25
Figura 8. Esquema general de conexiones de una red neuronal (Ovando <i>et al.</i> , 2005).....	26
Figura 9. Representación espacial del modelo de color (RGB).	31
Figura 10. Modelo de color CIE-Lab	32
Figura 11. Concentración de nitrógeno y magnesio en tejido vegetal en función de la concentración de nitrógeno y magnesio en la solución nutritiva.	50
Figura 12. Comparación del índice de interacción de nitrógeno y magnesio.	52
Figura 13. Reflectancia de luz en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.	53
Figura 14. Valores CIE-Lab en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.	55
Figura 15. Valores de croma en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.	56
Figura 16. Valores de hue en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.	57

RESUMEN

La detección oportuna de deficiencias nutrimentales en hojas de plantas cultivadas permite tomar medidas correctivas inmediatas así como predecir rendimientos.

Las características espectrales y de textura de las imágenes se pueden utilizar para obtener información y correlacionarlos con el estado nutrimental de elementos esenciales que generan sintomatología similar en hojas de las plantas.

En la presente investigación se estableció un experimento para medir las propiedades espectrales y características texturales del cultivo de frijol con diferentes concentraciones de nitrógeno y magnesio de imágenes obtenidas con escáner. A partir de los valores de reflectancia se generaron modelos de regresión para asociar la concentración de nitrógeno y magnesio en el tejido vegetal. Además, los valores espectrales se relacionaron con características texturales utilizando redes neuronales para generar clasificadores que permitan conocer el comportamiento de las deficiencias mediante ésta técnica. Los modelos que presentaron mayor grado de asociación con respecto a la interacción de N-Mg fueron el CIE-b ($r^2 = 0.76$), croma ($r^2 = 0.75$), rojo, verde y CIE-L ($r^2 = 0.73$). El mejor clasificador generado por redes neuronales fueron las variables de colores R, G, B, CIE-a con un 89.8% de clasificaciones correctas correspondientes a los tratamientos. Pero también, las combinaciones de variables de colores con texturas produjeron clasificadores adecuados (1) con los espacios de color RGB y CIE-Lab (87.07%) y (2) con las cuatro características texturales y espacios de color RGB y CIELab (88.44). Los valores texturales presentan una mejora considerable cuando se utilizan en combinación con variables de color, que cuando se usan solos.

Palabras claves: *Reflectancia, discriminación, espacios de color, textura, redes neuronales.*

ABSTRACT

The opportune detection of nutrient deficiencies in plants grown leaves can take immediate corrective action as well as predict yields. The spectral characteristics and texture of the images can be used for information and correlate with nutritional status of essential elements that create similar symptoms in leaves of plants.

In the present investigation, an experiment to measure the spectral properties and textural characteristics of bean cultivation with different concentrations of nitrogen and magnesium from images obtained with scanner. From the reflectance values the regression models were generated to associate the magnesium concentration of nitrogen in the plant tissue. In addition, the spectral values related to textural features using neural networks to generate classifiers that reveal the behavior of the deficiencies by this technique. The models had a higher degree of association with respect to the interaction of N-Mg were the ICD-b ($r^2 = 0.76$), chroma ($r^2 = 0.75$), red, green and CIE-L ($r^2 = .73$). The best classifier neural networks were generated variables colors R, G, B, to a CIE-89.8% of correct classifications for treatments. But also, combinations of variables produced colors with textures suitable classifiers (1) with RGB color spaces and CIE-Lab (87.07%) and (2) with the four textural characteristics, and color spaces RGB and CIELab (88.44) . The textural values presented a considerable improvement when used in combination with variable color, which when used alone.

Keywords: *Reflectance, discrimination, color spaces, texture, neural networks.*

I. INTRODUCCIÓN GENERAL

La apariencia anormal de una planta puede estar relacionada, entre otras causas, a una deficiencia de algún elemento químico. Como consecuencia, el diagnóstico nutricional cobra mayor importancia y adquiere aun más valor cuando se emplean de manera preventiva (Etchevers, 1988).

Las técnicas convencionales de detección de desequilibrios nutrimentales (análisis químico de tejido vegetal y cuantificación semicuantitativa con ionómetros) son costosas, y en muchos casos lentas. Por lo tanto, es conveniente generar alternativas que contrarresten las desventajas de los análisis tradicionales. El análisis de imágenes digitales es un área que podría explotarse para la detección de deficiencias nutrimentales, a bajo costo.

La aparición de programas para analizar y procesar imágenes digitales en forma inmediata permite obtener información que puede ayudar a la solución de problemas industriales y científicos. Las imágenes pueden proporcionar suficientes detalles con alta resolución y un gran número de colores para la percepción humana y la interpretación.

La interacción de la radiación solar con compuestos de mayor importancia (clorofila, agua, proteínas) para el crecimiento y desarrollo de la planta, permiten obtener información espectral a partir de la reflectancia y absorbancia en diferentes longitudes de onda. Las deficiencias de nitrógeno y el magnesio afectan la formación de clorofila originando diferentes grados de clorosis. Por ello, utilizando la reflectancia puede identificarse el estrés nutrimental de la planta, mediante la firma espectral, con un sensor con suficiente resolución para distinguir su espectro de colores a partir de otros materiales.

Las imágenes digitales se han convertido en una tendencia en el análisis de color en las plantas en combinación con cámaras digitales, escáneres utilizando computadoras y el software adecuado para explorar la imagen y evaluar el color de las hojas con relativa facilidad y a un costo accesible (Murakami *et al.*, 2005).

Los espacios de color proporcionan un método para especificar, ordenar y manipular colores. Los colores se representan mediante puntos en el espacio de los vectores, que en la actualidad estos espacios de color son numerosos y la gran mayoría se han desarrollado para aplicaciones específicas, aunque todos parten de un mismo concepto: la teoría tricromática de colores primarios rojo, verde y azul (Ortiz, 2002).

Por otro lado, el análisis de textura describe la distribución de niveles de gris relativa al vecindario de cada píxel calculando variables estadísticas que describan propiedades como la variabilidad, el contraste, valor medio, etc. y que permitan obtener bandas de textura que puedan utilizarse de forma aislada o combinadas con bandas espectrales para clasificar las imágenes originales (Sarria *et al.*, 2003).

La información que proveen el color y la textura son valores que pueden ser analizados mediante redes neuronales (clasificadores) para predecir deficiencias de nutrimentos. Según Freeman y Skapura (1991) las redes neuronales se basan en una estructura de neuronas unidas por enlaces que transmiten información a otras neuronas, las cuales entregan un resultado mediante funciones matemáticas.

Por tal motivo, se realizó un experimento para diagnosticar distintos grados de deficiencia de nitrógeno y magnesio en plantas de frijol, dando pauta para generar una metodología que permita identificar deficiencias. Se obtuvieron modelos de regresión de las imágenes digitales en los espacios de color RGB y CIE-Lab, Cromo y Hue de hojas de frijol con las deficiencias de nitrógeno y magnesio en el

follaje. Además, se obtuvo las características texturales de los folíolos centrales de la hoja de frijol y en combinación con los colores se generaron clasificadores que permitan la identificación de deficiencias.

Estos resultados de esta investigación se presentan a manera de artículos, en siguiente orden:

V. DIAGNÓSTICO DE DEFICIENCIAS DE NITRÓGENO Y MAGNESIO CON IMÁGENES DIGITALES.

VI. REDES NEURONALES PARA CLASIFICAR DEFICIENCIAS DE NITRÓGENO Y MAGNESIO MEDIANTE CARACTERÍSTICAS TEXTURALES Y DE COLOR.

,

II. REVISIÓN BIBLIOGRÁFICA

2.1. Nutrición Mineral de las Plantas

Es bien sabido, que la mayoría de la vida terrestre depende de las plantas y de su capacidad para formar compuestos orgánicos a partir de constituyentes inorgánicos. Es por ello, que necesitan una fuente de suministro o sustancias llamadas nutrientes esenciales para poder llevar a cabo la fotosíntesis, y así producir energía (Wiedenhoeft, 2006). Al respecto Lambers *et al.* (2008) mencionan que después del agua, los nutrientes son el factor ambiental que más fuertemente limita la productividad de prácticamente todos los ecosistemas naturales.

La nutrición mineral, que se refiere al suministro, disponibilidad, absorción, traslocación y utilización de elementos inorgánicamente formados para el crecimiento y desarrollo de las plantas (Fageria, 2009), cobra gran importancia en la producción de cultivos, ya que gran parte de las cosechas dependen de la capacidad de los suelos para abastecer las necesidades del cultivo de interés. Si bien es cierto, la nutrición mineral es solamente un componente del sistema de producción, no deja de ser uno de los más importantes ya que en gran medida la calidad de la producción es función de ésta.

Según Fageria (2009), en el proceso de producción de cultivos, la nutrición mineral junto con la disponibilidad del agua, el control de plagas, enfermedades y malezas y las condiciones socioeconómicas del agricultor son componentes que juegan un papel importante para lograr una mayor productividad.

Las raíces de las plantas son las encargadas de transportar los nutrientes inorgánicos a partir del suelo y traslocarlos a diferentes partes de las plantas, donde son utilizados en diversas funciones biológicas. El área de superficie que abarcan las raíces y su habilidad de absorber los iones inorgánicos a bajas

concentraciones de la solución del suelo, hacen que la absorción mineral de las plantas sea un proceso muy eficaz (Taiz y Zeiger, 2002).

Las plantas manifestaran deficiencias nutrimentales cuando el suministro de estos no es suficiente en el sistema, por lo tanto, se presentaran desórdenes metabólicos, que se reflejaran en síntomas de deficiencia.

Para lograr rendimientos adecuados en la agricultura es necesario conocer el suelo para conocer los niveles de nutrientes. Esto se logra mediante un análisis de suelo, sin dejar a un lado los análisis de tejido vegetal durante el desarrollo del cultivo.

La concentración de nutrientes minerales en el tejido vegetal cambia durante el crecimiento y desarrollo de las plantas, por lo que es necesario identificar las etapas en que los nutrientes influyen sobre el rendimiento. De aquí, la necesidad de conocer el suelo como medio de cultivo y la fenología del cultivo de interés.

Las plantas, para su adecuado desarrollo necesitan de macro y micronutrientes que permitirán que las plantas cumplan con su ciclo de vida. Estos nutrientes minerales generalmente se encuentran en bajas concentraciones en el suelo, y su disponibilidad es función de ambiente, clima (precipitación, temperatura, viento etc.) y de propiedades físico-químicas (erosión, tipo de suelo y el pH del suelo). Las cantidades adecuadas de estos nutrientes afectan en gran medida el crecimiento y desarrollo de los cultivos en la agricultura moderna (Maathuis y Diatloff, 2013).

Para lograr altos rendimientos en la agricultura es necesario, junto con otros factores, la fertilización con nutrientes minerales. La fertilidad de los suelos juega un papel importante para aumentar o mantener máximos rendimientos con el menor costo económico. No hay que olvidar, que la agricultura es un complejo de relaciones entre la planta – suelo – atmósfera – agua – hombre.

Un suelo fértil es aquel que constituye un medio en el que las plantas puedan desarrollarse; para lo cual cumple con requisitos desde el punto de vista físico, químico, biológico, mineralógico, morfológicos y pedológicos, así como sus cualidades de fertilidad, topográficas, de drenaje y productividad.

La productividad de un suelo no solamente está dada por la fertilidad, intervienen otros factores para lograr las condiciones en el suelo para que se desarrollen las especies cultivadas, como:

- Una textura moderada, suelo profundo, topografía no mayor a 3%, buen drenaje para evitar encharcamientos y problemas de salinidad.
- Porcentaje de materia orgánica que oscile entre 2-4%.
- Adecuado nivel de humedad, cercano a capacidad de campo.
- ph cercano a la neutralidad.
- Abastecimiento adecuado en cantidad y frecuencia de nutrimentos que no causen deficiencias ni toxicidad.

Con un suelo de con estas características es alta la probabilidad de obtener altos rendimientos. También hay que considerar que la obtención de buenos rendimientos no es solamente por la utilización de fertilizantes, sino que posiblemente a la adopción de mejores métodos de cultivos, variedades mejoradas, combate de malas hierbas y sobre todo un buen manejo.

2.2. Requerimiento de nutrientes para las plantas cultivadas

En los tejidos de las plantas se pueden encontrar más de 90 elementos, de los cuales solamente 17 son considerados esenciales para su crecimiento, desarrollo y producción.

Estos nutrientes se dividen en elementos en nutrimentos presentes en la atmósfera y el agua: carbono (C), hidrógeno (H), oxígeno (O). El otro grupo son los macronutrimentos: nitrógeno (N), fósforo (P), potasio (K), calcio (Ca), magnesio (Mg) y azufre (S). El tercer grupo lo constituyen los micronutrimentos que participan en la activación de enzimas: zinc (Zn), cobre (Cu), hierro (Fe), manganeso (Mn), boro (B), molibdeno (Mo), cloro (Cl) y níquel (Ni). Tanto macro y micronutrimentos las plantas los absorben de la solución del suelo.

De acuerdo con los criterios de esencialidad de Arnon y Stout (1939) un elemento es esencial porque las plantas no pueden completar su ciclo de vida en ausencia de este, son insustituibles por otros elementos, y están directamente involucrados en el metabolismo de la planta.

Para esto, Epstein y Bloom (2005) utilizan dos criterios para que un elemento se considere esencial. El primero, es que el nutriente es parte de una molécula que es un componente intrínseco de la estructura o el metabolismo de una planta, y el segundo, que la planta llegará a presentar anormalidad en su crecimiento y desarrollo cuando el nutriente en cuestión no esté presente en el medio donde crece y se desarrolla la planta.

Resulta útil en el ámbito agronómico conocer la importancia de los elementos esenciales ya que su deficiencia aguda obstaculiza el desarrollo vegetal, produciendo síntomas claros de carencia, tal es el caso de los nutrientes N y Mg que se estudiaron en este trabajo y que tal deficiencia puede remediarse con suministro antes de que el metabolismo y la cosecha se dañen irreversiblemente.

Lambers *et al.* (2008) menciona que el N, P y K son los principales nutrientes que limitan el crecimiento de las plantas y por lo consiguiente sus cosechas. Las concentraciones de los nutrientes minerales en los tejidos de las plantas van a diferir dependiendo del ambiente y de los escenarios donde se desarrollan, al igual que la capacidad para adquirir nutrientes desde el suelo y la cantidad de nutrientes que se necesitan para el crecimiento. Por lo tanto, las plantas que se desarrollan en un ambiente favorable tendrán altas concentraciones de N, P y K en sus tejidos.

Antes de que el nutriente esté disponible, para posteriormente ser absorbido o utilizado por la planta, debe ocurrir una serie de procesos en el sistema suelo-planta. Primeramente, el nutriente debe estar en el suelo, ya sea por aplicación de fertilizante o porque ya existe en el suelo. Enseguida debe ocurrir transporte desde el suelo hacia las raíces de las plantas y posteriormente transporte a la parte aérea de la planta y, por último, la utilización por parte de la planta para la producción de cosechas (Fageria, 2009).

Los procesos que se mencionan anteriormente, son afectados por factores tal como el clima, suelo, planta y su interacción. Estos factores, varían de región a región e inclusive dentro de la misma región (Fageria, 2009).

2.3. Deficiencias Nutrimientales en las Plantas

Para Stevens *et al.* (2002) una deficiencia se produce cuando un elemento esencial no está disponible en cantidad suficiente para satisfacer las necesidades de la planta en crecimiento, afectando la calidad de la misma. Y que la presencia de deficiencias está en función de varios factores como el edáfico, genotípico, climático y los factores culturales, los cuales interactúan para influir en la disponibilidad de nutrientes para las plantas de cultivo a lo largo de la temporada de crecimiento.

Epstein (1972) considera que si uno de los elementos químicos esenciales para la vida de una planta se encuentra en cantidades insuficientes en el medio donde se desarrolla, esta presentará deficiencia de este elemento en las células de la planta que producirá trastornos en su metabolismo. Tales trastornos, y dependiendo de la gravedad de la deficiencia, de la especie en particular y de otros factores ambientales, se manifestarán retrasando el crecimiento, ocasionando amarillamiento o necrosis de hojas u otras anomalías.

Según Fageria (2009) el comportamiento de las necesidades de nutrientes de los cultivos dependen del nivel de rendimiento, las especies de cultivos, cultivar o genotipos dentro de cada especie, tipo de suelo, las condiciones climáticas y la biología del suelo. También menciona, que las deficiencias de nutrientes en las plantas pueden deberse a la erosión del suelo, lixiviación de nutrientes a un perfil más bajo, infestación de enfermedades, insectos, malas hierbas, deficiencia de agua y bajas aplicaciones de fertilizantes.

También hay que recordar, que indistintamente del suelo, las plantas y los factores climáticos y sus interacciones, un factor adicional que puede limitar las necesidades de los nutrientes es el valor económico de un cultivo y el nivel socioeconómico del agricultor.

Wiedenhoeft (2006) menciona que cuando las plantas sufren deficiencias presentan evidentes respuestas fisiológicas que pueden ser fácilmente observables. La deficiencia más común es la clorosis, que es un amarillamiento de las hojas y otras partes verdes de la planta. Esta clorosis, puede aparecer intervenal o generalizada en toda la hoja y en casos extremos las hojas afectadas pueden caer.

A esta respuesta fisiológica de la planta que obedece a una deficiencia, se le llama síntoma. Tales síntomas, pueden ocurrir en tres patrones principales: localizada

en tejidos más jóvenes, localizada en tejidos maduros y ampliamente distribuidos a través de la planta.

Las deficiencias de N y Mg, por ser dos elementos móviles, se van a manifestar primeramente en hojas viejas, esto debido a que los nutrimentos en cuestión se traslocan a las hojas jóvenes.

La forma en que estas deficiencias se encuentran distribuidas en la planta puede facilitar su identificación y corrección antes que provoque daños irreversibles en el cultivo, previo conocimiento de las deficiencias de cada nutrimento.

Taiz y Zeiger (2002) resumen que los síntomas de deficiencia de nutrientes en la planta son la expresión de trastornos metabólicos que resultan del insuficiente suministro del elemento esencial. Tales trastornos, están relacionados con las funciones del elemento esencial en el metabolismo y la función en una planta normal.

Para la identificación de trastornos nutrimentales, Fageria (2009) propone cuatro criterios: 1) síntomas de deficiencia visual, 2) análisis de suelo, 3) análisis de tejido vegetal y 4) las respuestas de los cultivos a los productos químicos fertilizantes o abonos orgánicos.

Normalmente, las plantas manifestarán a cierto grado la deficiencia de un elemento. Esto, resulta en algo complejo al momento de diagnosticar la salud de la planta, ya que cada nutriente tiene diferentes funciones biológicas, que a su vez tiene un conjunto independiente de interacciones con un sinnúmero de parámetros ambientales. Estas deficiencias en la planta pueden ser agudas o crónicas. Una deficiencia aguda, se manifiesta en la ausencia repentina de un nutriente en una planta en desarrollo que puede provocar daños irreversibles. Mientras que una deficiencia crónica, se presenta cuando hay una tasa de abastecimiento limitado

del nutriente que es insuficiente para la demanda de la planta, que puede provocar retrasos en el crecimiento (Taiz y Zeiger, 2010).

Existe gran relación entre la movilidad del nutriente y tasa de crecimiento de la planta (Taiz y Zeiger, 2010) lo que conduce al tipo y ubicación de una posible deficiencia. Los síntomas que aparecen primeramente en hojas maduras o viejas generalmente son debidos a deficiencias de nutrientes móviles tal como el nitrógeno y potasio. Con esto, la planta busca proteger los tejidos jóvenes en crecimiento, sacrificando la salud de los tejidos viejos (Wiedenhoeft, 2006).

2.4. Nitrógeno

Mengel y Kirkby (1987) clasifican los nutrientes minerales de las plantas de acuerdo con su función bioquímica. El nitrógeno junto con el azufre, se encuentra ubicado en el grupo 1, llamado el grupo de **nutrientes que son parte de los compuestos de carbono**. Esto, porque el nitrógeno es constituyente de aminoácidos, amidas, proteínas, ácidos nucleicos, nucleótidos, coenzimas, hexoaminas, etc.

