

UNIVERSIDAD PANAMERICANA
FACULTAD DE INGENIERÍA

Con estudios incorporados a la
Secretaría de Educación Pública

**“Monitoreo y análisis de las hojas de las plantas de
jitomate a partir de un sistema de visión, un algoritmo
supervisado y un sistema de control semiautomático”**

T E S I S

QUE PARA OBTENER EL TÍTULO DE
MAESTRÍA EN INGENIERÍA

P R E S E N T A

CLAUDIO SEBÁSTIAN CEVALLOS VEGA

DIRECTOR DE TESIS:

DR. HIRAM EREDÍN PONCE ESPINOSA

MÉXICO, CIUDAD DE MÉXICO

FEBRERO 2020

Resumen

Con el fin de ahorrar los recursos necesarios para el cuidado de una planta de jitomate y otorgarle una mejor calidad del cultivo, se realizó el monitoreo de las características de sus hojas a través de un sistema de visión, el cual captura imágenes de la planta para analizar los rasgos y colores de éstas con un algoritmo supervisado para, finalmente, predecir el nutriente faltante en la tierra. Esto permite integrar un sistema de control semiautomático para que el usuario final pueda agregar este nutriente en el regado de manera controlada.

A lo largo de la investigación, se realizó una base de datos de fotografías con distintas características presentes en la planta de jitomate al faltarle alguno de sus principales nutrientes (nitrógeno, fósforo y potasio) para entrenar al algoritmo supervisado, con ayuda de muestras químicas realizadas en la tierra de la planta.

Durante la experimentación para entrenar al algoritmo supervisado, se utilizó un conjunto de datos creado con imágenes de hojas de planta de jitomate con características originales, contrastadas y con uso de imágenes de Internet, originales y contrastadas, para obtener la mejor exactitud posible. Gracias a los distintos experimentos, se obtuvo una exactitud de 86% con el uso de imágenes contrastadas combinadas con imágenes de Internet contrastadas para el entrenamiento.

Con los resultados obtenidos, se programó un sistema de control semiautomático donde se capturan imágenes de la planta en tiempo real. El sistema utiliza los resultados del mejor algoritmo supervisado y otorga como respuesta el nombre del nutriente faltante en la tierra de la planta. Al evaluar estos resultados, se obtuvo un 70% de exactitud en condiciones reales.

Con base en lo anterior, se tiene como ventaja el reconocimiento anticipado de los nutrientes faltantes, lo cual tiene como aplicación futura el ahorro en el uso de éstos, mejor calidad y cantidad de producto final y disminución en la contaminación de la tierra y el medio ambiente. Sin embargo, se puede mejorar la exactitud y aumentar la investigación a mayor cantidad de hortalizas, fortaleciendo así la agricultura de exactitud.

Agradecimientos.

A Dios

Por darme la oportunidad y la salud necesaria para llegar a este punto y haberme guiado y ayudado durante todo el camino a lograr mis objetivos y propósitos, además de su infinita bondad y amor.

A mis padres

Por ser el pilar fundamental y guía en todo este camino permitiéndome ser quien soy y por otorgarme la educación, académica y de vida. Y por su incondicional apoyo que nunca ha faltado. Todo ha sido posible gracias a ellos.

A mis hermanos

Andrea y Bernardo por su apoyo incondicional y constante apoyo siempre.

A mi abuelita y mi tío Jorge

Por haberme acompañado en este camino y apoyado en todo siempre.

A mis mejores amigos

Miguel Peña Campos y Cecilia Betancourt Barrita por acompañarme durante la carrera, especialidad y maestría y su apoyo y ayuda constante durante este camino.

A mi asesor de tesis

Hiram Ponce quien me guío y orientó durante este proceso para poder lograr este objetivo.

A mis maestros

Por sus enseñanzas y orientación a lo largo de mi vida.

Índice

Introducción	8
Problema de estudio	8
Novedad de la propuesta y justificación	9
Hipótesis.....	10
Objetivos generales y específicos	10
Objetivo general.....	10
Objetivos específicos.....	10
Contribuciones	10
1. Antecedentes y estado de la cuestión.....	12
1.1. Afecciones comunes en las plantas.....	12
1.1.1. Planta de jitomate	15
1.1.2. Afectaciones comunes en el jitomate	16
1.2. Soluciones tecnológicas utilizadas en agricultura	18
1.2.1. Invernaderos	18
1.2.2. Invernaderos automatizados	20
1.2.3. Sistemas de irrigación	20
1.2.4. Uso de la robótica en la agricultura	22
1.2.5. Uso de la visión artificial en la agricultura	23
1.3. Sistema de visión artificial.....	24
1.3.1. Fuente de iluminación.....	24
1.3.2. Cámara	26
1.3.3. CPU	26
1.4. Sistemas de control	27
1.4.1. Actuadores externos	28
1.5. Algoritmos de clasificación supervisados.....	28
1.5.1. Red neuronal artificial	29
1.5.2. Red neuronal profunda	30
1.5.3. Redes neuronales convolucionales	31
1.6. Resumen.....	32
2. Metodología	33
2.1. Descripción del sistema de monitoreo y control	33
2.2. Experimentación	34
2.2.1. Adquisición de datos	34
2.2.2. Pre procesamiento	38