El nitrógeno, es uno de los 17 elementos que requieren las plantas para su pleno desarrollo. Es absorbido en formas de nitratos (NO_3^-) y amonio (NH_4^+). La mayoría de las plantas lo absorben como nitratos y en excepciones, como el cultivo de arroz, lo absorben como amonio. Sin embargo, algunos cultivos usan cantidades de NH_4^+ si es que éste está presente en el suelo.

El nitrógeno, considerado como el motor de crecimiento de las plantas, también desempeña un papel fundamental en la estructura de la clorofila. La carencia del nitrógeno en la clorofila no permite que la planta utilice la luz solar como fuente de energía en el importante proceso de la fotosíntesis, y por consecuencia la planta perderá la habilidad de absorber otros nutrientes. Lo anterior, junto con su papel

estructural en aminoácidos, explica porque las plantas necesitan grandes cantidades de nitrógeno y porqué a menudo es el nutriente limitante en el crecimiento de las plantas (Wiedenhoeft, 2006).

2.4.1. Síntomas de deficiencias del nitrógeno

En ecosistemas naturales y agrícolas, la disponibilidad del nitrógeno en los suelos, limita frecuentemente la productividad de las plantas por las cantidades en que es requerido. Tal deficiencia, afecta en diferentes grados el metabolismo de la planta, ya que el nitrógeno es un elemento esencial para todos los seres vivos y es un componente específico de las proteínas que está presente en la mayor parte de las combinaciones orgánicas de las plantas (Navarro y Navarro, 2003).

El nitrógeno, en cantidades adecuadas, produce hojas de color verde oscuro, debido a que éstas tienen una alta concentración de clorofila, y aumenta el área foliar al ser mas grandes las hojas.

La deficiencia de nitrógeno inhibe rápidamente el crecimiento de las plantas, en consecuencia van manifestar por primera vez en las hojas maduras una clorosis y, de tratarse de una deficiencia grave las hojas presentan un amarillo completamente y caerán de las plantas. Las hojas con mayor madures, exportarán el nitrógeno a los tejidos en crecimiento activo, dejando a las hojas maduras mostrar los signos de deficiencia. Por lo tanto, esta deficiencia provocará una reducción en la productividad y vigor.

Las plantas, que se desarrollan bajo la limitación del nitrógeno, presentarán hojas cloróticas a cierto grado, que tan pronto reciba el aporte de nitrógeno se tornaran nuevamente al color verde característico.

2.5. Magnesio

De acuerdo con Mengel y Kirkby (1987) el magnesio se encuentra clasificado en el grupo 3, llamado “nutriente que se mantienen en forma iónica”. La importancia de este elemento es por su requerimiento por muchas enzimas que intervienen en la transferencia de fosfato y, además porque es constituyente de la molécula de clorofila y está implicado en la síntesis de ácidos nucleicos.

El magnesio, considerado como el elemento olvidado, es esencial para el crecimiento y desarrollo vegetal y que se pasa por alto con demasiada frecuencia (Mikkelsen, 2010).

El magnesio interviene en funciones vitales de las plantas. Los procesos y reacciones en las que interviene son los siguientes (Cakmak y Yazici, 2010): 1) fotofosforilación (formación de ATP en los cloroplastos), 2) fijación fotosintética del dióxido de carbono (CO₂), 3) síntesis de proteínas, 4) formación de clorofila, 5) recarga del floema, 6) partición y asimilación de los productos de la fotosíntesis, 7) generación de formas reactivas de oxígeno y 8) fotooxidación de los tejidos de las hojas.

El magnesio que es un catión divalente, su papel está más ligado a funciones intracelulares, contrariamente a las funciones extracelulares del calcio. Se considera, el mineral más importante en la activación de enzima que intervienen en la respiración, es un elemento estructural central de la clorofila y está implicado en la síntesis de ácidos nucleicos (Wiedenhoeft, 2006).

El magnesio es absorbido por la planta como Mg²⁺. Normalmente, la concentración de magnesio en la planta oscila alrededor del 0.5% del peso seco, y aunque es un constituyente de la molécula de clorofila, pigmento esencial para que las plantas verdes lleven a cabo el proceso de fotosíntesis, solamente del 10-12% del total de la planta representa el magnesio clorofílico (Navarro y Navarro, 2003).

Wiedenhoeft (2006) menciona que la fotosíntesis se lleva a cabo en el organelo llamado cloroplasto que está expuesto directamente a la luz solar. En los cloroplastos, es donde se concentran muchos de los nutrientes que las plantas necesitan. En él se encuentran almacenados considerables cantidades de nitrógeno, hierro y magnesio. El nitrógeno y el magnesio son necesarios para que se forme la clorofila de lo contrario el color verde normal de las plantas se verán reducidos, resultando en una clorosis. Mientras que la principal labor del hierro es la recolección de complejo de energía, por el cual la luz solar es convertida en energía química.

2.5.1. Síntomas de deficiencias del magnesio

El magnesio (Mg^{2+}) es un macronutriente esencial para el crecimiento y desarrollo de la mayoría de las plantas y un abastecimiento adecuado en el suelo es importante para obtener rendimientos económicos altos (Fageria, 2009).

El magnesio disminuye su solubilidad en pH ácidos y alcalinos. En el caso de pH bajos, el magnesio puede ir acompañado con toxicidad con metales pesados (Wiedenhoeft, 2006).

La deficiencia de magnesio se presenta en suelos de textura gruesa de regiones húmedas en donde existe baja capacidad de intercambio catiónico. Su disponibilidad y comportamiento en las plantas es parecido al calcio, con la diferencia que se necesita en cantidades más pequeñas. Su disponibilidad principalmente está dada por la concentración de Mg^{2+} en la solución del suelo, grado de saturación de Mg^{2+} , presencia de otros cationes como el K^+ , y Ca^{2+} , pH del suelo, el tipo de arcilla y plantas (Fageria, 2009).

Las hojas maduras deficientes de magnesio presentan una clorosis intervenal, esto producto de la disminución de clorofila en las hojas ocasionado por la inhibición de síntesis de proteínas.

Para Wiedenhoeft (2006) las hojas deficientes de magnesio presentan áreas cloróticas moteadas entre las nervaduras, la superficie de la hoja puede presentar arrugadas que posteriormente se desarrollará una necrosis en el tejido clorótico. Esta deficiencia puede llegar a tener un parecido a la deficiencia de potasio.

2.6. Principios Básicos de la Percepción Remota

2.6.1. Percepción remota

Lillesand y Klefer (1994) definen percepción remota como la ciencia y el arte de obtener información acerca de un objeto, superficie o fenómeno a través del análisis de los datos adquiridos por un dispositivo que no está en contacto directo con el objeto de estudio. Sin embargo, la percepción remota no solamente engloba los procesos de obtención de imágenes por cualquier medio, sino que incluye el procesamiento y tratamiento de imágenes para obtener una determinada aplicación en un área específica (Soria, 1998).

Esta definición, permite que los sensores se asocien específicamente con la medición de las interacciones entre los materiales de una superficie de estudio con la energía electromagnética.

La finalidad de los sensores remotos, consiste en la medición de la energía a lo largo del espectro electromagnético. Pero las principales regiones de estudio con mayor interés son las regiones de la luz visible, infrarroja reflejada y emitida. La medición de la radiación en el espectro electromagnético se llama bandas espectrales. Cada banda espectral es un intervalo de comportamiento similar en el espectro electromagnético.

2.6.2. Interacción de la radiación con la materia

Para llevarse a cabo la percepción remota, es necesario que entre el objeto y el sensor exista una interacción, y el encargado de ponerlos en relación es el flujo energético.

Cuando la energía electromagnética incide sobre una superficie varias fracciones de la energía incidente se reflejan, absorben y transmiten (Figura 1), y se relacionan mediante el principio de conservación de energía (Lillesand y Klefer, 1994).

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda)$$

Donde E_I denota la energía incidente, E_R la energía reflejada, E_A la energía absorbida y E_T la energía transmitida.

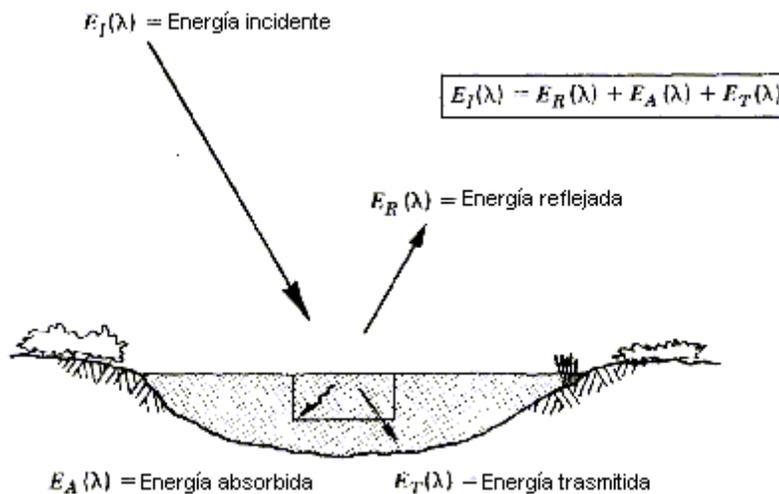


Figura 1. Interacción básica entre la energía electromagnética y un cuerpo de agua (Lillesand y Klefer, 1994).

La proporción de energía reflejada, absorbida y transmitida por una superficie va a variar dependiendo del material, de las condiciones y de las longitudes de ondas en que se encuentre, permitiendo que existan diferencias distinguibles en una imagen. Algunos sensores remotos funcionan en regiones de longitud de ondas en la que predomina la energía reflejada, por ello se pueden medir las características de reflectancia mediante la medición de la proporción de la energía incidente que es reflejada (Lillesand y Klefer, 1994).

$$R_{\lambda} = \frac{E_R(\lambda)}{E_I(\lambda)} * 100$$

Donde R_{λ} es la reflectancia de espectral expresada en porcentaje, $E_R(\lambda)$ es la energía de longitud de onda reflejada por el objeto y $E_I(\lambda)$ es la energía de longitud de onda incidente sobre el objeto.

La gráfica de la reflectancia de un objeto, como una función de la longitud de onda, es llamada curva de reflectancia espectral. La configuración de una curva de reflectancia espectral nos da una idea de las características espectrales de un objeto y tiene una fuerte influencia en la elección de las regiones de longitud de onda en la que el sensor adquiere los datos para una aplicación en particular (Lillesand y Klefer, 1994). En la Figura 2 se muestran las curvas de reflectancia espectral altamente generalizadas para árboles de hojas caducas y coníferas.

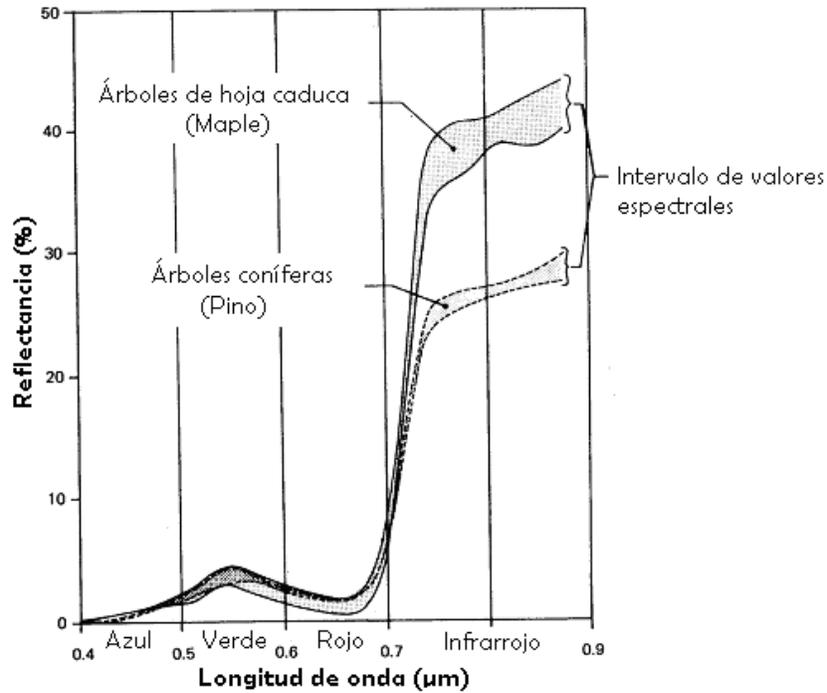


Figura 2. Reflectancia espectral generalizada para árboles de hoja caduca y coníferas (Lillesand y Klefer, 1994).

2.6.3. Propiedades de la radiación electromagnética

La radiación electromagnética es una forma de energía (luz) que se transmite por el espacio a enorme velocidad ($2.99792 \times 10^8 \text{ m s}^{-1}$) a través de paquetes discretos de energía o partículas llamados fotones o cuantos. La radiación electromagnética, se puede describir también como una onda con longitudes de onda, frecuencia, velocidad y amplitud. Estas dos teorías son complementarias. Como se muestra en la Figura 3, la radiación electromagnética se puede presentar como campos eléctricos de una onda sinusoidal de una sola frecuencia en el espacio y tiempo y el campo eléctrico se representa como un vector, cuya longitud es proporcional a la fuerza del campo (Skoog *et al.*, 2004).

La *amplitud* de la onda sinusoidal es la longitud del vector del campo eléctrico en el punto máximo de la onda, la *longitud de onda* (λ) se define como la distancia entre dos crestas adyacentes (o puntos máximos sucesivos) y la *frecuencia* (ν) es

el número de oscilaciones del vector del campo eléctrico por unidad de tiempo (Figura 3). La relación entre frecuencia y longitud de onda está dada por la siguiente fórmula:

$$C = \lambda v$$

Donde C es la velocidad de la luz (2.99792×10^8 m s⁻¹), λ longitud de onda y v es la frecuencia (ciclos/segundo).

Harris (2007) menciona que es conveniente concebir a la luz como partículas llamadas *fotoes*. Cada fotón transporta la energía, E , dada por

$$E = hv$$

Donde h es la constante de Planck (6.63×10^{-34} J s), v la frecuencia.

La ecuación anterior afirma que la energía es proporcional a la frecuencia. Se puede calcular la cantidad de energía transportada por un fotón siempre y cuando se conozca su frecuencia.

Por lo tanto, la energía de un fotón es inversamente proporcional a la longitud de onda y está relacionada con la frecuencia y la longitud de onda de la radiación electromagnética, y se puede describir de la siguiente manera:

$$E = \frac{hc}{\lambda} = hv$$

Donde h es la constante de Planck (6.63×10^{-34} J s), v la frecuencia, c la velocidad de la luz y λ la longitud de onda.

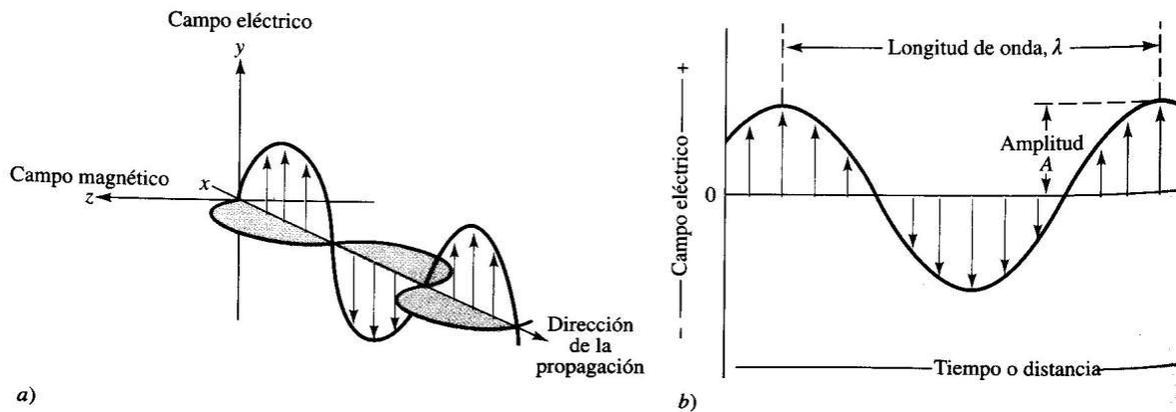


Figura 3. Naturaleza de una onda de un haz de radiación electromagnética. a) onda polarizada plana que se propaga en el eje x. b) oscilaciones del campo eléctrico (Skoog *et al.*, 2004).

Concluimos que un haz de luz es el flujo de partículas de energía llamadas fotones. Cada una de estas partículas posee una energía característica que está relacionada con la frecuencia de la luz. La luz, de una cierta frecuencia (o longitud de onda) está asociada con los fotones, cada uno de los cuales posee una cantidad definida de energía. La cantidad de energía que posee un fotón, es la que determina si una cierta especie molecular absorberá o emitirá la luz de la longitud de onda correspondiente.

2.6.4. Espectro electromagnético

La interacción de la materia con la radiación se verifica en la totalidad del espectro electromagnético (Figura 4), nombre que se le da a la organización de las bandas de longitudes de onda o frecuencias. Comprende las radiaciones de longitudes de radiaciones más cortas (rayos cósmicos) hasta las ondas de radio que poseen longitudes de onda superiores a los 1000 km. La naturaleza de estas radiaciones es la misma, y todas se desplazan a la velocidad de la luz. Las radiaciones solo se

diferencian en la longitud de onda y frecuencia y en los efectos que pueden producir (Willard, 1986).

Podemos describir las bandas espectrales utilizadas en la percepción remota como sigue:

- *Espectro visible (0.4-0.7 μm)*: Es la única radiación que pueden percibir el ojo humano. Se distinguen tres bandas elementales:
 - Azul (0.4-0.5 μm): El agua absorbe cada vez más radiación electromagnética en longitudes de onda más largas, esta banda proporciona los mejores datos para el mapeo de la profundidad de zonas cubiertas con agua. También se utiliza para la discriminación del suelo-vegetación y la cartografía forestal.
 - Verde (0.50-0.60 μm): La región azul-verde del espectro corresponde a la absorción de la clorofila de una vegetación sana y es útil para el detalle de mapeo tales como la profundidad o sedimentos en los cuerpos de agua. Características como las carreteras y edificios también aparecen en esta banda.
 - Rojo (0.60-0.70 μm): La clorofila absorbe estas longitudes de onda en la vegetación saludable. Por lo tanto, esta banda es útil para distinguir las especies de plantas, así como el suelo.
- *Infrarrojo cercano (0.7–1.3 μm)*: Se utiliza para discriminar la vegetación y concentraciones de humedad.
- *Infrarrojo medio (1.3-8.0 μm)*: En esta región se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre.
- *Infrarrojo lejano o térmico (8.0-14 μm)*: Esta región del espectro está dominado totalmente por la radiación emitida por la tierra y ayuda a dar cuenta de los efectos de la absorción atmosférica, dispersión, y la emisión. Es útil para la detección de estrés de cultivos, la intensidad del calor, las aplicaciones de insecticidas, la contaminación térmica, y la cartografía

geotérmica. Este canal se utiliza comúnmente para medir la temperatura del agua superficial.

- *Microondas (a partir de 1 mm)*: Las microondas pueden penetrar las nubes, la niebla y la lluvia. El radar es la forma activa de la obtención de imágenes.