2.2.3.	Construcción del modelo de aprendizaje máquina CNN	38
2.2.4.	Sistema de control semiautomático	39
2.2.5.	Evaluación de resultados.....	39
3.	Resultados obtenidos	41
3.1.	Experimento 1: Fotos originales.....	42
3.2.	Experimento 2: Fotos originales contrastadas.....	43
3.3.	Experimento 3: Fotos originales con fotos de internet.....	44
3.4.	Experimento 4: Fotos originales con fotos de internet contrastadas.....	45
3.5.	Monitoreo de las hojas del jitomate con el sistema de control semiautomático	47
3.6.	Resumen experimentos	50
4.	Discusión de resultados	51
	Conclusiones	53
	Referencias.....	54

Índice de figuras

Figura 1: Guía de falta de nutrientes en plantas, adaptado de [14]	13
Figura 2: Deficiencia de los principales macronutrientes en las plantas, adaptado de [17]	14
Figura 3: Planta sana (Izq.) vs planta con carencia de nitrógeno (Der.), adaptado de [6]	17
Figura 4: Deficiencia de fósforo en el jitomate adaptado de [6]	17
Figura 5: Carencia de fósforo en el jitomate, adaptado de [6]	18
Figura 6: Invernadero plano, adaptado de [29]	19
Figura 7: Invernadero en raspa y amagado, adaptado de [29]	19
Figura 8: Invernadero asimétrico, adaptado de [29]	19
Figura 9: Invernadero de cristal, adaptado de [30]	20
Figura 10: Riego por goteo, adaptado de [33]	21
Figura 11: Fertirrigación, adaptado de [34]	22
Figura 12: Diagrama componentes sistema de visión	24
Figura 13: Diagrama sistema de control	27
Figura 14: Diagrama de una red neuronal adaptado de [70]	30
Figura 15: Diagrama del prototipo para la experimentación	34
Figura 16: Diagrama del flujo de trabajo de la implementación del sistema de monitoreo basado en visión.	34
Figura 17: Muestra de todas las mediciones del jitomate	35
Figura 18: Muestra de jitomate con nitrógeno deficiente	36
Figura 19: Muestra de jitomate con potasio deficiente	37
Figura 20: Muestra de jitomate con fósforo adecuado	37
Figura 21: Muestra de jitomate con exceso de nitrógeno	37
Figura 22: Red neuronal convolucional	39
Figura 23: Gráfica de cajas y bigotes experimento 1.	42
Figura 24: Gráfica de cajas y bigotes experimento 2.	44
Figura 25: Gráfica de cajas y bigotes experimento 3.	45
Figura 26: Gráfica de cajas y bigotes experimento 4.	46
Figura 27: Gráfica de resumen de experimentos	47
Figura 28: Resultado sistema de control semiautomático: Potasio	49
Figura 29: Resultado sistema de control semiautomático: Nitrógeno	49
Figura 30: Resultado sistema de control semiautomático: Fósforo	49
Figura 31: Resultado sistema de control semiautomático: Jitomate	50

Índice de tablas

Tabla 1: Adquisición de muestras de la tierra por semana	36
Tabla 2: Exactitud del modelo cnn con fotos originales	42
Tabla 3: Exactitud del modelo cnn con fotos con contraste	43
Tabla 4: Exactitud del modelo cnn con fotos originales y fotos de internet	44
Tabla 5: Exactitud del modelo cnn con fotos originales y fotos de internet con contraste	46
Tabla 6: Resultados sistema de control semiautomático	47
Tabla 7: Resumen experimentos	50

Índice de ecuaciones

Ecuación 1: Transformación gamma	38
Ecuación 2: Porcentaje de exactitud	40

Introducción

Problema de estudio

En la actualidad, aproximadamente un tercio de los alimentos destinados al consumo humano se desperdicia en las diferentes etapas de la cadena de suministro. En [1], se estima que 40% de la producción agrícola es afectada directamente por deficientes cuidados de las plantas, siendo reactivos a plagas y enfermedades que los ejemplares presentan.

Con base en datos de la FAO¹, se estima que 1,300 millones de toneladas de alimentos se desperdician cada año en el mundo, lo que equivale a una tercera parte del alimento designado para el consumo humano [2]. Se estima que este porcentaje de alimentos desperdiciados es suficiente para alimentar aproximadamente 300 millones de personas [2]. El desperdicio existente durante la fase de producción alcanza el 28% del total evaluado. Este porcentaje supone la utilización de aproximadamente 1,400 millones de hectáreas utilizadas para alimento que no se consumirá [2]. Se considera que el desperdicio de alimentos en América Latina asciende a 127 millones de toneladas al año, lo que significa el 9.8% del desperdicio mundial [2].

El contar con prácticas agrícolas eficientes permite obtener un aprovechamiento óptimo del cultivo, disminución de contaminación ambiental y reducción de desperdicios. En la actualidad, tal como se reporta en [3], estas prácticas permiten al agricultor suministrar la cantidad de nutrientes necesarios a las plantas, en el momento que éstas lo necesitan.

Con base en los datos anteriores, se puede observar el gran porcentaje de desperdicio de alimentos presente durante la fase agrícola de la cadena de suministro, el cual se debe al escaso cuidado que se tiene sobre las plantas. Trabajar en mejores prácticas agrícolas reducirá el porcentaje de desperdicio durante esta fase, aprovechando de manera óptima los recursos y cultivos y ayudando al medio ambiente.