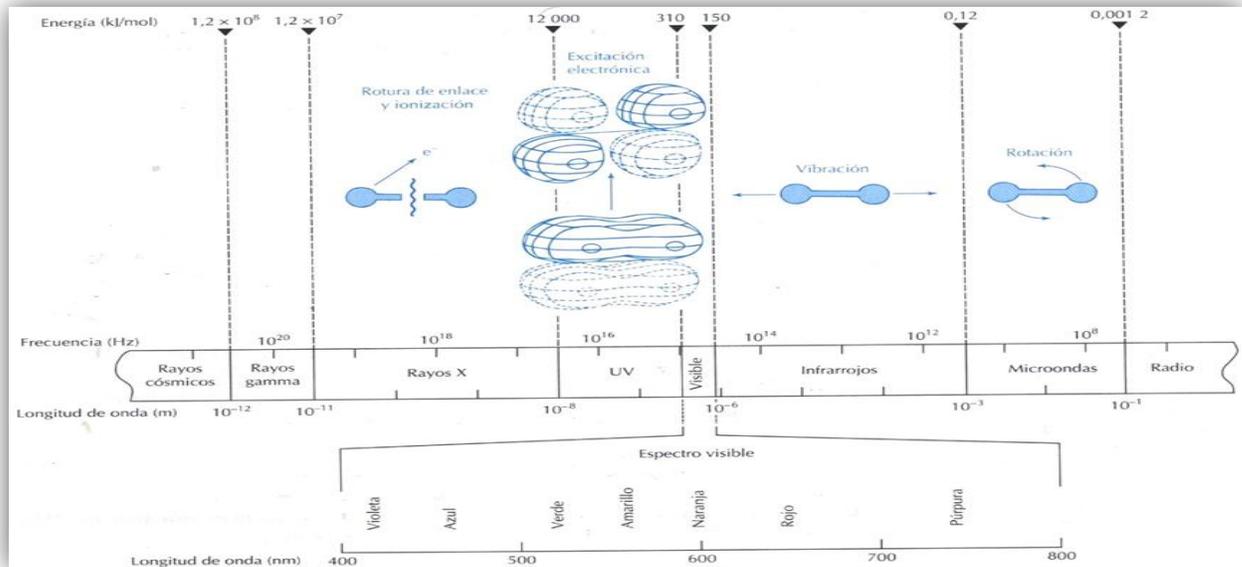


Figura 4. Espectro electromagnético, donde se indican los procesos moleculares representativos que ocurren cuando se absorbe luz.

2.6.5. Firma espectral

La identificación de las características de los objetos de estudio es la base de los sensores remotos. Esto, gracias a la construcción de *signatura espectral* o *firma espectral*. La firma espectral, es la respuesta en términos de radiación reflejada o emitida por el objeto en cada intervalo de longitudes de onda y es propia de cada composición química.

Las propiedades particulares de cada material producen una distribución específica de la reflectancia en diferentes longitudes de onda, generando un

patrón único conocido como firma espectral. Las firmas están afectadas por las características del objeto que originan su interacción con la energía electromagnética y son distintas según las longitudes de onda (Soria *et al.*, 1998).

Según Chuvieco (1995) las firmas espectrales de los objetos presentan dificultades a causa de los factores que influyen en la radiancia final detectada por el sensor. Se debería de considerar la reflectividad de la hoja en base a su estado fenológico, forma y contenido de humedad, algunas características morfológicas (altura, perfil, grado de cobertura en el suelo, etc) de las plantas y por último la situación geográfica de la planta (pendiente, orientación, geometría de plantación, etc.).

En la Figura 5 se muestra el comportamiento típico de una vegetación sana. Se observa una baja reflectividad en las bandas visibles roja y azul (0.4-0.5 y 0.60-0.70 μm , respectivamente) debido a la absorción de los pigmentos de las hojas, y un incremento de la reflectancia en la porción del verde (en torno a 0.55 μm).

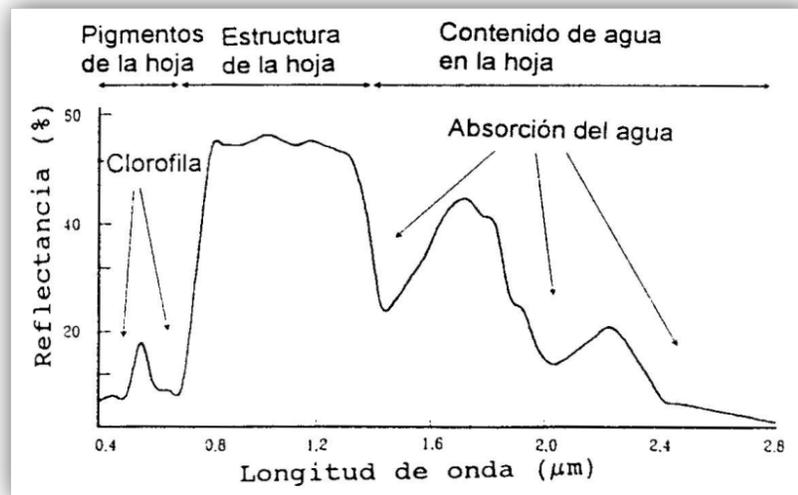


Figura 5. Firma espectral de una vegetación sana (Chuvieco, 1995).

Las firmas espectrales son una herramienta que permite obtener información del estado fisiológico de la planta asociando la concentración de nitrógeno con el

contenido de clorofila, esto en tiempo real, de una forma sencilla, rápida y económica antes de que la deficiencia se presente visualmente (Brizuela, 2007).

En el cultivo de Maíz, se obtuvieron firmas espectrales en diferentes etapas vegetativas (V1 a la V4). Particularmente, en la etapa vegetativa V4 con dosis crecientes de nitrógeno, se encontró que el déficit de nitrógeno está altamente correlacionado con una reducción en la concentración de clorofila y por lo tanto se incrementa la reflectancia del verde (Figura 6).

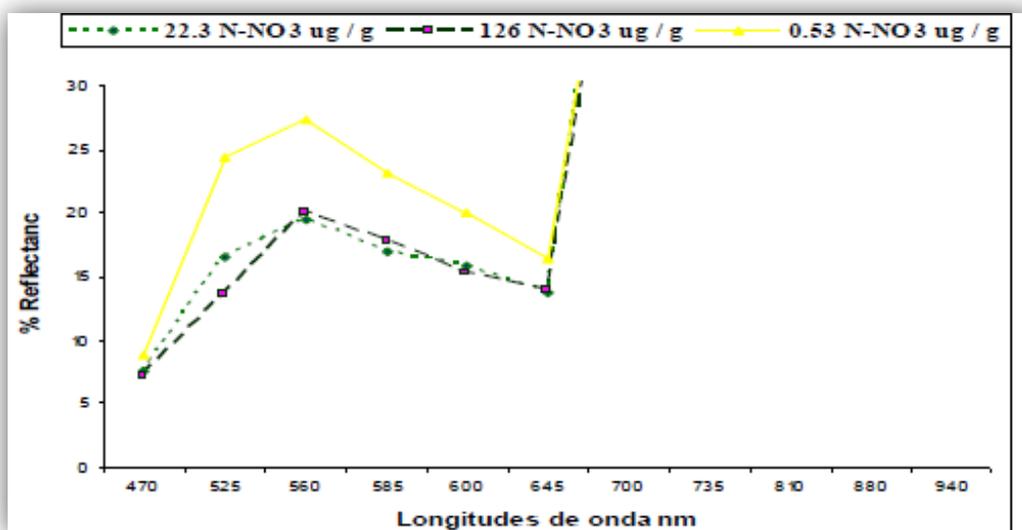


Figura 6. Firmas espectrales de maíz etapa V4 con diferentes niveles de nitrógeno (Brizuela, 2007).

Según Soria et al. (1998) todo objeto en la naturaleza posee una distribución única de radiación reflejada, transmitida y absorbida. Estas características espectrales pueden ser usadas para distinguir un objeto de otro o para obtener información acerca de la forma, tamaño y otras propiedades físicas y químicas (Figura 7).

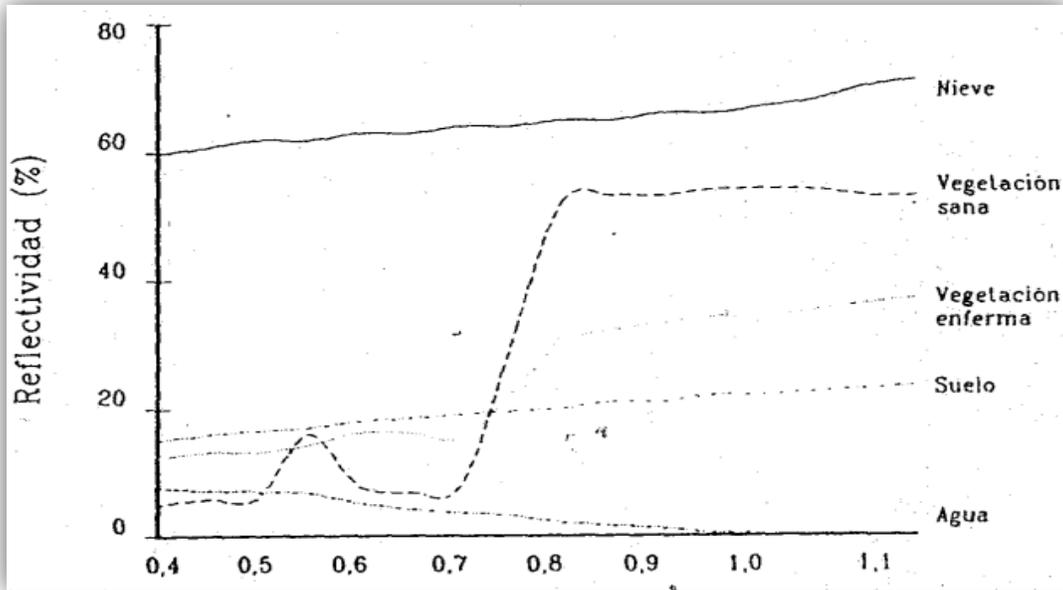


Figura 7. Firma espectral típica de distintas cubiertas (Chuvieco, 1995)

2.7. Redes neuronales artificiales

Una red neuronal se puede definir como un sistema de procesamiento de información que consta de un gran número de elementos simples interconectados llamados neuronas que procesan la información respondiendo dinámicamente frente a estímulos externos. Estas neuronas, análogas a las biológicas del cerebro humano intentan interactuar con los objetos del mundo real por lo tanto son capaces de aprender tal como lo hacen las personas (Diez *et al.*, 2001).

Para Ovando *et al.* (2005) una red neuronal artificial es un entramado o estructura formada por nodos o neuronas, que se conectan entre sí y tienen la capacidad de recibir datos de entrada y producir una salida. La cantidad de neuronas de la capa de salida va a depender del problema que se pretende resolver. En la Figura 8 se observa un esquema general de conexiones de una red neuronal. Durante la fase entrenamiento de la red, se determinan los pesos de las conexiones W_{ij} que a su vez se conectan a las neuronas de entrada con las de la capa oculta y w_j para la

transferencia entre la capa oculta y la de salida. El entrenamiento concluye cuando la red es capaz de reproducir las salidas conocidas para los parámetros de entrada, con un error mínimo arbitrario.

La segunda fase consiste en realizar la validación de la red diseñada con otro conjunto de datos para los cuales se conocen los resultados, a fin de comprobar la eficiencia de la misma.

La finalidad de las redes neuronales, según Flores y Fernández (2008), es emular el comportamiento del cerebro humano, caracterizado por el aprendizaje a través de la experiencia y la extracción de conocimiento genérico a partir de un conjunto de datos.

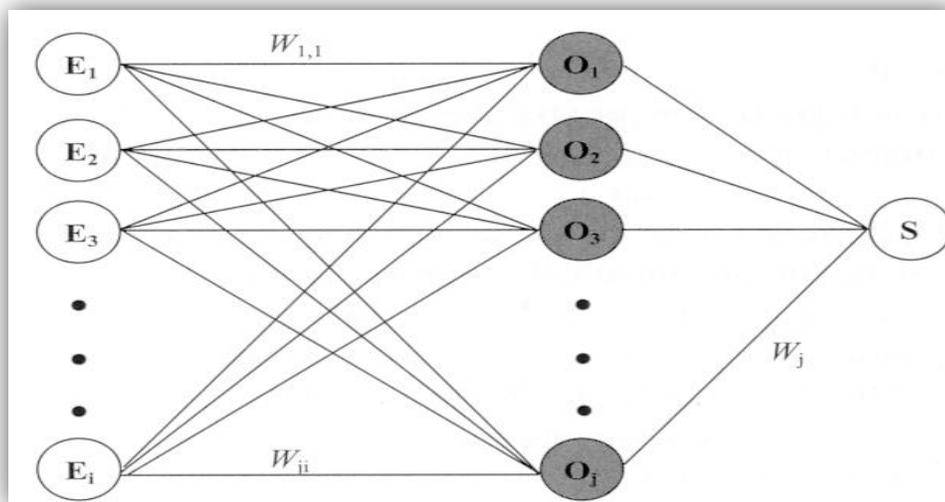


Figura 8. Esquema general de conexiones de una red neuronal (Ovando *et al.*, 2005).

Las redes neuronales se utilizan, normalmente, como elementos clasificadores o memorias asociativas, asociando una serie de patrones de entrada con patrones de salida. Para ello se entrena la red, alterando los pesos de las interconexiones de acuerdo a la relación deseada.

Según Freeman y Skapura (1991) las redes neuronales se basan en una estructura de neuronas unidas por enlaces que transmiten información a otras neuronas, las cuales entregan un resultado mediante funciones matemáticas. Aprenden de la información histórica a través de un entrenamiento, proceso mediante el cual se ajustan los parámetros de la red, a fin de entregar la respuesta deseada, adquiriendo entonces la capacidad de predecir respuestas del mismo fenómeno. El comportamiento de las redes depende entonces de los pesos para los enlaces, de las funciones de activación que se especifican para las neuronas, las que pueden ser de tres categorías: lineal, de umbral (o escalón) y sigmoidea, y de la forma en que propagan el error.

Freeman y Skapura (1991) también mencionan que las redes neuronales representan una técnica de modelación matemática, que intenta imitar el proceso de aprendizaje que ocurre en el sistema nervioso. Su primer antecedente data de mediados del siglo XX y las primeras que se conocieron fueron las redes Perceptrón y Adaline.

2.8. Aplicaciones del análisis de imágenes

Según Lira (2010) una imagen digital guarda una variedad de patrones relacionados directamente con los objetos de la escena.

Mery (2004) menciona que mediante el análisis digital de imágenes se puede obtener una medición, interpretación o decisión a partir de una imagen. Este análisis se compone de 5 etapas:

Adquisición de la imagen: imagen del objeto de estudio. Puede ser una imagen digital a partir de una cámara fotográfica o una imagen digitalizada.

Pre-procesamiento: con el fin de mejorar la calidad de la imagen obtenida se emplean ciertos filtros digitales que eliminan el ruido en la imagen o bien aumentan el contraste.

Segmentación: Partición de una imagen en regiones que pueden o no tener un significado relativo a la escena respectiva. Se identifica el objeto de estudio en la imagen.

Medición: extracción de características. Se realiza una medición objetiva de ciertos atributos de interés del objeto de estudio.

Interpretación: Clasificación. De acuerdo a los valores obtenidos en las mediciones se lleva a cabo una interpretación del objeto.

El análisis de imágenes está estrechamente relacionado con el reconocimiento de patrones por las amplias interpretaciones que puede tener un conjunto de datos. Las clases de patrones, según Lira (2010), aplica tanto a patrones espaciales como espectrales; objetos con una cierta forma o tamaño, o pixels con un mismo valor en donde las características similares son aquellas propiedades morfológicas o espectrales que son comunes y de interés en un problema.

La textura y la información de color consideran como dos características útiles para clasificación de textura de imágenes en color (Nisale *et al.*, 2011). De igual manera, para Lucchese y Mitray (2001) el color y la textura son dos atributos utilizados para la recuperación de contenidos en imágenes y videos.

2.8.1. Representación del color

El color, es un fenómeno perceptual relacionado con la respuesta humana a diferentes longitudes de onda del espectro visible (400 - 700 nm), pero la medida de este estímulo depende de las condiciones que lo rodean.

El estímulo cromático está caracterizado por la colorimetría triestímulo, la cual permite obtener la sensación de color que percibimos y que está relacionada con la energía a diferentes longitudes de onda de una radiación electromagnética. Cada color tiene sus propias sensaciones o atributos psicométricos, que dan finalmente un carácter tridimensional a este estímulo. Estos son: el tono, la luminosidad y la saturación. Estas características identifican con precisión un color y lo distinguen de cualquier otro.

El tono o matiz es la característica que permite percibir el color de un objeto (rojo, amarillo, verde o azul) y está relacionado con las diferencias de absorbancia/transmitancia cuando sobre ellos incide la luz a diferentes longitudes de onda. La saturación o pureza, describe el grado o la intensidad con la que un color se separa del gris neutro y se acerca a un matiz puro del espectro, y describe la reflexión o transmisión a una determinada longitud de onda. La luminosidad o brillo permite clasificar el color como claro u oscuro, que se define como la característica de una sensación de color que la hace equivalente a la producida por algún elemento de la escala de grises que va desde el blanco (máxima luminosidad - 100) hasta el negro (mínima luminosidad - 0), haciendo un elemento más claro u oscuro (CIE, 1971 y Sancho *et al.*, 1999).

Algunas representaciones de color están en uso en el procesamiento de imágenes a color. El espacio de color RGB (rojo, verde y azul; por sus siglas en inglés) es el más común (Lucchese y Mitray, 2001).

Los espacios de color proporcionan un método para especificar, ordenar y manipular colores. Los colores, se representan mediante puntos en el espacio de los vectores, que en la actualidad estos espacios de color son numerosos y la gran mayoría se han desarrollado para aplicaciones específicas, aunque todos parten de un mismo concepto: la teoría tricromática de colores primarios rojo, verde y azul (Ortiz, 2002).

La elección del espacio del color depende de un conocimiento previo de la información que nos es útil del color para la aplicación a desarrollar, con el fin de discriminar los colores, agruparlos, indexarlos, compararlos, etc. (Márquez, 2008).

Lamens (1994) menciona que en la literatura clásica pueden distinguirse cuatro familias de modelos de color.

Modelos colorimétricos. Basados en medidas físicas de la reflectancia espectral. Suelen trabajar con tres filtros de colores primarios y un fotómetro, dando lugar a un diagrama de cromaticidad CIE¹.

Modelos psicofísicos. Fundamentados en la percepción humana del color. Estos modelos se basan en criterios subjetivos de observación y modelos de referencia, como por ejemplo, el modelo de color Munsell, o bien se construyen a partir de experimentos que cumplan con la percepción humana del color, como la familia HSL (Hue-Tono, Saturation-Saturación y Luminosity-Luminosidad); HSV (Hue-Tono, Saturation-Saturación y Value-Valor); HSI (Hue-Tono, Saturation-Saturación e Intensity-Intensidad), L*a*b* (Luminosity-Luminosidad y dos canales de cromaticidad), etc.

Modelos fisiológicos. Basados en los tres colores primarios (los tres tipos de conos de la retina humana). El más conocido es el espacio de color RGB utilizado en los dispositivos de las computadoras y en la televisión en colores.

Modelos de colores contrapuestos. Hacen uso de parejas de colores primarios opuestos entre sí, como el amarillo-azul o el rojo-verde.

2.8.2. Modelo RGB

De acuerdo con Ortiz (2002) el modelo RGB es el más comúnmente empleado, basado directamente en el modelo triestímulo y síntesis aditiva. En el espacio RGB el color aparece especificado mediante cantidades positivas de rojo, verde y azul, formando en el espacio 3D el cubo que se presenta en la Figura 9. Las imágenes en el modelo RGB están formadas por tres planos de imágenes independientes, cada uno correspondiente a un color primario y la suma (Shen, 2003) de intensidades de los colores primarios producen otros colores.

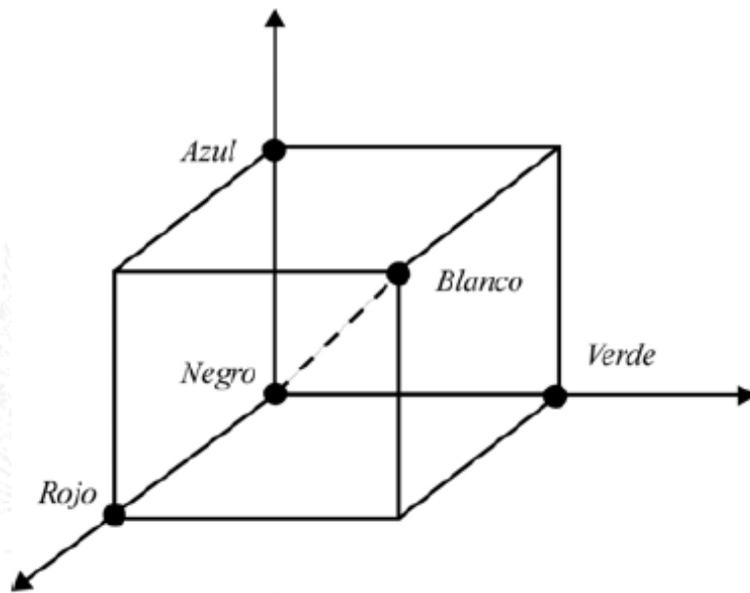


Figura 9. Representación espacial del modelo de color (RGB).

2.8.3. Modelo CIELab

En 1931, la CIE (Comisión Internacional de Iluminación) autoridad internacional en cuestiones de luz, iluminación, olor y espacios de color estableció una serie de normas para los diferentes espacios de color que representan el espectro visible.

Y en 1976, desarrolló el modelo de color “Lab” para mejorar la representación del color. Esta escala de color se basa en la teoría de los colores opuestos que establece que un color no puede ser verde y rojo al mismo tiempo. Por lo tanto se pueden usar valores sencillos para denotar los atributos rojo/verde y amarillo/azul. La ventaja de este espacio de color es que es más objetivo.

Se puede identificar cada color de forma precisa mediante sus valores L (claridad o brillo), a (rojo/verde) y b (amarillo/azul). Como se muestra en la Figura 10 el eje “a” corre de izquierda (negativo) a derecha (positivo), esto indica que un valor en dirección a la izquierda indica un valor verde al ser más negativo. En el eje “b un movimiento hacia +b* representa un cambio hacia el amarillo. El centro del eje L* muestra L=0 (negro o absorción total) en el fondo. En el centro de este plano es neutral o gris.

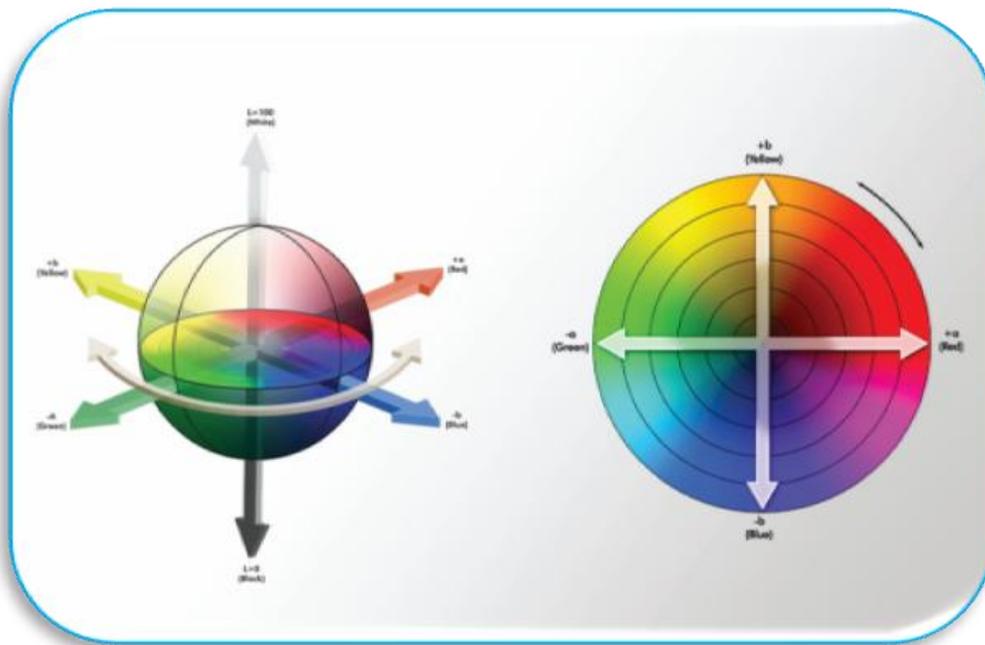


Figura 10. Modelo de color CIE-Lab

2.8.4. Textura

Lira (2010), define textura como la “manifestación espacial organizada de un arreglo local de tonos (píxeles) de la imagen”. Continúa diciendo que la textura puede cambiar de un lugar a otro de la imagen y depende de la escala a la cual se le observe y que también se manifiesta diferente de banda a banda de la imagen multispectral.

Muchos objetos o regiones no son uniformes, sino están compuestas de pequeños elementos indistinguibles y entrelazados que en general se conoce como textura (Sucar y Gómez, 2011).

A los elemento básicos de textura se le denomina texel (texture element) y lo podemos definir como una primitiva visual con ciertas propiedades invariantes que ocurre repetidamente a diferentes posiciones, deformaciones y orientaciones en un área (Sucar y Gómez, 2011). Las propiedades invariantes de los texels pueden ser: forma, tamaño, nivel de gris y color.

Existen diferentes formas de describir los tipos de textura, estos se clasifican en: modelos estructurales, modelos estadísticos y modelos espectrales.

Los dos primeros modelos están basados principalmente en estructuras altamente regulares y uniformes, en donde no solamente la estructura es importante sino que también su posicionamiento en el plano.

Por lo contrario, cuando la textura no tiene regularidad ni uniformidad, es mejor describirla mediante modelos estadísticos. Un primer método, es utilizar el histograma de niveles de gris y caracterizarlo mediante sus *momentos*. El segundo momento o varianza es particularmente útil ya que nos da una medida de la uniformidad o suavidad de la región.

Se han desarrollado diferentes alternativas de transformaciones para la clasificación de texturas en las que destacan: *momentos, energía en el dominio espacial, matrices de dependencia espacial y transformada de Fourier.*

El método de matrices de dependencia espacial obtiene una matriz intermedia de medidas a partir de la imagen y de esta matriz se definen las características o atributos para la clasificación (Sucar y Gómez, 2011) como los son:

$$\text{Energía } \sum_i \sum_j P_{ij}^2$$

$$\text{Entropía } \sum_i \sum_j P_{ij} \log P_{ij}$$

$$\text{Correlación } \sum_i \sum_j (i - m_x)(j - m_y) P_{ij}$$

$$\text{Inercia } \sum_i \sum_j (i - j)^2 P_{ij}$$

$$\text{Homogeneidad local } \sum_i \sum_j 1/1 + (i - j)^2 P_{ij}$$

Cope *et al.* (2010) presentan un método para clasificar textura de las hojas de las plantas. Compararon el método Gabor, Fourier y matrices co-ocurrencia. Llegando a la conclusión que el método Fourier captura los detalles más finos, mientras que la matriz de co-ocurrencia se desempeña mejor en las imágenes de contrastes altos entre los píxeles vecinos.

Haralick *et al.* (1973), menciona que los métodos de análisis de texturas más profusamente estudiados en la práctica de la teledetección se basan en la extracción de características estadísticas de segundo orden obtenidas a partir de la matriz de co-ocurrencias de niveles de gris (MCNG). Aunque hay otros métodos como descriptores de Fourier, modelos de autorregresión, morfología matemática, *wavelets*, filtros de Gabor o filtros de energía, pero básicamente la eficiencia de estos métodos radica en los tipos de textura que en práctica se desean caracterizar (Sarria *et al.*, 2003).

En general, el reconocimiento de patrones busca describir a cada patrón como un vector o región en el espacio *n-dimensional*. El proceso de reconocimiento

consiste en encontrar, para un patrón desconocido, el vector más cercano que corresponde a la clase que lo describe. Las características o atributos deben ser seleccionados de forma que exista cierta correlación entre elementos de la misma clase; es decir, que forman grupos o clusters en el espacio n-dimensional (Sucar y Gómez, 2011).

2.8.5. Procesamiento de imágenes digitales

La formación de una imagen ocurre cuando un sensor registra la radiación que interactúa con objetos físicos. Esta imagen, se puede ver como una función bidimensional $f(x, y)$, en donde el valor de la función corresponde a la intensidad o nivel de gris de la imagen en ese punto. Cuando x , y y los valores de amplitud de f son todas cantidades discretas finitas llamaremos a la imagen una “imagen digital” (Sucar y Gomez, 2011; González y Woods, 2002)

El procesamiento de imágenes se puede definir como una disciplina en donde el proceso de entrada y salida en un ordenador digital son imágenes, incluye los procesos que extraen los atributos de las imágenes, incluyendo el reconocimiento de los objetos individuales. Cada imagen digital está compuestas por un número finito de elementos llamados “píxeles” con una ubicación y valor en particular (González y Woods, 2002).

Dentro del procesamiento de imágenes existen 3 tipos de procesos informáticos: bajos, medios y procesos de alto nivel. Los procesos de bajo nivel implican tareas triviales tales como pre tratamientos para reducir el ruido, aumento de contraste y la nitidez, y se caracteriza por el hecho de que las entradas y salidas son imágenes. En el procesamiento de nivel medio se realizan tareas como segmentación (partición de un objeto en regiones u objetos), descripción y clasificación de los objetos, este nivel se caracteriza porque sus entradas generalmente son imágenes pero sus salidas son atributos extraídos de la imagen. Y por último, el procesamiento de alto nivel que implica

darle sentido a conjunto de objetos reconocidos, al igual que en el análisis de imágenes, esto involucra la realización de funciones cognitivas asociadas con la visión computacional (González y Woods, 2002).

La importancia de las imágenes adquiridas a partir de sensores remotos no solo envuelve el proceso de adquirir la información, sino que es necesario el procesamiento de imágenes que implica un conjunto de métodos para obtener esa información. Y una de las principales razones por lo cual el procesamiento de imágenes se ha transformado en una herramienta importante es que los datos son almacenados en forma digital, permitiendo así una manipulación más amplia de manera rápida y sencilla. Pero el procesamiento de imágenes no está limitado únicamente a la clasificación de suelos y vegetación, también es utilizado para destacar propiedades de interés en la imagen para su posterior interpretación.

III. LITERATURA CITADA

Arnon, D. I. and P. R. Stout. 1939. The essentiality of certain elements in minute quantity for plants with special reference to copper. *Plant Physiol.* 14:371–385.

Brizuela-Amador, B., Alcántar-González, G., Sánchez-García, P., Pea-Kalra, Y., Crumbaugh, J., Olive C., Tijerina-Chávez L. y R. Maldonado-Torres. 2007. Establecimiento de índices espectrales en el diagnóstico nutrimental de nitrógeno en maíz. *Agrociencia* 41 (8): 827-835.

C.I.E. 1971. Colorimetry, Official recommendations of the International Commission on Illumination. CIE Publicación No. 15 (E-1.3.1). Bureau Central de la CIE, Paris.

Cakmak, I. and A. M. Yazici. 2010. Magnesium: A Forgotten element in crop production. *Better Crops* 94 (2): 23-25.

Chuvieco, E. 1995. Fundamentos de teledetección espacial. Segunda edición. Ed. RIALP. Madrid, España. 449 p.

Cope, J. S., Remagnino, P., Barman, S., & Wilkin, P. 2010. Plant texture classification using gabor co-occurrences. *In: Advances in Visual Computing.* Springer Berlin Heidelberg 669-677

Díez, R. P., Gómez, A. G., y Martínez, N. D. A. 2001. Introducción a la Inteligencia Artificial: Sistemas expertos, redes neuronales artificiales y computación evolutiva. Universidad de Oviedo. España. 108 p.

Epstein, E. 1972. Mineral nutrition of plants: Principles and perspectives. Wiley, New York, USA.

Epstein, E. and Bloom, A. J. 2005. Mineral nutrition of plants: Principles and perspectives. Sinauer Associates. University of California, Davis. California. USA. 380 p.

Etchevers B., J. D. 1988. Diagnóstico de la fertilidad del suelo (curso intensivo). Colegio de Postgraduados. Cárdenas, Tabasco, México.

Fageria, N. K. 2009. The use of nutrients in crop plants. Ed. Taylor & Francis Group. 448 p.

Flores L, R. y Fernández F., J. M. 2008. Las redes neuronales artificiales: fundamentos teóricos y aplicaciones prácticas. Ed. Netbiblo. La Coruña, España. 152 p.

Freeman, J. A., and D.M. Skapura. 1991. Neural networks: algorithms, applications and programming techniques (Computation and Neural Systems Series) Addison-Wesley Pub., Reading, Massachusetts, USA. 401 p.

González, R. C., and Woods, E. R 2002. Digital image processing. Ed. Prentice Hall Press. USA.

Haralick, R. M., Shanmugam, K., and Dinstein, I. H. 1973. Textural features for image classification. Systems IEEE Transactions Systems, Man and Cybernetics SMC-3 (6): 610-621.

Harris, D.C. 2007. Análisis químico cuantitativo. Reverté. Barcelona, España. 532 p.

Lambers, H; Pons T. L. and Chapin III. F. S. 2008. Plant physiological ecology. Second edition. Springer Science. New York. USA. 623 p.

Lammens, J.M.G. 1994. A computational model for color Perception and color Naming. Ph. D dissertation, State University of New York at Bufalo, Bufalo, New York.

Lillesand, T.M. and R.W. Klefer. 1994. Remote sensing and image interpretation. John Wiley & Sons. University of Michigan, Michigan. 750 p.

Lira C., J. 2010. Tratamiento digital de imágenes multiespectrales. Universidad Nacional Autónoma de México. México. 618 p.

Lucchesezy, L., and Mitray, S. K. 2001. Color image segmentation: A state-of-the-art survey. Proceedings of the Indian National Science Academy (INSA-A). Delhi, Indian: Natl Sci Acad. 67(2). 207-221.

Maathuis, F. J., and Diatloff, E. 2013. Roles and functions of plant mineral nutrients. *In*: Frans J.M. Maathuis (ed.), Plant Mineral Nutrients: Methods and Protocols, Methods in Molecular Biology 953. 1-21. Springer Science.

Márquez D., S., S. A 2008. Selección de los colores esenciales de una imagen digital. Tesis de Maestría en Ciencias de la computación. Instituto Politécnico Nacional. México, D. F. 127 p.

Mengel, K., and Kirkby, E. A. 1987. Principles of plant nutrition. International Potash Institute, Worblaufen-Bern, Switzerland.

Mery, D. 2004. Visión por computador. Universidad Católica de Chile. Santiago de Chile. 146 p.

Mikkelsen, R. 2010. Soil and fertilizer magnesium. *Better Crops* 94:26–28.

Murakami, P. F., Turner, M. R., van den Berg, A. K. and Schaberg, P. G. 2005. An instructional guide for leaf color analysis using digital imaging software. United States Department of Agriculture. Washington, DC, USA.

Navarro, B. C y G. Navarro G. 2003. Química agrícola: el suelo y los elementos químicos esenciales para la vida vegetal. Segunda edición. Editorial Mundi-Prensa. Barcelona, España. 487 p.

Nisale, S. S., Bharambe, C. J., and More, V. N. 2011. Detection and analysis of deficiencies in groundnut plant using geometric moments. World Academy of Science, Engineering and Technology 58: 609-613.

Ortiz Z., F. G. 2002. Procesamiento morfológico de imágenes en color. Aplicación a la reconstrucción geodésica. Tesis doctoral. Universidad de Alicante. Alicante, España. 205 p.

Ovando G., Bocco, M., y Sayago, S. 2005. Redes neuronales para modelar predicción de heladas. Agricultura Técnica 65(1): 65-73.

Sancho, J.; Bota, E.; de Castro, J 1999. Introducción al análisis sensorial de los alimentos. Universidad de Barcelona, España. 51-60.

Sarría, A. F., Recio, J. R., y Fernández, L. A. R. 2003. Análisis de imágenes mediante texturas: Aplicación a la clasificación de unidades de vegetación. Geofocus: GeoFocus (Articulos) 3. 143-159.

Shen, Z. 2003. Colour differentiation in digital images. Master of Science. School of Computer Science and Mathematics Victoria University of Technology. Australia. 172 p.

Skoog, D.A., West, D.M, Holler, F.J. y S.R. Crouch. 2004. Química analítica. McGraw-Hill. México, DF.

Soria R., J; Ortíz S., C.A.; Islas G., F. y V. Volke H. 1998. Sensores remotos. Principios y aplicaciones en la evaluación de los recursos naturales. Experiencias en México. Publicación especial 7. Sociedad Mexicana de la Ciencia del Suelo (S. M. C. S.) Chapingo, México.

Stevens, G; P. Motavalli; P. Scharf; M. Nathan and D. Dunn. 2002. Crop nutrient deficiencies and toxicities. University of Missouri. MS, USA. 20 p.

Sucar, L. E., and Gómez, G. 2011. Visión computacional. Instituto Nacional de Astrofísica, Óptica y Electrónica, Puebla México. 185 p.

Taiz, L. and E. Zeiger. 2002. Plant physiology. Third edition. Sinauer Associates. 623 p.

Taiz, L. and Zeiger, E. 2010. Topic 5.1: Symptoms of Deficiency in Essential Minerals. Plant Physiology, Fifth Edition. Online in: <<http://www.plantphys.net>> Accessed [23 de mayo de 2013].

Widenhoeft, A. C. 2006. Plant nutrition. Chelsea House. New York, NY. USA. 153 p.

Willard, H. H; Merrit Jr. L. L; Dean J. A. and Settler Jr. F. A. 1986. Métodos instrumentales de análisis. CECOSA. México, D. F. 1036 p.

IV. OBJETIVOS E HIPÓTESIS

4.1. OBJETIVOS GENERALES

- Determinar el estrés causado por deficiencias de nitrógeno y magnesio mediante la reflectancia de imágenes digitales.
- Desarrollar un clasificador de red neuronal utilizando características texturales y de color capaz de predecir el grado de deficiencia de nitrógeno y magnesio.

4.1.1. Objetivos particulares

- Obtener los valores de reflectancia de las deficiencias de nitrógeno y magnesio en frijol a través de imágenes digitales de escáner.
- Obtener la concentración de nitrógeno y magnesio en hojas de frijol sometidas a deficiencias y correlacionarlas con los valores de reflectancia de las imágenes digitales.
- Obtener las características texturales de una superficie de los pecíolos centrales de la hoja de frijol.

4.2. HIPÓTESIS

La reflectancia producida por las plantas con diferentes niveles de suministro, y las características texturales proveen de información para la identificación de deficiencia de nitrógeno y magnesio.

DIAGNÓSTICO DE DEFICIENCIAS DE NITRÓGENO Y MAGNESIO CON IMÁGENES DIGITALES

Diagnosis of Nitrogen and Magnesium Deficiency With Digital Images

Maciel Reyes-Flores¹, Manuel Sandoval-Villa^{2*}, José Alfredo Carrillo-Salazar³ y Jorge Manuel Valdéz-Carrasco⁴

RESUMEN

En el presente trabajo se estudió la relación entre la reflectancia de las hojas recientemente maduras con la concentración de N y Mg en plantas de frijol mediante el análisis de imágenes digitales, con el objetivo de encontrar una técnica precisa y confiable que nos permita la identificación de deficiencias nutrimentales de N y Mg en sus etapas iniciales. La similitud entre las deficiencias de ambos elementos, que afectan la composición y proporción de pigmentos en el tejido de la hoja, hace difícil la discriminación del elemento causal de la deficiencia. Se digitalizaron hojas recientemente maduras de frijol con un escáner y se obtuvieron los valores de los canales del espacio RGB, CIE-Lab Cr y Hue. A estas mismas hojas se le hicieron las determinaciones de N en laboratorio por el método micro Kjeldahl y el método para la determinación de Mg fue a través de espectrofotometría de absorción atómica. Las concentraciones conjuntas de N y Mg se relacionaron con las reflectancias obtenidas de las imágenes de escáner en las bandas roja, verde, azul, CIE-Lab además de la pureza (croma) y Hue, mediante el programa estadístico Statistical Analysis System (SAS 9.3). Los datos se expusieron a un análisis de varianza, comparación de medias Duncan ($\alpha = 0.05$) y análisis de regresión. Los modelos que presentaron mayor grado de asociación con respecto a la interacción de N-Mg fueron el CIE-b ($r^2 = 0.76$), croma ($r^2 = 0.75$), rojo, verde y CIE-L ($r^2 = 0.73$).