Uno de los productos agrícolas más importantes a nivel económico en el mundo es el jitomate. Gracias a los estándares de producción que esta fruta ha conseguido con el paso de los años, ha permitido que la demanda haya aumentado considerablemente a nivel nacional e internacional por su calidad, rendimiento y rentabilidad [4].

En México, por ejemplo, el cultivo de jitomate ha incrementado un 50% por lo que se ha necesitado una mayor superficie (54,000 hectáreas) para su cultivo [4]. Con base en datos obtenidos por la SIAP², el cultivo de jitomate ocupa el segundo lugar mientras que el chile sigue ocupando el primer lugar en los cultivos dentro de México [4].

El jitomate se ha convertido, con el paso de las décadas, en uno de los cultivos estrella

¹ Organización de las Naciones Unidas para la Alimentación y la Agricultura por sus siglas en inglés (*Food and Agriculture Organization*).

² Servicio de Información Agroalimentaria y Pesquera de México.

como cultivo comercial y cultivo en casa [5]. Este producto es utilizado en gran cantidad y variedad de platillos y se puede consumir en diferentes presentaciones; lo que permite gran aceptación por los consumidores y una de las fuentes de vitaminas y minerales presente en la dieta de éstos [5]. La importancia que el jitomate ha tenido, se ha incrementado considerablemente; por lo que la búsqueda de soluciones tecnológicas para este tipo de cultivos ha aumentado debido a los distintos aspectos mencionados anteriormente.

Una correcta fertilización en la planta de jitomate es fundamental para un buen crecimiento y desarrollo de ésta [6]. Al faltarle alguno de los principales nutrientes a esta planta, dependiendo de la fase en la que se encuentre, puede afectar en el desarrollo de sus hojas, del crecimiento en general de la planta o desarrollo del fruto. Entre los principales macronutrientes presentes en la planta del jitomate se encuentran el nitrógeno, el fósforo y el potasio [6]. Cuando la planta presenta déficit de estos nutrientes la coloración de las hojas se verá afectada, indicándonos el elemento faltante en la tierra. Cuando la planta presenta déficit de nitrógeno las hojas se pondrán de color verde limón [6]. En cambio, el déficit es de fósforo, las venas de las hojas se pondrán moradas [6]. Finalmente si la deficiencia es de potasio, los bordes de las hojas se pondrán amarillos [6].

Con el paso de los años, enfocar los avances tecnológicos en la agricultura ha tomado gran importancia. Por ejemplo, en [7, 8], se reporta que la automatización de los huertos y las tareas presentes en estos ha sido tema de investigación con el fin de tener prácticas de agricultura de precisión, seguridad en los usuarios y mejor calidad en el producto final de las plantas. Así mismo, el uso de sistemas de visión en detección de coloración de frutos, plagas y enfermedades ha tomado importancia en el campo de la agricultura para conocer el mejor momento para cosechar [9]; o si la planta presenta hojas con plaga u hongos para tratar de eliminarlos a la brevedad [10].

Es posible mediante el análisis de las características y coloración de las hojas de la planta del jitomate obtener información del estado de los nutrientes específicos de la planta, lo que permite controlar en el regado el uso de estos.

Novedad de la propuesta y justificación

Hasta donde se ha investigado, el monitoreo de las hojas de la planta del jitomate a través de un sistema de visión no se ha implementado en la actualidad. Hoy en día este control se realiza por medio de sensores (humedad y pH, entre otros) con el fin de cuidar la planta facilitando las distintas tareas que esto conlleva al usuario. Los sistemas de visión que utilizan cámaras han sido aplicados para detectar espacios vacíos para sembrar una nueva planta, la presencia de hierba mala en el área de cultivo, la necesidad de agua debido a sequedad en la tierra y el tiempo de cosecha según la coloración de ciertos frutos.

Obtener información de las características presentes en las hojas del jitomate, procesarla en un algoritmo detectando falta de algún nutriente y corregir esta ausencia a través de un sistema de control semiautomático que notifique al usuario, presenta una novedad capaz de reducir recursos y optimizar el cultivo de una planta.

Además, enfocarse en las hojas de la planta presenta una ventaja sobre el análisis de la coloración en los frutos debido a que permite realizar el monitoreo desde los primeros días de la planta hasta la cosecha final. Esto otorga la posibilidad de tener prácticas eficientes y preventivas en el cuidado de la planta.

Hipótesis

El monitoreo de las características de las hojas de la planta del jitomate mediante un sistema de visión artificial y un algoritmo de aprendizaje supervisado permite identificar el tipo de nutriente faltante en la planta.

Objetivos generales y específicos

Objetivo general

Desarrollar un sistema de visión artificial para el monitoreo y control semiautomático a través de un algoritmo de aprendizaje supervisado para predecir el tipo de nutriente faltante en una planta de jitomate mediante la inspección de sus hojas.