Palabras clave: Reflectancia, color, discriminación.

SUMMARY

In this paper we studied the relationship between the reflectance of recently mature leaves with the concentration of N and Mg in bean plants by digital image analysis, with the aim of finding a reliable and accurate technique that allows us to identify nutritional deficiencies of N and Mg in the initial stages. The similarity between both elements deficiencies which affect the composition and proportion of pigment in the leaf tissue, discrimination becomes difficult causative element deficiencies. Recently mature leaves were digitized with a scanner bean and obtained the values of the RGB space channels, CIE-Lab Cr and Hue. At these same leaves were made in the laboratory determinations N by micro Kjeldahl method and the method for the determination of Mg was through atomic absorption spectrophotometry. The concentrations of N and Mg joint related to the reflectance images obtained from scanning in the bands Red, green, blue, CIE-Lab plus purity (chroma) and Hue, the program Statistical Analysis System (SAS 9.3). Data were exposed to an analysis of variance comparing means Duncan ($\alpha = 0.05$) and regression analysis. The models had a higher degree of association with respect to the interaction of N-Mg were the CIE-b ($r^2 = 0.76$), chroma ($r^2 = 0.75$), red, green and CIE-L ($r^2 = .73$).

Keywords: *Reflectance, color, discrimination.*

INTRODUCCIÓN

Es bien sabido que las deficiencias nutrimentales resultan de un desbalance metabólico dentro de la planta derivadas del insuficiente suministro del elemento esencial, ocasionando un decremento en el rendimiento (Shaahan *et al.*, 1999). Este desbalance está relacionado con las funciones del elemento ya sea que participe en un proceso fisiológico en el metabolismo de la planta, como regulador enzimático o constituyente estructural de un complejo macromolecular.

De los macronutrientes primarios, el nitrógeno es el elemento más importante para el crecimiento vegetativo, floración y fructificación de árboles frutales (Mengel y Kirkby, 1987). También desempeña un papel fundamental en la estructura de la clorofila (Wiedenhoeft, 2006), y por tanto uno de los resultados de la deficiencia es la falta de formación y baja densidad de clorofila en hojas de las plantas (Thomson y Weier, 1962). Deficiencias de magnesio y de hierro y otros nutrientes como el azufre, el calcio, el manganeso y el zinc también pueden afectar la formación de clorofila, dando lugar a diferentes grados de clorosis (Wiedenhoeft, 2006; Mengel y Kirkby, 1987). El nitrógeno y magnesio son componentes estructurales de la clorofila, por lo que un desabasto de estos disminuye el color verde de las hojas manifestándose una clorosis.

En consecuencia, el análisis de imágenes mediante la interpretación de valores de reflectancia en el espectro visible, puede ser utilizado como herramienta para determinar el estado nutrimental para la determinación de algunos nutrientes. Con la utilización del análisis de imágenes se busca nuevas técnicas metodológicas que permitan superar las limitaciones de los métodos tradicionales de detección de deficiencias.

El nitrógeno, es el elemento que más se ha estudiado debido a la importancia que ejerce en la producción de cultivos. Se han generado modelos en base a la

reflectancia en el espectro visible (RGB) para predecir la deficiencia de nitrógeno en chile manzano (De la Cruz, 2011).

El espacio de color CIE-Lab también se puede utilizar para predecir deficiencias de nutrimentos y superar algunas limitaciones del espacio RGB. Los colores se definen por los valores L^* , a^* , b^* . Luminosidad se expresa como valor "L" que toma valores de 0 (negro) a 100 (blanco). Los valores de "a" y "b" indican las coordenadas de cromaticidad. Verde a rojo se expresa por el valor de "a". Un valor más positivo representa rojo, mientras que un valor más negativo representa verde. Azul y amarillo se expresa por el valor "b". Un valor más positivo representa amarillo, un valor más negativo representa azul. a^* y b^* del color representan la reflectancia de la planta de frijol a través de las hojas que se utilizaron para la discriminación de la condición de nitrógeno y magnesio.

El diagnóstico de deficiencias es muy importante en la agricultura para aplicar de manera anticipada el elemento causal de cierta deficiencia. Para esto, se necesita de técnicas precisas y confiables que nos permitan la identificación de desórdenes fisiológicos con oportunidad. La mayoría de estos desórdenes fisiológicos afectan la composición y proporción de pigmentos en el tejido de la hoja. Al respecto, Brizuela *et al.* (2007) proponen la utilización de firmas espectrales para obtener información del estado fisiológico de la planta, asociándolo con la concentración de elementos de interés en el tejido vegetal.

Por tanto, el objetivo de esta investigación fue diferenciar la sintomatología de la deficiencia de nitrógeno y magnesio mediante la utilización de los canales del espacio RGB, CIE-Lab, croma y hue de imágenes digitalizadas de hojas de frijol.

La hipótesis fue que los valores de reflectancia en los canales rojo y verde producida por las plantas con diferentes niveles de suministro, provee de información para la identificación de deficiencia de nitrógeno y magnesio.

MATERIALES Y MÉTODOS

Las hojas de frijol utilizadas en este estudio se cultivaron en un invernadero del Área de Nutrición Vegetal del Colegio de Postgraduados, Campus Montecillo en Texcoco, Estado de México. Como material vegetal se utilizó frijol mezcla-negro CP Mon-2011. La producción de plántulas se llevó a cabo en dos charolas de 77 cavidades utilizando como sustrato perlita. En cada una de las cavidades se colocó una semilla. Durante el proceso emergencia, las plantas se regaron con agua destilada únicamente. Se trasplantó a los 22 días después de la siembra en vasos de poliestireno con capacidad de 1 L rellenas hasta un 85% de su capacidad volumétrica con el sustrato. A partir de esta fecha se regaron con solución nutritiva Steiner, con los tratamientos correspondientes (Cuadro 1). Se seleccionó un grupo de hojas recientemente maduras para este estudio, a los 30 días después de la aplicación de los tratamientos.

Cuadro 1. Descripción de los tratamientos para generar deficiencias conjuntas y separadas de nitrógeno y magnesio en plántulas de frijol.

Identificación del tratamiento	Nitrógeno		Magnesio	
	NO ₃ ⁻ (meq L ⁻¹)	(%)*	Mg ²⁺ (meq L ⁻¹)	Mg (%)*
T1	3	25	1	25
T2	3	25	2	50
T3	6	50	1	25
T4	6	50	2	50
T5	12	100	4	100

* En relación a la solución nutritiva universal de Steiner.

El diseño experimental fue completamente al azar, con 8 repeticiones por tratamiento. Cada unidad experimental consistió en un vaso de poliestireno de 1 L

de capacidad con una planta. Se originaron 40 unidades experimentales, provenientes de 5 tratamientos y 8 repeticiones.

Los tratamientos consistieron en aplicar riegos con la solución nutritiva universal de Steiner modificada en la concentración de nitrógeno y magnesio para inducir la deficiencia a cierto porcentaje de estos elementos. Los tratamientos se aplicaron desde los 22 hasta los 51 días después de la emergencia. Los diferentes tratamientos se presentan en el Cuadro 1.

Se analizaron los resultados de esta investigación como una interacción entre ambos elementos. Para la obtención de los índices de la interacción entre N y Mg se utilizó la siguiente fórmula:

$$Y1 = 0.5 \left[\frac{XN - Nmín}{Nmáx - Nmín} + \frac{XMg - Mgmín}{Mgmáx - Mgmín} \right]$$

Donde;

Y1 = índice N-Mg en el rango de 0 a 1.

XN = valor actual de la concentración de nitrógeno en %.

XMg = valor actual de la concentración de magnesio en %.

Nmín = valor mínimo de nitrógeno en %.

Nmáx = valor máximo de nitrógeno en %.

Mgmín = valor mínimo de magnesio en %.

Mgmáx = valor máximo de magnesio en %.

Las muestras de hojas de las plantas de frijol se digitalizaron inmediatamente después de cortarlas para mantener el nivel de humedad. Las imágenes digitales se obtuvieron digitalizando un tapiz de hojas recientemente maduras por repetición de cada tratamiento con un escáner comercial a 300 dpi (puntos por pulgada), y almacenadas en formato JPEG.

Posteriormente, en un programa en Visual Basic v6 se obtuvieron los valores de reflectancia en el espacio de color RGB, CIE-Lab, croma y hue de cada píxel de las imágenes de las hojas y se obtuvo un promedio por repetición.

Inmediatamente después del proceso de escaneo de las hojas las plantas fueron llevadas al laboratorio y secadas en una estufa a 65 °C por 48 horas. Las plantas secas fueron trituradas con la ayuda de un mortero, hasta obtener una muestra vegetal fina. A las muestras secas y molidas se les determinó la concentración de nitrógeno por el método micro Kjeldahl. La concentración de magnesio se determinó por el método espectrofotometría de absorción atómica.

El análisis estadístico se realizó mediante el programa de cómputo Statistic Analysis System version 9.3. Se efectuó un análisis de la varianza y una prueba de medias Duncan ($\alpha = 0.05$) a todas las variables evaluadas. Se realizó análisis de regresión entre la concentración de nitrógeno y magnesio en parte aérea y las variables respuesta y se seleccionaron modelos para estimar el comportamiento de dichas variables.

RESULTADO Y DISCUSIÓN

Se realizó un análisis de varianza de la concentración de nitrógeno y magnesio en el tejido vegetal, el cual reveló diferencias altamente significativas ($\alpha < 0.0001$) en el comportamiento de las variables a causa de la aplicación de los tratamientos. La prueba de medias de Duncan ($\alpha = 0.05$) mostró diferencias entre cada uno de los tratamientos para cada elemento (Figura 11).

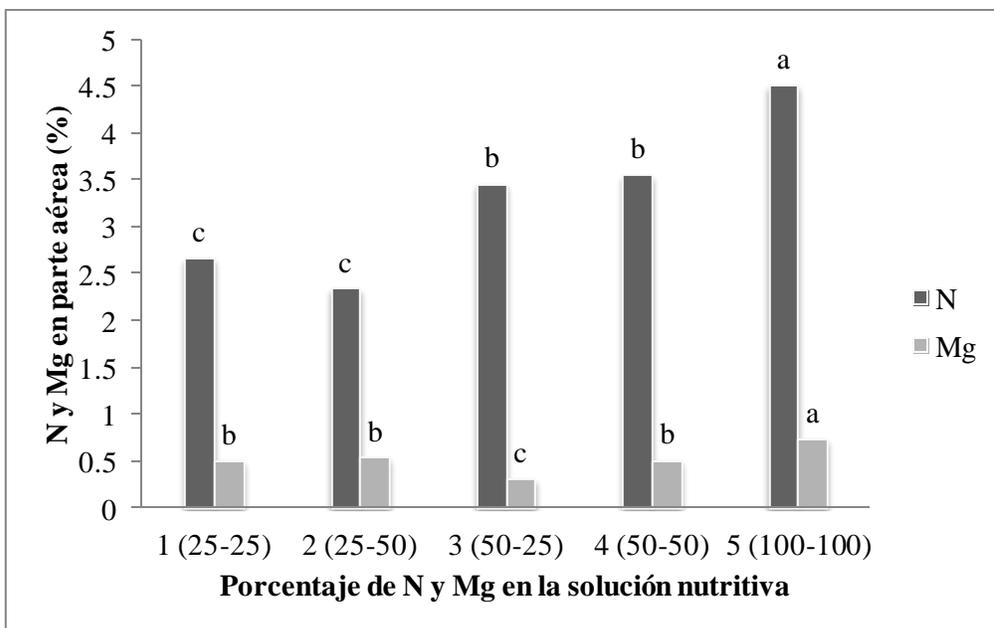


Figura 11. Concentración de nitrógeno y magnesio en tejido vegetal en función de la concentración de nitrógeno y magnesio en la solución nutritiva .

Los resultados de la Figura 11 indican que las soluciones nutritivas modificaron la concentración de nitrógeno y magnesio en las hojas recientemente maduras. Se observa que la concentración de nitrógeno del T5 (100% N – 100% Mg) estadísticamente es diferente a los T1 (25% N – 25% Mg), T2 (25% N – 50% Mg), T3 (50% N – 25% Mg) y T4 (50% N – 50% Mg). Se observa una tendencia de aumento de la concentración de nitrógeno en el tejido vegetal conforme se aumentó su concentración en la solución nutritiva.

Con respecto a la concentración de magnesio, el T5 (100% N – 100% Mg) produjo la más alta concentración, como era de esperarse. Mientras que el T2 (25% N – 50% Mg), T4 (50% N – 50% Mg) y T1 (25% N – 25% Mg) son estadísticamente iguales.

Índice de interacción de nitrógeno y magnesio

En el Cuadro 2 se aprecia una tendencia positiva al incrementar las concentraciones de N en la solución nutritiva; es decir, conforme aumenta la concentración de N en la solución, mayor es su concentración en el tejido vegetal.

Sin embargo, en el Mg no se observó esta tendencia, ya que el T1 (25% N – 25% Mg), T2 (25% N – 50% Mg) y T4 (50% N – 50% Mg) presentaron valores estadísticamente iguales, excepto para el T3 (50% N – 25% Mg) que en teoría debería de tener la misma concentración que el T1. Se nota en esta Figura que el N influye en la absorción de Mg. Por lo tanto, conviene analizar los resultados de esta investigación como una interacción entre ambos elementos.

Cuadro 2. Efecto de la interacción nitrógeno-magnesio (N-Mg) en los tratamientos sobre la concentración promedio de N y Mg en hojas de frijol recientemente maduras.

Tratamiento	N en hoja (%)	N (% en la SN)	Mg (% en la SN)	Mg en hoja (%)
T1	2.66c	25	25	0.5009b
T2	2.34c	25	50	0.5373b
T3	3.46b	50	25	0.3073c
T4	3.55b	50	50	0.5083b
T5	4.51a	100	100	0.7338a

SN: solución nutritiva Steiner.

Para medir la magnitud de la interacción, se llevó a cabo una prueba de comparación de medias del índice N-Mg por el método de Duncan con un nivel de significancia de 0.05. En la Figura 12 se presentan las medias de la interacción entre N y Mg. De esta forma se pretende conocer el efecto de cada uno de los tratamientos.

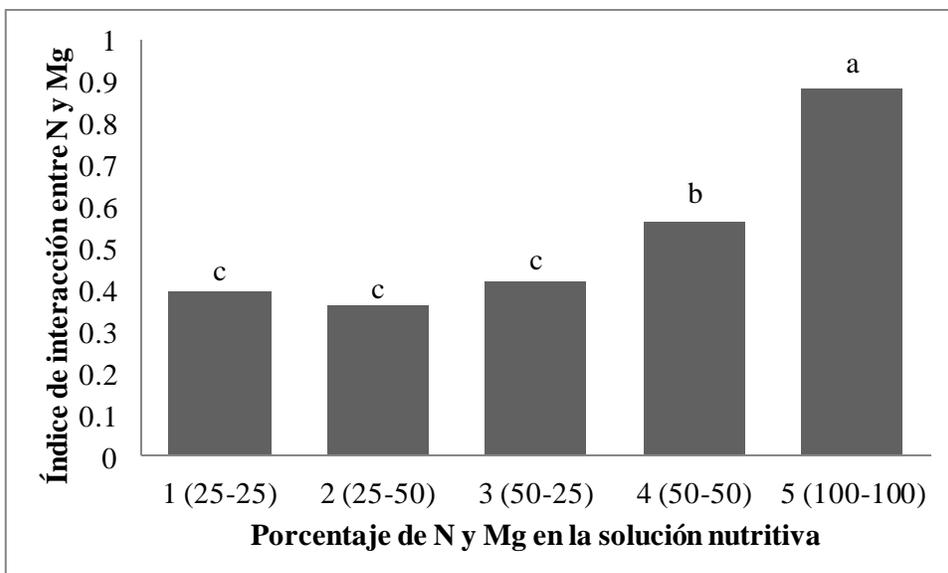


Figura 12. Comparación del índice de interacción de nitrógeno y magnesio.

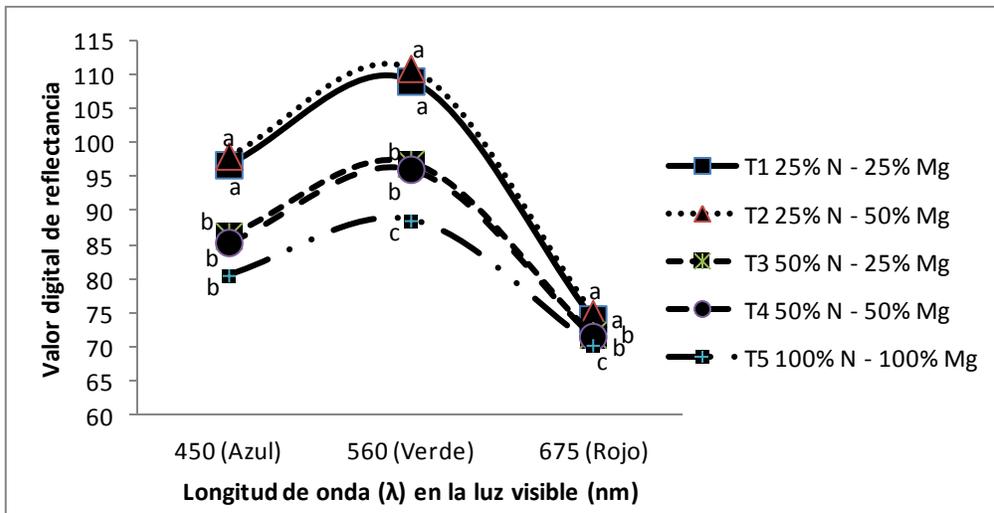
Se observa que el mejor índice de interacción corresponde al T5 (solución completa Steiner), seguido del T4 (50% N - 50% Mg) y los T1 (25% N - 25% Mg), T2 (25% N - 50% Mg) y T3 (50% N - 25% Mg) son estadísticamente iguales.

De los resultados de la Figura 12, podemos deducir que cuando se tienen concentraciones como las del T1 (25% N - 25% Mg), T2 (25% N - 50% Mg) y T3 (50% N - 25% Mg) el índice de interacción no tendrá efecto significativo. Sin embargo, hay que tomar en cuenta que los resultados de producción de materia seca y de grano pueden variar aun sí presenten valores similares. Sería conveniente evaluar estas interacciones para conocer el efecto en producción grano y conocer la concentración de nitrógeno y magnesio con los que se alcanzan los mejores resultados de producción.

Reflectancia de hoja en los canales del espacio RGB, CIE-Lab, croma y hue

La información proporcionada en la Figura 11 permitió establecer que cualquier cambio detectado por el sensor al momento de digitalizar las hojas se debió a las concentraciones de N y Mg, dando como resultado valores de reflectancia para cada uno de los tratamientos.

En la Figura 13 se muestran los valores digitales en el espectro de luz visible en hojas de frijol recientemente maduras como respuesta de los tratamientos con N y Mg en la solución nutritiva.



Valores con la misma letra son estadísticamente iguales (Duncan $\alpha = 0.05$).

Figura 13. Reflectancia de luz en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.