Objetivos específicos

- Investigar la sintomatología de la planta del jitomate ante la deficiencia de nutrientes primarios (nitrógeno, potasio y fósforo).
- Realizar un conjunto de datos compuesto por imágenes de cada uno de los síntomas³ para el algoritmo de clasificación supervisado.
- Programar y realizar pruebas experimentales con el algoritmo de clasificación.
- Programar el sistema de control semiautomático para la detección y notificación de la falta de nutrientes en una planta de jitomate.
- Realizar pruebas experimentales con el sistema completo para evaluar su efectividad.
- Analizar los beneficios y limitaciones del sistema propuesto.

Contribuciones

A partir de esta investigación se logró contribuir con los siguientes productos científicos:

- Generación de un conjunto de datos (imágenes) de hojas de plantas de jitomate, etiquetados por tipo de nutriente faltante.⁴
- Escritura de un artículo para un congreso internacional:
 - Cevallos, Claudio; Ponce, Hiram; Moya-Albor, Ernesto; Brieva, Jorge; Vision-Based Analysis on Leaves of Tomato Crops for Classifying Nutrient

³ Se define en agricultura la palabra *síntoma* como: “Reacciones o alteraciones internas o externas que sufre una planta como resultado de su enfermedad [84].”

⁴ https://github.com/ccevallo/Monitoreo_Jitomate.

Deficiency using Convolutional Neural Networks; IEEE World Congress on Computational Intelligence; Glasgow, Reino Unido; *en revisión*.

A lo largo de los siguientes capítulos se hablará de: los antecedentes y estado de la cuestión (Capítulo 1); la propuesta del sistema de visión computacional y el sistema de control semiautomático, así como la metodología a seguir en la experimentación (Capítulo 2); los resultados obtenidos (Capítulo 3); el análisis y la discusión de los datos y resultados obtenidos (Capítulo 4) y la conclusiones a las que se llegaron con la realización de este trabajo.

1. Antecedentes y estado de la cuestión

A lo largo de esta sección, se describen las principales características de la planta del jitomate, la sintomatología y características que presenta la planta ante la deficiencia de los macronutrientes (nitrógeno, potasio y fósforo) necesarios para esta. De igual forma se dan a conocer los proyectos basados en sistemas de visión artificial y sistemas de control que han sido desarrollados con fines agrícolas presentando las ventajas y áreas de oportunidad presentes en cada uno de estos.

El desarrollo e implementación de robots que ayuden a la agricultura de exactitud sería útil para tener mejor control de los cultivos. Automatizando este tipo de tareas se reduce el desperdicio que puede llegar a existir en la cosecha final, gracias a que se tiene un mejor cuidado de los cultivos y se acciona cada una de las partes del proceso en el tiempo requerido, por ejemplo, realizar la fertilización de las plantas en la fecha exacta según el crecimiento que la planta ha tenido en los días anteriores. De igual forma se logra una mayor seguridad para las personas que laboran en este tipo de tareas gracias a los sensores y programación de los robots a utilizar [7, 11, 12].

Con base en lo descrito por los autores anteriores se puede observar la importancia y necesidad de implementar nuevas tecnologías y metodologías en la agricultura buscando tener ejemplares sanos durante todo el año y en distintas temporadas comunes a las habituales.

1.1. Afecciones comunes en las plantas

Existen distintos síntomas en las hojas de las plantas que nos permiten conocer los nutrientes de los cuales carecen. En general la mayoría de las plantas responden de la misma manera a la falta de cierto nutriente. En lo que varía cada una de las plantas es en las plagas y síntomas que presentan al estar enfermas [13]. En la figura 1 se muestra una guía de falta de nutrientes en una planta [14].

Guía de falta de nutrientes



FIGURA 1: GUÍA DE FALTA DE NUTRIENTES EN PLANTAS, ADAPTADO DE [14]

Para cada uno de los síntomas existe un tratamiento diferente con el fin de que nuestra planta mejore. Los nutrientes necesarios para todo ser vivo se dividen en dos grupos, los macronutrientes y los micronutrientes. Los primeros, en los que se basará este trabajo, son los que se consumen en gran cantidad [15]. En este grupo se encuentran el nitrógeno (N), el potasio (K) y el fósforo (P). Entre los principales micronutrientes se encuentran el hierro (Fe), el zinc (Zn), el manganeso (Mn), el boro (B), el cobre (Cu), el molibdeno (Mo) y el cloro (Cl) [15]. Las características por falta o exceso de algún macronutriente serán visibles en hojas con mayor tiempo de vida, mientras que los micronutrientes son observables en nuevos brotes [15].

Al existir deficiencia de nitrógeno en las plantas, se pueden observar hojas poco desarrolladas y con coloración amarillenta (figura 2). Estas características se observan principalmente en hojas viejas, debido a que el poco nutriente presente en la planta es utilizado por las nuevas hojas. Esta disminución en el nutriente afecta directamente al fruto, teniendo como resultado una maduración acelerada y frutos pequeños de baja calidad [16]. Por otra parte, tener insuficiencia de fósforo ocasiona un débil crecimiento de la planta. Las

hojas con mayor edad cambian su coloración a un azul verdoso (figura 2). Así mismo, al presentar deficiencia de este elemento afecta al fruto y la cosecha final debido a que se retrasa la maduración y disminuye el rendimiento de la cosecha [16]. Cuando la planta carece de potasio, las hojas pierden su color verde y las puntas comienzan a teñirse color negro (figura 2); por otro lado, se alarga el periodo vegetativo, afectando directamente en el tiempo de maduración del fruto, la calidad, cantidad y la conservación del producto final [16].