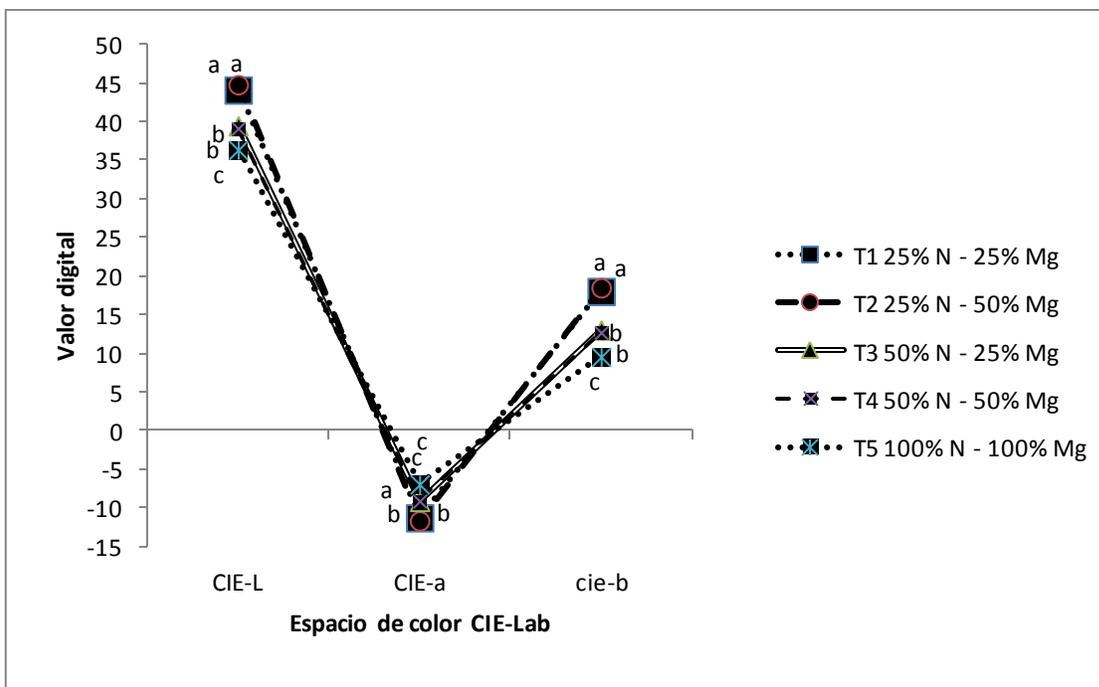
En la Figura 13 se observa que cuando se aplica N y Mg en porcentajes bajos en la solución nutritiva el valor de reflectancia aumenta en los canales de color rojo, verde y azul y disminuye conforme se aumenta el porcentaje de estos elementos. Esto se puede atribuir principalmente a que en los tratamientos con menores concentraciones de N presentan una menor concentración de clorofila (Curran *et al.*, 2001), pero como también el Mg es parte de la estructura de la clorofila, por eso afecta directamente la presencia de ésta, y por lo tanto la reflectancia aumenta. Mientras que un cultivo saludable nutrimentalmente presentará bajas

reflectancias en la región visible del espectro electromagnético principalmente a la intensa absorción de la molécula de clorofila (Thomas y Oerther, 1972). Para esto, Brizuela *et al.* (2007) menciona que la clorofila absorbe radiación en el rango rojo y azul, dando como resultado una pequeña reflectancia de esos espectros por el cultivo, y refleja el verde.

La clorofila “a” es la más abundante en los tejidos vegetales y muestra dos picos importantes de absorción, uno en la región azul y otro en la región del rojo, ambas regiones son utilizadas con frecuencia para medir la concentración de clorofilas. Sin embargo, el pico de absorción de la región azul se traslapa con la absorción de carotenoides, por lo cual no se utiliza como estimador de la clorofila (Rivas, 2002). Los resultados obtenidos en la investigación demuestran que la reflectancia en la banda azul presentó el modelo más bajo como estimador en la concentración de nitrógeno en la parte aérea de la planta. Se corroboró que las plantas con menor contenido de N y Mg reflejaron mayor cantidad de luz debido a concentraciones bajas de clorofila.

La degradación de cloroplastos se debe a la pérdida de clorofilas dando origen a los cromoplastos, los cuales exhiben pigmentaciones amarillas y anaranjadas, debido principalmente a los carotenos y xantofilas. Es por ello, que las plantas presentan la típica clorosis en ausencia de clorofilas ya sea por deficiencia de elementos nutritivos o por la madurez de hoja que exporta los nutrimentos a los tejidos jóvenes, tal es el caso del N y Mg.

Con lo que respecta a la concentración de N y Mg en la solución nutritiva tuvieron un efecto estadísticamente significativo en los valores de CIE-Lab (Figura 14).



Valores con la misma letra son estadísticamente iguales (Duncan $\alpha = 0.05$).

Figura 14. Valores CIE-Lab en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.

La interacción de la concentración de N-Mg en la solución nutritiva tuvo un efecto significativo sobre los valores de CIE-L. Los T2 (25% N-50% Mg) y T1 (25% N-25% Mg) presentaron los valores más altos de CIE-L. Caso contrario con los valores CIE-a que se observó en hojas del T5 (100% de N y Mg).

Los tratamientos tuvieron un efecto estadísticamente significativo sobre los valores de CIE-b, en donde el menor valor lo obtuvo el T5 (100% de N y Mg). Lo que concuerda con el trabajo realizado por Graeff *et al.* (2008) quienes mencionan que al aumentar la tasa de fertilización de N en variedades de brócoli, el parámetro “b” aumenta. La relación de la reflectancia de éste parámetro y la concentración de nitrógeno y magnesio fue descrito como el mejor modelo lineal (Cuadro 3).

El conocimiento de la demanda de nitrógeno como la de magnesio permitirá la predicción de las necesidades de los cultivos y, por lo tanto, el desarrollo de las recomendaciones de fertilización confiables para los productores.

Se observó un efecto significativo sobre los valores de pureza de color (croma) y matiz (hue). El T2 y el T1 (25 % N- 25% Mg y 25% N-50% Mg) tuvieron el nivel más alto de pureza de color (Figura 15). Por lo contrario, los mayores resultados de hue se obtuvieron en hojas de los T5, T4 y T3 (Figura 16).

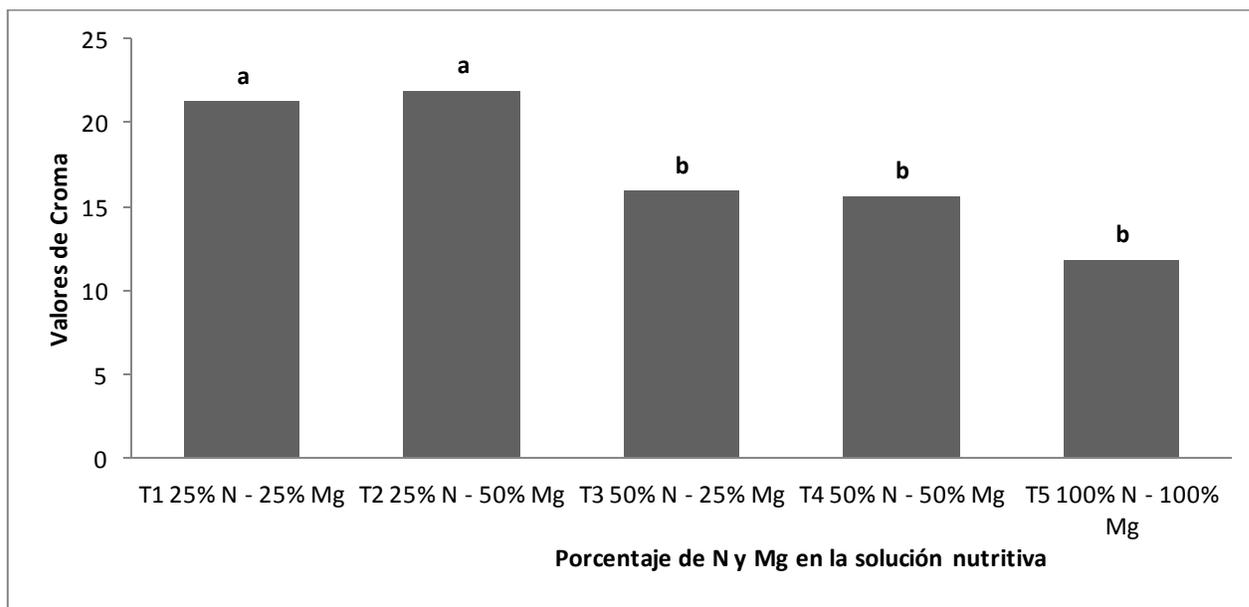


Figura 15. Valores de croma en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.

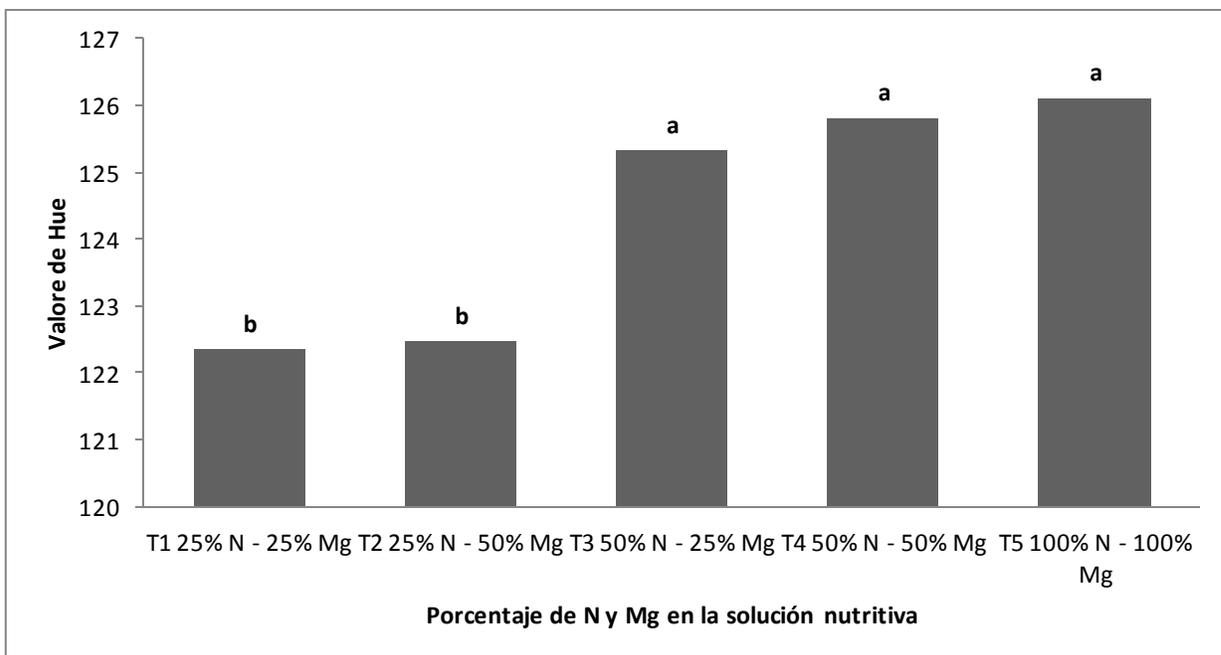


Figura 16. Valores de hue en hojas recientemente maduras de frijol para los diferentes tratamientos de nitrógeno y magnesio.

De acuerdo con el análisis de regresión existió una asociación lineal negativa altamente significativa ($\alpha \leq 0.01$) entre los valores CIE-b, Cr, rojo, verde y CIE-L con la concentración de la interacción de N y Mg. Estos modelos permiten predecir las concentraciones de N y Mg del follaje a partir de los valores CIE-b, Cr, rojo, verde y CIE-L, con una asociación del 76, 75, 73, 73 y 73%, respectivamente (Cuadro 3).

Cuadro 3. Modelos para estimar la concentración de nitrógeno y magnesio en hojas de frijol recientemente maduras.

X	Modelo	r ²
Banda roja	%N-Mg = -4.5285X + 102.9727	0.73
Banda verde	%N-Mg = -5.5777X + 117.0158	0.73
Banda azul	%N-Mg = -1.1102X + 75.8780	0.50
CIE-L	%N-Mg = -2.1161X + 47.1179	0.73
CIE-a	%N-Mg = 1.1169X - 12.9730	0.69
CIE-b	%N-Mg = -2.2757X + 21.1879	0.76
Croma	%N-Mg = -2.5171X + 24.8702	0.75
Hue	%N-Mg = 1.0950X + 121.1405	0.60

De la cruz *et al.* (2011) mencionan que el espectro verde (560 nm) es un buen indicador para diagnosticar concentraciones menores del 3% de N en el tejido vegetal obtenido a través de imágenes de escáner.

CONCLUSIONES

Algunos parámetros de reflectancia en las bandas verde y roja, además del espacio CIE- b, CIE-L y valores de croma derivados de imágenes digitales son apropiados para la estimación de concentraciones de nitrógeno y magnesio en plantas de frijol.

LITERATURA CITADA

Amador-Pérez B., B., G. Alcántar-González, P. Sánchez-García, Y. Pea-Kalra, J. Crumbaugh, C. Olive, L. Tijerina-Chávez y R. Maldonado-Torres. 2007. Establecimiento de índices espectrales en el diagnóstico nutrimental de N en maíz. *Agrociencia* 41: 827-835.

Curran, P. J., J. L. Dungan, and D. L. Peterson. 2001. Estimating the foliar biochemical concentration of leaves with reflectance spectrometry: Testing the Kokaly and Clark Methodologies. *Remote Sensing of Environ.* 76: 349-359.

De la Cruz-Durán, J. A., Sánchez-García, P., J. A., Galvis-Spínola, A., y Carrillo-Salazar, J. A. 2011. Índices espectrales en pimiento para el diagnóstico nutrimental de nitrógeno. *Terra Latinoamericana* 29: 259-265.

Graeff, S., J. Pfenning, W. Claupein and H. P. Liebig. 2008. Evaluation of image analysis to determine the N-Fertilizer demand of broccoli plants (*Brassica oleracea* convar. *botrytis* var. *italica*). *Adv. Optical Technol.* 2008: 1-8.

Marshner, H. 1995. Mineral nutrition of higher plants. Academic Press. London, UK. 674 pp.

Mengel, K. and E.A. Kirkby. 1987. Principles of plant nutrition. Int. Potash Inst. Bem, Switzerland. 687 pp.

Rivas, J. 2000. La luz y el aparato fotosintético. *In: Azcón-Bieto, J. y Talón, M. Fundamentos de fisiología vegetal.* España. pp. 131-153.

Shaahan, M. M., El-Sayed, A. A., and Abou El-Nour, E. A. A. 1999. Predicting nitrogen, magnesium and iron nutritional status in some perennial crops using a portable chlorophyll meter. *Sci. Hortic.* 82: 339-348.

Taiz, L., and E. Zeiger. 2002. Plant physiology. Sinauer Associates. Sunderland, MA, USA. 690 pp.

Thomas, J.R. and G. F. Oerther. 1972. Estimating nitrogen content of sweet pepper leaves by reflectance measurements. *Agronomy Journal*. 83:11-13.

Thomson, W.W., and T. E. Weier, 1962. The fine structure of chloroplasts from mineral-deficient leaves of *Phaseolus vulgaris*. *Am. J. Bot.* 49: 1047-1055.

Wiedenhoeft, A.C. 2006. Plant nutrition. Chelsea House Publishers. Philadelphia, PA, USA. 144 pp.

REDES NEURONALES PARA CLASIFICAR DEFICIENCIAS DE NITRÓGENO Y MAGNESIO MEDIANTE CARACTERÍSTICAS TEXTURALES Y DE COLOR

Neural Networks For Classify Of Nitrogen And Magnesium Deficiency By Characteristics And Color Textural

Maciel Reyes-Flores¹, José Alfredo Carrillo-Salazar^{2*}, Manuel Sandoval-Villa³ y Jorge Manuel Valdéz-Carrasco⁴

RESUMEN

En esta investigación se presenta una metodología basada en características superficiales de análisis de color y textura de imágenes digitalizadas, utilizando el método de co-ocurrencia de color para discriminar las deficiencias de la interacción N-Mg. A partir de estadísticas de segundo orden de Haralick, se calcularon cuatro características texturales (segundo momento angular, entropía, homogeneidad local e inercia) de cada una de las matrices de co-ocurrencia y ocho valores de colores en los espacios RGB, CIE Lab además del croma (C) y el matiz (H), en imágenes de 100 X 100 píxeles. El mejor clasificador resultó a partir de datos de cinco tratamientos de las variables de colores R, G, B, CIE-a con un 89.8% de clasificaciones correctas correspondientes a los tratamientos. Pero también, las combinaciones de variables de colores con texturas produjeron clasificadores adecuados (1) con los espacios de color RGB y CIE-Lab (87.07%) y (2) con las cuatro características texturales y espacios de color RGB y CIE Lab (88.44). Se utilizaron en total 368 observaciones en esta investigación. Los valores texturales presentan una mejora considerable cuando se utilizan en combinación con variables de color, que cuando se usan solos.

Palabras claves: Espacios de color, textura, redes neuronales, co-ocurrencia.

ABSTRACT

This research presents a methodology based on surface characteristics of color and texture analysis of digitized images, using the co-occurrence method for discriminating color deficiencies N-Mg interaction. From second-order statistics Haralick, four characteristics were calculated textural (angular second moment, entropy, local homogeneity and inertia) of each of the co-occurrence matrices and eight values of colors in RGB space, in addition CIELab chroma (C) and hue (H), images of 100 X 100 pixels. The best classifier data resulted from five treatments variables colors R, G, B, to a CIE-89.8% of correct classifications for treatments. But also, combinations of variables produced colors with textures suitable classifiers (1) with RGB color spaces and CIE-Lab (87.07%) and (2) with the four textural characteristics, and color spaces RGB and CIELab (88.44). Total 368 were used in this investigation. The textural values presented a considerable improvement when used in combination with variable color, which when used alone.

Keywords: Spaces of color, texture, neural networks, co-occurrence.

INTRODUCCIÓN

El nitrógeno, es uno de los elementos que más se ha estudiado por la importancia que ejerce en la producción de cultivos. Por otro lado, el magnesio que es considerado como el elemento olvidado (Cakmak y Yazici, 2010), juega un papel importante en el rendimiento y la calidad de los cultivos, debido a la funcionalidad dentro de la molécula de clorofila que es la encargada del proceso de fotosíntesis. Por consiguiente, la deficiencia de magnesio pasa a ser un importante factor limitante en producción intensiva, principalmente en suelos fertilizados con nitrógeno, fosforo y potasio (Cakmak y Yazici, 2010). Estos dos elementos están estrechamente relacionados por formar parte del complejo de la molécula de clorofila, por lo tanto; un buen suministro de estos nutrimentos se reflejará en una buena producción.

Para generar nuevas alternativas de diagnóstico nutrimental se están generando técnicas prácticas diferentes a las convencionales. El área del análisis de imágenes va en aumento debido a lo simple en el manejo de cantidades de imágenes digitales. La finalidad del estudio de imágenes es cuantificar las propiedades que nos proporciona una imagen, a partir de los elementos que la componen (Lira, 2010). Por lo tanto, una imagen nos proveerá de información como los valores en espacios de colores, así como la textura, que muestran un potencial para predecir deficiencias de nutrimentos.

Una imagen espectral consiste en medir la intensidad de luz que refleja la superficie de un material, esta luz reflejada contiene información sobre el material que absorbe cerca de la superficie. Y mediante el uso de longitudes de ondas específicas es posible construir las características espectrales de un material. En este caso, la intensidad de la reflectancia de la superficie se pueden medir a longitudes de onda específicas (Park *et al.*, 2002).

La textura de la imagen se ha utilizado para la segmentación y clasificación con resultados alentadores. Burks *et al.* (2000) desarrollaron un método para clasificar especies de malezas utilizando características de textura, color y análisis discriminante con excelente precisión. Para ello, utilizaron el método de co-ocurrencia de color (MCC). Este método tiene la capacidad de discriminar entre varios tipos de doseles sin importar la escala y la posición de las hojas.

En la investigación realizada por Meyer *et al.* (1998) para distinguir de malezas utilizaron cuatro características clásicas de textura, segundo momento angular, entropía, inercia y homogeneidad local derivados del método co-ocurrencia para los análisis discriminantes. La clasificación de malezas de hoja ancha y pastos tuvo una precisión del 93 y 85%, respectivamente. Y las especies individuales tuvieron una exactitud de clasificación variable entre 30 y 77%.

Pydipati *et al.* (2006) reportan una precisión del 95% utilizando características de textura, de tono y de saturación, utilizando el método de co-ocurrencia para identificar hojas normales y enfermas en cítricos.

Tang *et al.* (2003) desarrollaron un método de reconocimiento de patrones para clasificar mediante textura las malezas con una eficacia de clasificación del 100%. El método consta de un algoritmo de extracción de características basada en ondas Gabor de bajo nivel y un algoritmo de reconocimiento de patrones basado en redes neuronales de alto nivel, para clasificar las imágenes de malezas de hojas anchas y de pastos para la aplicación de herbicida selectivos en tiempo real.