NITROGEN *deficiency*

SIGNS:

Yellow or pale green leaves, stunted growth.

SOULTION:

Add coffee grounds directly to your soil or plant nitrogen-rich plants near nitrogen-deficient plants. Common nitrogen-rich plants include beans and peas.



PHOSPHOROUS *deficiency*

SIGNS:

Darkening around edges of leaves, small or absent flowers, stunted growth.

SOULTION:

Add bone meal directly to soil. You can also add used fish tank water to soil if it does not contain saltwater. This water is also a good source of nitrogen.

POTASSIUM *deficiency*

SIGNS:

Leaves with brown spots, brown or yellow veins or yellow edges. This deficiency is more susceptible to disease and drought.

SOULTION:

Bury banana peels an inch into your soil. Peels take a while to rot, so this is a method that will slowly help your plants. Banana peels also deter aphids.



FIGURA 2: DEFICIENCIA DE LOS PRINCIPALES MACRONUTRIENTES EN LAS PLANTAS, ADAPTADO DE [17]

1.1.1. Planta de jitomate

El jitomate es una planta perenne⁵ perteneciente a la familia de las Solanáceas [18] y que es cultivada como planta anual⁶ [19]. A este cultivo se le conoce científicamente como *Solanum lycopersicum* o *Lycopersicum esculentum* debido a que es parte del género *Lycopersicon*, subfamilia *Solanoideae* y tribu *Solaneae* [18, 20, 21].

Conocer la información anterior permite conocer los distintos ejemplares presentes dentro de la familia del jitomate, importante para tomar decisiones y obtener un buen cultivo.

El desarrollo de este tipo de planta puede ser de forma rastrera, recta o semirrecta y puede llegar a alcanzar los 10 m de altura; sin embargo, la estatura promedio es de 2.5 m. Existen distintas variedades de esta planta, lo que permite que se puedan cultivar en cualquier terreno de diferentes dimensiones. Esta planta es cultivada en regiones con climas templados debido a que las heladas pueden llegar a matarla [18, 19, 21, 22].

El cultivo del jitomate se puede realizar durante todo el año; sin embargo, es importante tener en cuenta las heladas y el calor extremo ya que pueden llegar a dañar a la planta. Si se busca una buena cosecha es necesario tomar en cuenta los factores anteriores y la utilización de semillas confiables y de calidad [23].

Para obtener los resultados esperados del cultivo es importante hacer una buena selección del lugar y un cultivo extensivo, considerando los siguientes criterios [20, 23]:

- No sembrar donde anteriormente se haya sembrado algún ejemplar de la familia del jitomate.
- Evitar suelos arenosos o compactos y buscar suelos con gran cantidad de nutrientes, materia orgánica y pH ligeramente ácido.
- Buscar un lugar con exposición solar y buena ventilación.

Las semillas de jitomate se pueden sembrar de distintas maneras. Se pueden utilizar bandejas con compartimientos individuales o semilleros para asegurar un buen germinado. De igual forma, se puede iniciar el cultivo en macetas colocando las semillas en hileras y al tener un crecimiento suficiente se realiza un aclareo⁷ para dejar los mejores ejemplares [20, 23].

Para un buen desarrollo del jitomate es necesario realizar un riego regular a las plantas, de esta manera se evita un desarrollo irregular y agrietamiento en los frutos [20].

⁵ Planta que vive por más de dos años [87].

⁶ Planta que en un periodo menor a un año florece, produce semillas y finalmente muere [87].

⁷ El aclareo se refiere a eliminar el exceso de plantas existentes en el cultivo una vez que éstas han crecido y alcanzado un tamaño ideal para asegurar su permanencia, con el fin de quedarse con plantas sanas que aprovechen al máximo el espacio y nutrientes para producir al máximo [85].

Cuando las plantas alcanzan algunos centímetros de altura es importante la colocación de tutores⁸ que lo ayudaran con el crecimiento futuro de las plantas y evitar que las hojas y frutos estén en contacto directo con el suelo, debido a que éstas suelen ser muy débiles para sostenerse [20, 19, 23].

Si se busca tener un buen cultivo de jitomate es importante considerar las características mencionadas anteriormente como los periodos de cultivos, temperaturas, riego y tutorado para poder trabajar antes, durante y después de tener la planta.

Mexico es considerado el principal provisor de jitomate a nivel mundial teniendo una participación en el mercado de 25.11% de todas las exportaciones mundiales [24].

Entre las principales variedades de jitomate se encuentran las siguientes: bola, saladette o roma, uva y cherry. Estos tipos se encuentran en distintos colores, tamaños y formas. El jitomate saladette o roma es un fruto ovalado, de pared gruesa con un diámetro entre 38 y 76 mm. Este tipo de jitomate representa uno de los mayores volúmenes de exportación mexicana [25].

1.1.2. Afectaciones comunes en el jitomate

Con base en la información sobre los síntomas generales de las plantas debido a la deficiencia de algún macronutriente y de la experiencia de distintos agricultores, podemos conocer los síntomas que la planta de jitomate presenta al tener exceso o deficiencia de nitrógenos, fosforo y potasio [6, 26].

1.1.2.1. Falta o exceso de nitrógeno

Cuando la planta de jitomate presenta una deficiencia de nitrógeno sus hojas de mayor tamaño cambian de color de verde a amarillo, mientras que las de menor tamaño se ponen pálidas. Las flores se caen y las que llegan a mantenerse en la planta tienen dificultad de producir fruto o producen frutos de menor tamaño al esperado. Por otro lado, si la planta presenta exceso de nitrógeno, esta tiene un gran crecimiento vegetativo, provocando la caída de las flores y crecimiento y desarrollo irregular de los jitomates; afectando a los demás nutrientes que la planta necesita, como se puede ver en la figura 3 [6, 26].

⁸ Soporte que funciona como guía para el crecimiento de la planta [86].



FIGURA 3: PLANTA SANA (IZQ.) VS PLANTA CON CARENCIA DE NITRÓGENO (DER.), ADAPTADO DE [6]

1.1.2.2. *Falta o exceso de fósforo*

Algunas de las características que presenta la planta de jitomate al tener una deficiencia de potasio son las siguientes [6, 26]:

- Las venas de las hojas de mayor tamaño presentan una coloración morada (figura 4).
- La planta tiene dificultades para crecer y madurar los frutos.
- Presenta un aspecto débil.

Si la planta presenta un exceso de este elemento ocasiona que otros elementos como el hierro, zinc y cobre no puedan ser asimilados por la planta, bloqueando sus propiedades [6, 26].



FIGURA 4: DEFICIENCIA DE FÓSFORO EN EL JITOMATE ADAPTADO DE [6]

1.1.2.3. Falta o exceso de Potasio

El momento en que la planta necesita más potasio es durante la producción del fruto. Al presentar un déficit de este elemento los bordes las hojas se ponen amarillos. Los frutos presentan una maduración irregular que puede ser detectada por la presencia de una coloración amarilla en forma de estrella en la base del fruto, como se puede observar en la figura 5. Al carecer de este elemento, la planta tiene una disminución en la floración y en la calidad del fruto [6, 26].



FIGURA 5: CARENCIA DE FÓSFORO EN EL JITOMATE, ADAPTADO DE [6]

El exceso de potasio actúa de forma similar que el exceso de fósforo, bloqueando las propiedades de los mismos elementos [6, 26].

Gracias a la información anterior, se pueden conocer los distintos síntomas que la planta de jitomate presenta y cómo solucionar cada uno de estos y de esta manera enfocar el desarrollo del algoritmo supervisado a este tipo de plantas y síntomas.

1.2. Soluciones tecnológicas utilizadas en agricultura

1.2.1. Invernaderos

Se conoce como invernadero a una construcción cerrada con una estructura que actúa como soporte de una cubierta generalmente traslúcida. El objetivo principal de realizar trabajos agrícolas dentro de un invernadero es obtener productos vegetales de gran calidad sin importar la época del año [27].

Esto nos permite ampliar la temporada de cosecha de distintos ejemplares y facilitar el inicio de cultivo en ciertas localidades con climas extremos o no aptas para las plantas, debido a que nos proporciona tener condiciones favorables para el desarrollo de estas [28].

El uso de invernaderos ha incrementado con el paso de los años gracias a los beneficios que estos conllevan [28]. Tener un invernadero no genera gran trabajo y tener un buen control de las condiciones, como temperatura y humedad del ambiente, dentro del invernadero facilita las tareas que este requiere y permite que las plantas tengan mayor esperanza de vida [28].

Antes de tener un invernadero es importante realizar una correcta planeación considerando los siguientes puntos [28]: tamaño, sistema de irrigación, enfriamiento y calefacción, diseño, materiales ideales y presencia de luz solar.

Existen distintos tipos de invernadero, entre los que destacan los siguientes [29]:

- Invernadero plano (figura 6): es utilizado en zonas con pocas precipitaciones y está conformado de una estructura vertical y una horizontal.
- Invernadero en raspa y amagado (figura 7): Es parecido en forma al tipo anterior variando la forma de la cubierta.
- Invernadero asimétrico (figura 8): busca recibir la mayor radiación solar posible, por lo que se orienta de este a oeste, simulando el recorrido natural del sol.
- Invernadero de cristal (figura 9): consiste en una estructura cubierta de vidrio que reposa sobre canales de recolección de agua pluvial.




FIGURA 6: INVERNADERO PLANO, ADAPTADO DE [29]




FIGURA 7: INVERNADERO EN RASPA Y AMAGADO, ADAPTADO DE [29]




FIGURA 8: INVERNADERO ASIMÉTRICO, ADAPTADO DE [29]



FIGURA 9: INVERNADERO DE CRISTAL, ADAPTADO DE [30]

El uso de invernaderos conlleva grandes beneficios en los cultivos, gracias al control de temperatura y humedad que estos presentan, así como a la facilidad de trabajo con estos, permitiéndoles una mejor calidad y esperanza de vida en las plantas de los cultivos.