Kim *et al.* (2009) reportan que mediante el método de co-ocurrencia de color es posible diferenciar hojas en ocho condiciones entre las que destacan deficiencias de Fe, Mn y Zinc. Utilizaron análisis discriminante y generaron tres modelos con distintas variables obteniendo precisiones del 86.6, 95.6 y 97.33 %

El método de co-ocurrencia de color introducido por Haralick *et al.* (1973) intenta describir la textura mediante un muestreo estadísticamente de cómo se producen ciertos niveles de gris en relación con otros niveles de gris. El tamaño de la matriz se determina por el número de niveles de en la representación de la imagen. Para reducir el número de niveles de gris en la imagen, y por lo tanto el tamaño de la matriz, se utiliza a menudo la cuantificación. Se requiere una matriz separada para cada distancia y ángulo par. Para representar todos los posibles ángulos y distancias se requeriría de un número inviable de matrices, por lo que normalmente se utilizan sólo unas pocas orientaciones y distancias (Blunsden, 2004).

Con base en investigaciones anteriores, existe la posibilidad de utilizar el MCC en características texturales en conjunto con valores de color para hacer la clasificación de deficiencias de nitrógeno y magnesio. En relación a las investigaciones con enfoque a generar clasificadores que pronostiquen deficiencias de algunos elementos nutritivos mediante redes neuronales existen pocos estudios.

En términos generales, la motivación del presente trabajo es considerar alternativas como los clasificadores mediante redes neuronales para distinguir entre deficiencias de nitrógeno y magnesio, las cuales son similares en su apariencia. Por esta razón y aunado a la escasa información sobre clasificadores de elementos nutritivos en las plantas superiores se planteó esta investigación con el objetivo de desarrollar un clasificador de red neuronal utilizando características texturales y de color capaz de predecir el grado de deficiencia de nitrógeno y magnesio.

MATERIALES Y MÉTODOS

Hojas utilizadas

Las hojas de frijol utilizadas en este estudio se cultivaron en un invernadero del Área de Nutrición Vegetal del Colegio de Postgraduados, Campus Montecillo en Texcoco, Estado de México, en ciclo P-V. Como material vegetal se utilizó frijol mezcla-negro CP Mon-2011. La producción de plántulas se llevó a cabo en dos charolas de 77 cavidades utilizando como sustrato perlita. En cada una de las cavidades se colocó una semilla. Durante el proceso emergencia, las plantas se regaron con agua destilada únicamente. Se trasplantó a los 22 días después de la siembra en vasos de poliestireno, en los cuales se llenó con perlita hasta el 85% de un volumen de 1000 mL. A partir de esta fecha las plántulas se regaron con solución nutritiva Steiner en los tratamientos correspondientes (Cuadro 4 y 5). A los 30 días después de la aplicación de los tratamientos se seleccionaron hojas recientemente maduras para este estudio.

Cuadro 4. Descripción de los cinco tratamientos.

Identificación	Tratamientos	Contenido nutrimental	
		NO ₃ ⁻ (%) [*]	Mg ²⁺ (%) [*]
T1	Sin N	0	100
T2	Sin Mg	100	0
T3	Deficiente I N y Mg	25	25
T4	Deficiente II N y Mg	50	50
T5	Solución completa	100	100

* En relación a la solución nutritiva universal de Steiner.

Cuadro 5. Descripción de los ocho tratamientos.

Identificación	Tratamientos	Contenido nutrimental	
		NO ₃ ⁻ (%)	Mg ²⁺ (%)
T1	Sin N y Mg	0	0
T2	Sin N	0	100
T3	Sin Mg	100	0
T4	Deficiente I de N y Mg	25	25
T5	Deficiente II de N y Mg	25	50
T6	Deficiente III N y Mg	50	25
T7	Deficiente IV N y Mg	50	50
T8	Solución completa	100	100

* En relación a la solución nutritiva universal de Steiner.

Obtención de las imágenes

Las muestras de hojas de las plantas de frijol se digitalizaron inmediatamente después de cortarlas para mantener el nivel de humedad. Las imágenes digitales se obtuvieron digitalizando un tapiz de hojas recientemente maduras por repetición de cada tratamiento con un escáner comercial a 300 dpi (puntos por pulgada), y almacenadas en formato JPEG. Posterior a la digitalización de las hojas, se identificaron los pecíolos centrales de las hojas a la cuales se le tomaron seis sub-muestras por repetición al tratamiento 1, (hojas pequeñas, derivado del tratamiento) y al resto de los tratamientos 10 sub-muestras por repetición. Se obtuvieron en total 48 sub imágenes para el Tratamiento 1 cuando se utilizaron cinco tratamientos y del T1 y T2 cuando se utilizaron ocho tratamientos, y 80 sub imágenes para los demás tratamientos, con dimensiones de 100 x 100 píxeles. Este proceso se realizó utilizando el software GIMP 2.8.4.

Obtención de las características de color

Con un programa en Visual Basic v. 6 (Microsoft) se obtuvieron los valores de reflectancia en el espacio de color RGB, CIE-Lab, Cr y Hue de cada pixel de las sub imágenes de los pecíolos centrales de las hojas.

Análisis de textura

Metodología de co-ocurrencia de color

Haralick et al. (1973) presenta el procedimiento general para extraer propiedades de textura a partir de datos de imagen en el dominio espacial.

Primeramente, el espacio de color RGB de la imagen es transformado a otra representación de color, tono, saturación e intensidad (HSI). Para obtener el valor de intensidad se utiliza el valor medio de los tres valores RGB. Los valores de tono y saturación se determinan utilizando una transformación geométrica de la Comisión Internacional de Iluminación (CIE) del diagrama de cromaticidad (Ohta, 1985). Una vez que la imagen RGB se transformó en mapas de píxeles HSI, cada mapa de píxeles es utilizado para generar una matriz de co-ocurrencia de color, lo que resulta en tres matrices de del método de co-ocurrencia de color. Es decir, una matriz para cada uno de los píxeles de HSI. Y a través de la utilización de matrices de dependencia de nivel de grises espaciales, se aplicó el método de análisis de la textura de co-ocurrencia de color.

La matriz de co-ocurrencia se basan en el recuento del número de combinaciones diferentes de cada uno de los píxeles de la imagen en cuanto a la variación con respecto al pixel vecino en cuatro direcciones: horizontal, vertical, diagonal izquierdo y diagonal derecho (0° , 45° , 90° y 135°) conformando un arreglo matricial basado en las frecuencias de ocurrencia de cada tono con respecto a las cuatro direcciones. Finalmente se obtiene los valores texturales de la imagen promediando las frecuencias de las cuatro direcciones.

La metodología de co-ocurrencia de nivel de gris es una manera estadística para describir mediante el muestreo la manera en que ciertos niveles de grises se producen en relación con otros niveles de gris (Kim et al., 2009).

Con respecto a lo anterior Shearer y Holmes (1990) mencionan que estas matrices miden la probabilidad de que un píxel en un determinado nivel de grises producirá una clara distancia y orientación de cualquier píxel dado ese píxel que tiene un segundo nivel de gris particular.

Extracción de características de textura

Con un programa en Visual Basic v. 6 (Microsoft) se obtuvieron los valores de las cuatro características texturales: segundo momento angular, entropía, homogeneidad local e inercia. Fueron representadas mediante las siguientes formulas:

1. Segundo momento angular (SMA). Llamada también uniformidad, es una medida local de la homogeneidad y es la característica opuesta a la entropía. Es un estadístico de segundo orden en el dominio espacial. Valores altos son indicadores de uniformidad en los pixeles (Jensen, 2006). Esta característica textural se calculó con la siguiente ecuación:

$$\sum_{i=1}^n \sum_{j=1}^m [p_{ij}(\delta, \theta)]^2$$

2. Entropía (EN). Esta característica textural es un estadístico que analiza la aleatoriedad. Valores pequeños en el rango 0 y 1 indican uniformidad (Jensen, 2006). También es una medida estadística de la aleatoriedad y que puede usarse para caracterizar la textura de la imagen entrante. Se calculó con la siguiente ecuación:

$$\sum_{i=1}^n \sum_{j=1}^m p_{ij}(\delta, \theta) \log[p_{ij}(\delta, \theta)]$$

3. Homogeneidad local (HoL). Es una medida del contraste. Al incrementar el contraste, disminuye la homogeneidad local. Esta característica textural también es llamada momento de diferencia inversa. Se calcula con la siguiente ecuación:

$$\sum_{i=1}^n \sum_{j=1}^m 1/[1 + (i - j)^2] p_{ij}(\delta, \theta)$$

4. Inercia (INE): Se utiliza para caracterizar las reglas de ubicación y la unidad patrón de texturas periódicas y así detectar la periodicidad de los patrones de textura y determinar el gradiente de textura. Es calculada con la siguiente fórmula:

$$\sum_{i=1}^n \sum_{j=1}^m (i - j)^2 p_{ij}(\delta, \theta)$$

Modelado de la red neuronal artificial

Finalmente, para la generación de los clasificadores de todas las categorías se introdujeron en el programa NeuroShell® Classifier Release 2.2. NeuroShell Classifier que resuelve los problemas de clasificación y categorización basados en patrones aprendidos a partir de datos históricos. Produce salidas que son las probabilidades del modelo de entrada al que pertenece cada una de las categorías, que para este caso, fueron los tratamientos de deficiencias de nitrógeno en magnesio a cierto porcentaje.

Los algoritmos de clasificación son una red neuronal y un clasificador estadístico impulsado por un algoritmo genético y se han optimizado para resolver problemas de clasificación. Las herramientas estadísticas como una matriz de acuerdo (sensibilidad y especificidad), gráficos de probabilidad, curvas ROC, y la clasificación de entrada ayudan en el análisis de la efectividad del modelo.

Entrenamiento y validación de la red neuronal artificial

Una red neuronal artificial está compuesta, conceptualmente, por una o más capas de neuronas artificiales, que son modelos matemáticos que buscan simular el comportamiento de neuronas biológicas (Alves et al., 2011). Por lo tanto, para que una red identifique correctamente las entradas es necesario un entrenamiento adecuado con un conjunto de patrones que representen un comportamiento satisfactorio para posteriormente, reconozca el patrón que está siendo entrenado (Haykin, 2001).

Para esta investigación, un conjunto de 221 sub-muestras aleatorizadas se entrenaron en el programa NeuroShell® Classifier, con el “método neural” de entrenamiento, que se basa en un algoritmo llamado Turboprop2, que es una variante del famoso algoritmo de correlación cascada inventado en la Universidad Carnegie Mellon por Scott Fahlman. TurboProp2 aumenta dinámicamente la secuencia de neuronas ocultas muy rápido.

Las variables que se entrenaron en diferentes combinaciones fueron las cuatro características texturales (SMA, ENT, INE, HL) y los espacios de colores RGB y CIE Lab, además del croma y hue. Del entrenamiento y la validación se consideraron importantes los datos que se muestran en el Cuadro 6 y 9.

Después de que la red neuronal ha sido entrenada, está apta para realizar las clasificaciones, utilizando el conocimiento adquirido para inferir sobre las situaciones reales de análisis. Acto seguido del entrenamiento se realizó el procedimiento de validación. Para este proceso se validaron 127 sub-muestras aleatorizadas de cada combinación de las variables estudiada pertenecientes al mismo grupo entrenado. Las muestras de validación eran presentadas a la red neuronal después de cada ciclo de entrenamiento de las variables utilizadas.

Es importante tomar en cuenta que las mismas variables que se utilizaron en el entrenamiento, deben de ser utilizadas en la validación para generar el clasificador para esas variables.

RESULTADOS

Entrenamiento y validación del grupo de datos con cinco tratamientos

Las variables utilizadas en el proceso de entrenamiento y validación considerando cinco clases de salida son representativas de las situaciones de ocurrencia de la interacción de la deficiencia de nitrógeno y magnesio (Cuadro 6).

Cuadro 6. Combinación de variables utilizadas en el proceso de entrenamiento y validación considerando cinco clases de salida (0% de N - 100% Mg; 100% de N - 0% Mg; 25% de N - 25% Mg; 50% de N - 50% Mg; y 100% de N - 100% Mg).

Número de Clasificador	Variables (neuronas de entrada)	Entrenamiento		Validación	
		CC (%)	#ON	GEN (%)	CC (%)
1	SMA, EN, INE HoL	71.04	62	86	55.78
2	SMA, EN, INE	69.68	48	44	55.10
3	HOL, SMA, EN	69.68	50	SIN	55.78
4	R, G, B	88.24	26	17	80.95
5	CIE-Lab	86.88	41	SIN	81.63
6	R, G, B, CIE-Lab	97.74	98	32	87.07
7	R, G, B, CIE- a	95.93	66	47	89.80
8	SMA, EN, INE, HoL, R, G, B, L, a, b	99.10	92	48	88.44
9	SMA, EN, INE HoL, L, a, b, C, H	99.55	81	25	85.71
10	SMA, EN, INE HoL, R, G, B, L, a, b, C, H	99.55	69	49	86.39

Canales rojo (R), verde (G) y azul (B) del espacio de color RGB; Canales L, a y b del espacio de color CIE-Lab; croma (C), y matiz (H); segundo momento angular (SMA), entropía (EN), inercia (INE) y homogeneidad local (HoL); %CC= porcentaje de clasificaciones correctas; #ON= número óptimo de neuronas en la capa interna y % GEN= porcentaje de generalización.

En el cuadro 6 se observa que los clasificadores de redes neuronales artificiales (RNA) utilizando únicamente variables de color y la combinación de color con texturas presentan un alto porcentaje de confiabilidad al momento de predecir la deficiencia de la interacción nitrógeno-magnesio. Por lo contrario, las características de texturas por sí solas no generan clasificadores confiables.

También podemos notar que el aumento en el número de neuronas de entrada y el número óptimo de la capa interna mejora en algunos clasificadores sustancialmente la precisión del clasificador, tal es el caso del clasificador 6, 8 y 9.

Por lo tanto, la estructura de los patrones de entrenamiento puede representarse como una red neuronal con pocas o muchas neuronas en la capa interna, siempre y cuando se elijan las variables de entrada más representativas del problema a resolver para generar un clasificador con un alto porcentaje de aceptabilidad.

De los clasificadores de redes neuronales que se proponen, el clasificador 7 (Cuadro 7) con la combinación de variables R, G, B, y CIEa es el que presenta mayor estabilidad en cuanto al porcentaje de sensibilidad. Donde se observa, que un alto porcentaje (>84%) de todos tratamientos individuales se clasifican correctamente en el tratamiento correspondiente, habiendo poca atribución a otros tratamientos, excepto en el tratamiento 1 con un 78.95% clasificados correctamente y el resto del porcentaje de clasificación incorrectamente para este tratamiento son atribuidos a los Tratamientos 3, 4 y 5. Para esto, se tiene en el Cuadro 8 que el T1 atribuye un 96.1% al T4, 92.4% al T5 y dos observaciones más (67.4 y 55.3%) clasificadas como T3.

En el cuadro 8 se presenta el grado de atribución a los tratamientos equivocados del mejor clasificador en donde se puede observar que algunos tratamientos son clasificados en tratamientos no correspondientes. Por ejemplo en la fila 2 se observa que el T1 (0% de N y 100% de Mg) fue clasificado en un 96.1% como T4 (50% de N y 50% de Mg), es decir, por alguna razón el clasificador asocia las

características de color R, G, B y CIE-a del T1 como similares al T4. De igual manera en la fila 53 y 78 se observa que el T3 (25% de N y 25% de Mg) fue clasificado como T4 (50% de N y 50% de Mg) en un 99.7%, asociando sus características a este último tratamiento.

Cuadro 7. Estadísticas del arreglo matricial de las variables R, G, B y CIEa.

	Actual "1"	Actual "2"	Actual "3"	Actual "4"	Actual "5"	Total
Clasificado como "1"	15	0	0	1	0	16
Clasificado como "2"	0	31	3	1	0	34
Clasificado como "3"	2	1	27	1	0	31
Clasificado como "4"	1	0	2	30	3	36
Clasificado como "5"	1	0	0		29	30
Total	19	32	32	32	32	147
Radio Verdadero-pos.	0.7895	0.9688	0.8438	0.9375	0.9063	
Radio Falso-pos.	0.0078	0.0261	0.0348	0.0522	0.0087	
Radio Verdadero-neg.	0.9922	0.9739	0.9652	0.9478	0.9913	
Radio Falso-neg.	0.2105	0.0313	0.1563	0.0625	0.0938	
Sensibilidad	78.95%	96.88	84.38%	93.75%	90.63%	
Especificidad	99.22%	97.39%	96.52%	94.78%	99.13%	

El clasificador 7 es el que obtuvo el mayor porcentaje de sensibilidad utilizando únicamente características de color, al igual que el clasificador 6 con variables R, G, B y CIE-Lab con 87.07% de confiabilidad. Sin embargo, utilizando

combinaciones de color con texturas se obtienen clasificadores con bastante precisión como lo muestran los clasificadores 8, 9 y 10.

Cuadro 8. Grado de atribución al tratamiento equivocado para la combinación de variables R, G, B y CIE-a.

Fila	Actual	Clasificado	Tratamientos o clases de salida				
			1	2	3	4	5
2 *	1	4	0.035	0.000	0.000	0.961	0.003
9 *	1	5	0.075	0.000	0.000	0.001	0.924
10 *	1	3	0.002	0.000	0.553	0.259	0.001
15 *	1	3	0.066	0.000	0.674	0.0000	0.005
43 *	2	3	0.000	0.120	0.880	0.000	0.000
53 *	3	4	0.000	0.000	0.000	0.997	0.003
65 *	3	2	0.000	0.656	0.344	0.000	0.000
66 *	3	2	0.001	0.697	0.303	0.000	0.000
72 *	3	2	0.000	0.929	0.071	0.000	0.000
78 *	3	4	0.000	0.000	0.000	0.997	0.003
107 *	4	3	0.046	0.000	0.939	0.015	0.000
113 *	4	1	0.707	0.000	0.292	0.001	0.000
130 *	5	4	0.000	0.000	0.000	0.649	0.351
140 *	5	4	0.000	0.000	0.000	0.994	0.005
142 *	5	4	0.001	0.000	0.000	0.744	0.255

Entrenamiento y validación del grupo de datos con ocho tratamientos

En el Cuadro 9 se presentan los clasificadores entrenados y validados considerando 8 clases de salidas equivalentes a los tratamientos del Cuadro 5, con las mismas combinaciones de las variables de color y textura. En este cuadro se puede apreciar claramente que cuando se entrenan y validan los ocho tratamientos no se generan clasificadores confiables; esto debido a que en el proceso de la validación muchos de los tratamientos individuales se confunden con otros tratamientos al que no corresponden, ocasionado por los tratamientos

evaluados, ya que algunos tratamientos visualmente manifiestan características o patrones similares aun cuando se trate de deficiencias de N o Mg a cierto porcentaje.