1.2.2. Invernaderos automatizados

Un invernadero inteligente sigue los mismos principios de un invernadero tradicional con la ventaja del control de las variables ambientales que afectan directamente al cultivo. Algunas de las variables a controlar en un invernadero automático son las siguientes [31]:

- Riego
- Aplicación de nutrientes
- Temperatura
- Humedad
- Iluminación

La automatización de los invernaderos presenta varias ventajas; entre las cuales, destacan los incrementos de la producción, la mayor calidad en el cultivo y la oportunidad de tener cultivos específicos durante distintas épocas del año [31]. Contar con un invernadero ayuda a controlar la mayoría de los factores importantes en el desarrollo de las plantas. Este tipo de invernaderos permite al usuario trabajar con ciertas plantas en distintas épocas del año, cambiando de esta manera la estacionalidad de sus frutos.

Podemos observar que el uso de invernaderos convencionales y automatizados ha permitido el control de distintos factores importantes en el desarrollo y crecimiento de las plantas, ampliando las temporadas de los cultivos y cambiando las localidades para el crecimiento de ciertos ejemplares e incrementando los niveles de producción y calidad del producto final.

1.2.3. Sistemas de irrigación

Existen distintas maneras para realizar la tarea de regado de plantas, entre ellos el riego por goteo y el riego por fertirrigación⁹ [32].

⁹ Técnica utilizada para la aplicación de fertilizantes y agua simultáneamente a través de un sistema de regado [83].

1.2.3.1. *Riego por goteo*

El riego por goteo (figura 10) consiste en distribuir agua a cada una de las plantas a través de una tubería plástica, en pequeñas cantidades y de manera frecuente buscando que ninguna planta experimente momentos de sequía. El objetivo de este tipo de riego es mantener los niveles necesarios de humedad en la tierra. Algunas de las limitaciones o desventajas que presenta este tipo de riego en la planta son [32]:

- El costo del sistema, ya que los cultivos no son lo suficientemente rentables para justificar el gasto.
- Una instalación incorrecta del sistema puede ocasionar la pérdida o daño del cultivo, debido a la falta de agua y nutrientes necesarios para la planta.



FIGURA 10: RIEGO POR GOTEO, ADAPTADO DE [33]

Con base en lo descrito anteriormente, se pueden observar las ventajas y desventajas que el riego por goteo representa en el cultivo y de impacto económico. Si se decide utilizar este tipo de riego es importante considerar varias características para obtener los mayores beneficios posibles.

1.2.3.2. *Fertirrigación*

La fertirrigación (figura 11) es un tipo de riego poco utilizado; sin embargo, existe una tendencia a utilizarlo más y más, teniendo como objetivo optimizar los equipos de riego y reducir los costos derivados de la fertilización. Este tipo de riego se refiere a la aplicación de fertilizantes en el agua utilizada en los sistemas de regado. Los nutrientes utilizados presentan alta solubilidad, lo que permite que se disuelvan por completo en el agua para regar y que sean asimilados de inmediato por las plantas. Algunas de las desventajas de la fertirrigación son las siguientes [32]:

- El incorrecto uso de este tipo de riego puede contaminar la fuente de agua.
- Existe falta de información sobre los fertilizantes que se pueden utilizar, las dosis necesarias para las plantas y la época y modo de aplicación.

- Los fertilizantes al ser corrosivos deterioran el sistema de riego disminuyendo su tiempo de vida.



FIGURA 11: FERTIRRIGACIÓN, ADAPTADO DE [34]

Gracias a las características de cada tipo de regado se puede observar el aumento que se ha presentado en el uso de sistemas de fertirrigación y las ventajas que este conlleva. Es notable la necesidad de controlar el uso de fertilizante en el regado para no dañar a las plantas y tener un aumento en los gastos de recursos.

1.2.4. Uso de la robótica en la agricultura

Con el paso de los años y los avances en la tecnología, el uso de la robótica en tareas agrícolas se ha ido popularizando. Con base en las necesidades de cada país o región se han realizado proyectos e investigaciones con el fin de satisfacerlas.

En Japón, por ejemplo, se realizó una investigación [7] con el objetivo de utilizar robots móviles con forma de tractores con el fin de realizar las tareas necesarias dentro de un cultivo de arroz, soya y trigo. Estas tareas comienzan con la siembra de semillas y continúan con el cultivo de plantas, fertilización y monitoreo de los cultivos y cosecha de producto final. Este proyecto está pensado para abarcar grandes terrenos de cultivo, enfocarse en la seguridad del usuario con el uso de múltiples sensores y tener un sistema de localización y búsqueda de mejores trayectorias [7].

La contaminación y variedad de climas han sido temas de preocupación en las actividades de agricultura, por lo que se han realizado distintas investigaciones para proteger las cosechas de estos factores. En [8], se ha propuesto una habitación equipada con distintos robots, sensores y áreas especializadas en cada tipo de planta cultivada. Esta habitación puede controlar la temperatura, humedad y presión, lo que permite adaptarse a cualquier tipo de planta. Sin embargo, esto no ha podido ser automatizado por completo, necesitando intervención humana para realizar ciertas tareas como supervisión de las tareas realizadas por los robots o detección del color de los frutos para ser cosechados.

Por otro lado, la agricultura de exactitud ha intervenido en la combinación de robótica y agricultura. Con el fin de lograr gran calidad en los alimentos cultivados y seguridad en los

cultivos para el usuario y el producto final se han realizado proyectos basados en prácticas tipo GAP (Good Agricultural Practices) [11] con ayuda de herramientas de medición, sensores de rendimiento y software de análisis buscando implementar una cosecha controlada.