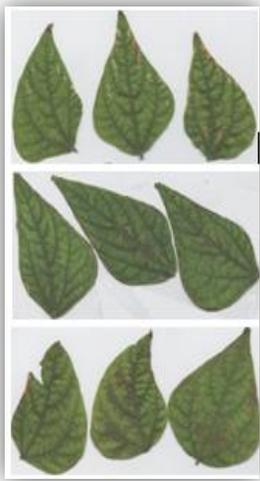
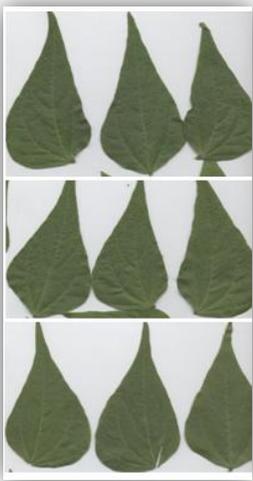
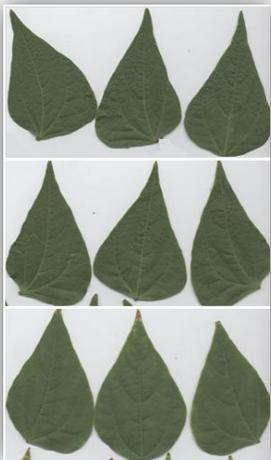
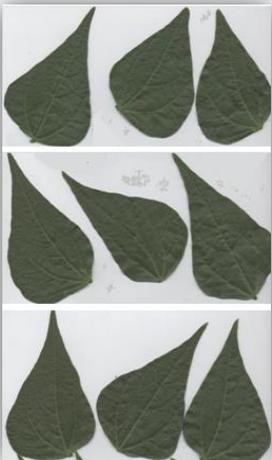
Cuadro 9. Combinación de variables utilizadas en el proceso de entrenamiento y validación considerando ocho clases de salida (0% de N - 0% Mg; 0% de N - 100% Mg; 100% de N - 0% Mg; 25% de N - 25% Mg; 25% de N - 50% Mg; 50% de N - 25% Mg 50% de N - 50% Mg; y 100% de N - 100% Mg).

Número de Clasificador	Variables (neuronas de entrada)	Entrenamiento		Validación	
		CC (%)	#ON	GEN (%)	CC (%)
1	SMA, EN, INE HoL	51.73	88	60	38.70
2	SMA, EN, INE	48.55	45	48	40.87
3	HOL, SMA, EN	47.98	76	25	40
4	R, G, B	69.08	95	sin	58.70
5	CIE-Lab	68.21	88	1	59.13
6	R, G, B, CIE-Lab	85.55	98	67	72.17
7	R, G, B, CIE- a	75.72	85	5	70.87
8	SMA, EN, INE, HoL, R, G, B, L, a, b	89.31	99	3	66.96
9	SMA, EN, INE HoL, L, a, b, C, H	89.02	90	36	66.09
10	SMA, EN, INE HoL, R, G, B, L, a, b, C, H	91.33	91	55	70.87

Canales rojo (R), verde (G) y azul (B) del espacio de color RGB; Canales L, a y b del espacio de color CIE-Lab; croma (C), y matiz (H); segundo momento angular (SMA), entropía (EN), inercia (INE) y homogeneidad local (HoL); %CC= porcentaje de clasificaciones correctas; #ON= numero optimo de neuronas en la capa interna y % GEN= porcentaje de generalización.

Se puede apreciar en el Cuadro 10 que visualmente algunas deficiencias son parecidas. Por ejemplo, los Tratamientos 4 y 5 (25% N- 25% Mg y 25% N - 50% Mg, respectivamente) en apariencia no existe tanta diferencia visual aunque únicamente la diferencia es de un 25% más de Mg. Los Tratamientos 6 y 7 (50% N- 25% Mg y 50% N - 50% Mg, respectivamente) aparentemente no manifiestan diferencias en el verdor de las hojas comparado con el T8 (Testigo, solución Steiner completa), e incluso en tamaño son comparables, aunque en la investigación no se tomó el peso de materia seca.

Cuadro 10. Imágenes digitales de los distintos tratamientos evaluados.

Tratamiento 1 (0% N- 0% Mg)	Tratamiento 2 (0% N- 100% Mg)	Tratamiento 3 (100% N- 0% Mg)	Tratamiento 4 (25% N- 25% Mg)
			
Tratamiento 5 (25% N- 50% Mg)	Tratamiento 6 (50% N- 25% Mg)	Tratamiento 7 (50% N- 50% Mg)	Tratamiento 8 (100% N- 100% Mg)
			

Comparación de grupo de datos

Comparando los resultados obtenidos en cada uno de los grupos de datos podemos apreciar que cuando se utilizan más clases de salida existe mayor error en la clasificación, aunque se utilicen las mismas variables de entrada. Por lo tanto, la información que recibe el clasificador es importante, ya que de eso dependerá el resultado final.

Para esta investigación en particular, el clasificador del grupo de ocho clases confundió algunos tratamientos asumiendo que los datos provenían de una misma clase o tratamiento, razón por la cual se decidió utilizar únicamente cinco tratamientos representativos para la generación de un buen clasificador. Se observó mayor confusión en los Tratamientos 4 y 5 (25% N – 25% Mg y 25% N – 50% Mg, respectivamente) y los Tratamientos 6 y 7 (50% N – 25% Mg y 50% N – 50% Mg, respectivamente), por ello se optó por dejar únicamente los Tratamientos 4 y 6 (25% N – 25% Mg y 50% N – 50% Mg, respectivamente) para la generación del clasificador que se muestra en el cuadro 7 .

Derivado de la información proporcionada por los dos grupos de datos se eligió el clasificador generado a partir de cinco tratamientos o clases, ya que resulta menos complejo el desarrollo del clasificador dado que de esta manera no existe alta confusión entre los tratamientos individuales, atribuyéndole el peso al tratamiento correspondiente.

DISCUSIÓN

Las redes neuronales artificiales (RNA) han sido utilizadas en distintos trabajos de investigación, relacionados a analizar tendencias o patrones.

La textura y la información de color son dos atributos que se pueden manipular para obtener contenidos de las imágenes. Estas dos características se pueden utilizar para la creación de clasificadores que permitan resolver problemas.

Burks et al. (2000) llevaron a cabo una investigación utilizando el método de co-ocurrencia de color y análisis discriminante para clasificar malezas usando características texturales y de color (HSI). La técnica del análisis discriminante fue utilizada para identificar las combinaciones del método de co-ocurrencia de color de las características de textura. Encontraron que este método tiene una excelente precisión (96.7%) en la clasificación de especies de malas hierbas en general, así como una alta precisión individual en la clasificación de especies (90%) con el menor número de variables de textura. De igual forma, la precisión clasificaciones arriba del 93% se lograron utilizando únicamente las características de tono y saturación. Lo anterior coincide con los resultados de esta investigación, en donde la precisión más alta se obtuvo utilizando únicamente los valores del espacio de color R, G, B y el CIEa, seguido del clasificador con las variables de los espacios de color R, G, B y CIELab.

Utilizando únicamente las características texturales en este trabajo de investigación, no se logra obtener una precisión significativa, en relación a lo que mencionan Burks et al. (2000), en donde obtuvieron excelentes resultados utilizando únicamente estas características.

Con respecto al método de co-ocurrencia de color, Cope *et al.* (2010) lo comparó con los métodos de Gabor y Fourier para clasificar textura de hojas de 15 especies de *Quercus*. Llegando a la conclusión que el método Fourier captura los detalles

más finos, mientras que la matriz de co-ocurrencia se desempeña mejor en las imágenes de contrastes altos entre los píxeles vecinos, es decir en características de texturas.

Por otro lado, Pydipati *et al.* (2006) realizaron una investigación en cítricos utilizando el método de co-ocurrencia de color para determinar si la textura y las características de color basadas en tonalidad, saturación e intensidad (HSI) en conjunto con algoritmos de clasificación estadísticos, podrían ser utilizadas para identificar hojas normales y enfermas en cítricos. Encontraron que utilizando el método de co-ocurrencia de color, la precisión de clasificación es de más del 95%, utilizando características de textura, de tono y de saturación. Sin embargo, con la característica de intensidad la precisión se redujo, debido a la alta pigmentación del haz de las hojas.

Las redes neuronales, también se han utilizado únicamente para reconocimiento de patrones. Tang *et al.* (2003) desarrollaron un modelo con un método que consta un algoritmo de extracción de características basada en ondas Gabor de bajo nivel, para clasificar las imágenes de hierbas de hojas anchas y de pastos para la aplicación de herbicidas selectivos en tiempo real. Concluyen que este método tiene 100% de eficacia al momento de clasificar la hoja ancha y el pasto.

Es evidente, que la creación de clasificadores mediante redes neuronales utilizando únicamente los colores es más eficiente, y que las texturas solo funcionan en combinación con colores. Estos debido a que los nutrimentos estudiados están más asociados con cambios de color en la hoja a partir de la importancia que ejercen en la molécula de clorofila y no presentan cambios sustanciales en cuanto a la textura aun en tratamientos con deficiencias. Lo anterior, significa que el impacto está más dado por la coloración o verdor que en cambios en la superficie de la hoja.

También hay que considerar otros elementos para el desarrollo de la presente metodología. Tal es el caso de los criterios a utilizar al momento de escoger la hoja recientemente madura de estudio. Una investigación realizada en trigo (Jiménez, 2009) concluyó que ciertamente la hoja recientemente madura es la adecuada para ser utilizada en estos trabajos, ya que esta hoja manifestará el déficit de abastecimiento de los nutrimentos, debido a que las hojas adultas traslocarán el nutrimento a las hojas en proceso de desarrollo. Y el movimiento del elemento implica la destrucción de la clorofila en los tejidos adultos, promoviendo la formación de este pigmento en los tejidos recientes. Aun con el resultado anterior, habría que uniformizar los criterios para cada cultivo al momento de realizar una investigación como la presente debido a que cada investigador utilizará su propio criterio para escoger la hoja de estudio.

Otro factor importante, es la etapa fenológica del cultivo, ya que como se sabe en cada etapa de desarrollo la planta necesita más o menos del elemento nutrimental dependiendo de la demanda. El nitrógeno es un elemento primordial para el crecimiento vegetativo, la floración y la fructificación de árboles frutales; mientras que el magnesio su desempeño radica en la estructura de la clorofila (Mengel y Kirkby, 1987; Thomson y Weier, 1962). Es por eso, que se tomó como referencia la etapa de floración para el desarrollo de esta investigación. Sin embargo, hay que considerar que los resultados obtenidos van a variar si se toman estos mismos datos en otras etapas fenológicas causado por la demanda del cultivo en ese momento.

Finalmente, con esta investigación se pretende dar a conocer que las características de color son indicadores que nos proveen de información para predecir deficiencias de nitrógeno y magnesio. Por ello, se pone en manifiesto en el clasificador donde se utilizan todas las características de color R, G, B y CIE - se clasifica correctamente el 89. 8%, siendo este un valor alto considerando que se usó únicamente 66 neuronas de la capa interna.

Todas las combinaciones de las variables y textura de los cinco tratamientos produjeron valores > del 80% para clasificar las deficiencias de nitrógeno y magnesio, diferenciándose en el número de neuronas utilizadas por el programa. El uso de un menor número de neuronas a menudo aumenta la probabilidad del algoritmo de aprendizaje aprovechándose en los mínimos locales. Por otro lado, el aumento del número de neuronas prolonga el tiempo de entrenamiento y también puede causar problemas de sobreajuste, memorizando patrones de entrenamiento en lugar de generalizar la predicción. Sin embargo, para empezar el programa NeuroShell Classifier proporciona un número predeterminado de neuronas ocultas.

CONCLUSIONES

La aportación de esta investigación radica en la posibilidad de alimentar una red neuronal con valores de textura y de colores obtenidos a través de una imagen. Para esto, se desarrollaron clasificadores que determinan el grado de deficiencia de nitrógeno y magnesio en la planta de frijol.

Concluimos que el clasificador con variables de color R, G, B y CIE-a obtenido de los datos de cinco tratamientos es el adecuado para predecir la deficiencia conjunta de nitrógeno y magnesio, con valores altos en la precisión, económicamente factible al tratarse de un método sencillo y práctico.

REVISIÓN BIBLIOGRÁFICA

Alves, M. L., Ferreira, B. B., y Leta, F. R. (2011). Evaluación de parámetros de rugosidad usando análisis de imágenes de diferentes microscopios ópticos y electrónicos. *Información tecnológica* 22(4): 129-146.

Blunsden, S. (2004). *Texture classification using non-parametric markov random fields*. University of Edinburgh, School of Informatics.

Burks, T. F., Shearer, S. A., Gates, R. S., & Donohue, K. D. (2000). Backpropagation neural network design and evaluation for classifying weed species using color image texture. *Transactions of the ASAE* 43(4): 1029-1037.

Cakmak, I., & Yazici, A. M. (2010). Magnesium: a forgotten element in crop production. *Better Crops* 94(2): 23-25.

Cope, J. S., Remagnino, P., Barman, S., & Wilkin, P. (2010). Plant texture classification using gabor co-occurrences. *In: Advances in Visual Computing* (pp. 669-677). Springer Berlin Heidelberg.

De la Cruz, D. J. A. 2013. *Reflectancia en hojas de pimienta y fresa para el diagnóstico nutrimental*. Tesis de Doctorado en Ciencias. Colegio de postgraduados, Montecillo, México. 88 p.

Haralick, R. M.; Shanmugan, K. and Dinstein, I. 1973. Textural features for images classification. *IEEE Transactions on systems, man and cybernetics* 3:6 610 – 621.

Haykin, S. (2001). *Neural networks: A comprehensive foundation*. Prentice Hall.

Jensen, J.R. 2006. *Introductory digital image processing: A remote sensing perspective*. Prentice Hall. Englewood Cliffs, NJ. USA.

Jimenez, M. V. M. 2009. Propiedades ópticas de trigo y deficiencias de nitrógeno. Tesis de Maestría en ciencias. Colegio de Postgraduados, Montecillo, México. 58 p.

Li, X., Nour, M. H., Smith, D. W., & Prepas, E. E. (2010). Neural networks modelling of nitrogen export: model development and application to unmonitored boreal forest watersheds. *Environmental technology* 31(5): 495-510.

Meyer, G. E., Mehta, T., Kocher, M. F., Mortensen, D. A., and Samal, A. (1998). Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. *Transactions of the ASAE* 41(4): 1189-1197.

Ohta, Y., 1985. Knowledge-based interpretation of outdoor natural color scenes. Pitman Publishing. Marshfield, MA, USA.

Park, B., Lawrence, K. C., Windham, W. R., Chen, Y. R., and Chao, K. (2002). Discriminant analysis of dual-wavelength spectral images for classifying poultry carcasses. *Computers and Electronics in Agriculture* 33(3): 219-231.

Pydipati, R., Burks, T. F., & Lee, W. S. (2006). Identification of citrus disease using color texture features and discriminant analysis. *Computers and electronics in agriculture* 52(1): 49-59.

Shearer, S. A., & Holmes, R. G. (1990). Plant identification using color co-occurrence matrices. *Transactions of the ASAE* 33(6): 2037-2044.

Tang, L., Tian, L. F., Steward, B. L., y Reid, J. F. (2003). Texture-based weed classification using gabor wavelets and neural network for real-time selective herbicide applications. *Urbana* 51: 61801.

VII. DISCUSIÓN GENERAL

Diagnóstico de deficiencias de nitrógeno y magnesio con imágenes digitales

La información proporcionada permitió establecer que cualquier cambio detectado por el sensor al momento de digitalizar las hojas se debió a las concentraciones de N y Mg, dando como resultado valores de reflectancia para cada uno de los tratamientos.

Cuando se aplica N y Mg en porcentajes bajos en la solución nutritiva el valor de reflectancia aumenta en los canales de color rojo, verde y azul y disminuye conforme se aumenta el porcentaje de estos elementos. Esto se puede atribuir principalmente a que en los tratamientos con menores concentraciones de N presentan una menor concentración de clorofila (Curran *et al.*, 2001), pero como también el Mg es parte de la estructura de la clorofila, por eso afecta directamente la presencia de ésta, y por lo tanto la reflectancia aumenta. Mientras que un cultivo saludable nutrimentalmente presentará bajas reflectancias en la región visible del espectro electromagnético principalmente a la intensa absorción de la molécula de clorofila (Thomas y Oerther, 1972).

Con lo que respecta a la concentración de N y Mg en la solución nutritiva tuvieron un efecto estadísticamente significativo en los valores de CIE-Lab.

La interacción de la concentración de N-Mg en la solución nutritiva tuvo un efecto significativo sobre los valores de CIE-L. Los T2 (25% N-50% Mg) y T1 (25% N-25% Mg) presentaron los valores más altos de CIE-L. Caso contrario con los valores CIE-a que se observó en hojas del T5 (100% de N y Mg).

Los tratamientos tuvieron un efecto estadísticamente significativo sobre los valores de CIE-b, en donde el menor valor lo obtuvo el T5 (100% de N y Mg). Lo que

concuerta con el trabajo realizado por Graeff *et al.* (2008) y De la Cruz (2013) quienes mencionan que al aumentar la tasa de fertilización de N en variedades de brócoli y pimiento el parámetro “b” aumenta. La relación de la reflectancia de éste parámetro y la concentración de nitrógeno y magnesio fue descrito como el mejor modelo lineal.

Se observó un efecto significativo sobre los valores de pureza de color (croma) y matiz (hue). El T2 y el T1 (25 % N- 25% Mg y 25% N-50% Mg) tuvieron el nivel más alto de pureza de color. Por lo contrario, los mayores resultados de hue se obtuvieron en hojas de los T5, T4 y T3.

Redes neuronales para clasificar deficiencias de nitrógeno y magnesio mediante características texturales y de color

Burks *et al.* (2000) llevaron a cabo una investigación utilizando el método de co-ocurrencia de color y análisis discriminante para clasificar malezas usando características texturales y de color (HSI). La técnica del análisis discriminante fue utilizada para identificar las combinaciones del método de co-ocurrencia de color de las características de textura. Encontraron que este método tiene una excelente precisión (96.7%) en la clasificación de especies de malas hierbas en general, así como una alta precisión individual en la clasificación de especies (90%) con el menor número de variables de textura. De igual forma, la precisión clasificaciones arriba del 93% se lograron utilizando únicamente las características de tono y saturación. Lo anterior coincide con los resultados de esta investigación, en donde la precisión más alta se obtuvo utilizando únicamente los valores del espacio de color R, G, B y el CIEa, seguido del clasificador con las variables de los espacios de color R, G, B y CIELab.

Utilizando únicamente las características texturales en este trabajo de investigación, no se logra obtener una precisión significativa, en relación a lo que

mencionan Burks et al. (2000), en donde obtuvieron excelentes resultados utilizando únicamente estas características.

Cope *et al.* (2010) compararon los métodos de Gabor y Fourier para clasificar textura de hojas de 15 especies de *Quercus*. Llegando a la conclusión que el método Fourier captura los detalles más finos, mientras que la matriz de co-ocurrencia se desempeña mejor en las imágenes de contrastes altos entre los píxeles vecinos, es decir en características de texturas.

Por otro lado, Pydipati *et al.* (2006) realizaron una investigación en cítricos utilizando el método de co-ocurrencia de color para determinar si la textura y las características de color basadas en tonalidad, saturación e intensidad (HSI) en conjunto con algoritmos de clasificación estadísticos, podrían ser utilizadas para identificar hojas normales y enfermas en cítricos. Encontraron que utilizando el método de co-ocurrencia de color, la precisión de clasificación es de más del 95%, utilizando características de textura, de tono y de saturación. Sin embargo, con la característica de intensidad la precisión se redujo, debido a la alta pigmentación del haz de las hojas.

Es evidente, que la creación de clasificadores mediante redes neuronales utilizando únicamente los colores es más eficiente, y que las texturas solo funcionan en combinación con colores. Estos debido a que los nutrientes estudiados están más asociados con cambios de color en la hoja a partir de la importancia que ejercen en la molécula de clorofila y no presentan cambios sustanciales en cuanto a la textura aun en tratamientos con deficiencias. Lo anterior, significa que el impacto está más dado por la coloración o verdor que en cambios en la superficie de la hoja.

VIII. CONCLUSIONES GENERALES

Algunos parámetros de reflectancia en las bandas verde y roja, además del espacio CIE-b, CIE-L y valores de croma derivados de imágenes digitales son apropiados para la estimación de concentraciones de nitrógeno y magnesio en plantas de frijol.

El clasificador con variables de color R, G, B y CIE-a obtenido de los datos de cinco tratamientos es el adecuado para predecir la deficiencia conjunta de nitrógeno y magnesio, con valores altos en la precisión, económicamente factible al tratarse de un método sencillo y práctico.

La aportación de esta investigación radica en la posibilidad de utilizar los valores de reflectancia y de textura a través de una imagen para generar alternativas en el desarrollo de técnicas que permitan predecir anticipadamente la deficiencia de nitrógeno y magnesio o de cualquier otro elemento nutrimental de interés.