Con base en los proyectos anteriores es perceptible el aumento del uso de nuevas tecnologías con el fin de obtener mejores cultivos y proporcionar mayor seguridad para el usuario. Cada uno de estos tiene sus ventajas y sus limitaciones, las cuales son importantes para trabajar con ellos y obtener mayores beneficios.

1.2.5. Uso de la visión artificial en la agricultura

El avance en la tecnología en términos de la visión artificial se ha ido incrementado en los últimos años. A continuación, se presentan trabajos recientes en esta temática aplicados a la agricultura.

Con el fin de calcular la cantidad necesaria de tratamiento para conseguir maduración exterior específica de las naranjas recién cosechadas para su consumo final, en [35] se realizó un proyecto basado en procesamiento de imágenes para detectar la coloración de estas. Para llevar a cabo la evaluación es necesario contar con un dispositivo Android y el uso de la cámara de este. El cálculo que se obtiene a partir de la imagen detectada nos muestra la cantidad de tratamiento necesario con base en los índices de coloración establecidos [35]. Es importante contar con aplicaciones de este tipo para poder realizar tareas comunes de manera más sencilla y práctica. Este tipo de proyectos sustituye sensores o dispositivos utilizados para realizar estas tareas, reduciendo de manera importante los gastos de aplicación.

Con el objetivo de detectar la coloración del jitomate durante su crecimiento y encontrar la fecha ideal para cosechar y vender el producto, se han utilizado sistemas de visión para la detección y análisis del color [36, 37, 38, 39]. Así mismo, este tipo de tecnología se ha utilizado durante la fase de acomodo y distribución del producto, donde se clasifica el jitomate como defectuoso o no defectuoso y maduro o no maduro para su separación. Con base en la detección de la coloración del fruto es posible determinar el estado de maduración de este. Gracias a los proyectos anteriores se puede observar cómo el análisis de color se puede realizar en distintas etapas de la cadena de suministro; sin embargo, las principales son durante el crecimiento de la planta y la cosecha.

Otros proyectos reportan distintas investigaciones y experimentos con base en la coloración de la cáscara de la fruta a evaluar. Por ejemplo, en el trabajo [9], los autores se enfocan en la coloración de la papaya para su cosecha final; con esto, buscan obtener mejores productos para la venta y consumo final sin tener que utilizar procesos físicos y químicos para obtener la maduración requerida.

De los proyectos anteriores es posible ver las ventajas en el uso de tecnologías accesibles por visión para una mejor calidad del producto final; sin embargo, sólo se enfoca en el

análisis de un solo fruto (jitomate o papaya) y su tiempo de cosecha, no en el resto de la planta y su ciclo completo de vida.

Actualmente, el aprendizaje profundo (deep learning) se ha utilizado para la detección de las características de las hojas de distintas plantas para la detección de enfermedades o plagas [10]. Es importante trabajar con las plagas y enfermedades de las plantas para tener un ahorro en recursos como pesticidas.

1.3. Sistema de visión artificial

Los sistemas de visión artificial están basados en la visión humana; sin embargo, no se ha logrado imitar por completo esta capacidad sensorial [40]. El proceso de visión en el humano comienza con la entrada de luz por los ojos. Esta señal es interpretada por el cerebro para reconocerla como algo familiar o antes visto, o por el contrario, iniciar un proceso de aprendizaje al estudiar la nueva señal [40].

En un sistema de visión artificial, los ojos humanos son sustituidos por una o varias cámaras que detectan la señal en forma de luz y un sistema informático que realiza la función del cerebro interpretando o aprendiendo la información obtenida al realizar una serie de pasos de reconocimiento de patrones para poder dar una respuesta final [40].

Un sistema de visión puede apoyar a la visión humana y dar una retroalimentación acertada al usuario final con base en la información detectada (por ejemplo, en cultivos), permitiendo que el usuario no sea experto en el tema y pueda reaccionar ante ciertas circunstancias (por ejemplo, síntomas en plantas).

Un sistema de visión general (figura 12) está compuesto por los siguientes componentes o etapas: una fuente de luz (iluminación), una cámara, un CPU (tarjeta de adquisición, algoritmos de procesamiento, interface) y un sistema de control (actuadores externos) [41].

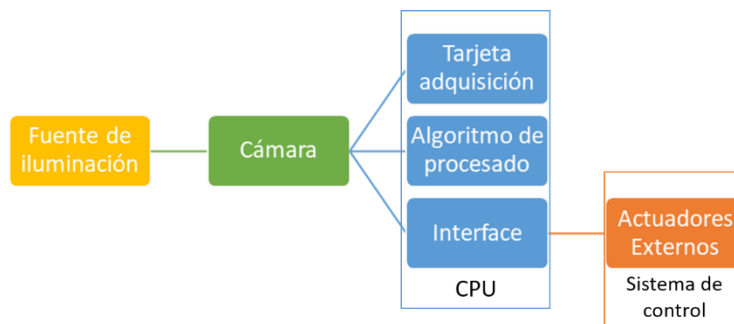


FIGURA 12: DIAGRAMA COMPONENTES SISTEMA DE VISIÓN

1.3.1. Fuente de iluminación

Una parte fundamental y crítica dentro de un sistema de visión es la iluminación. A partir de una óptima iluminación se logra que las cámaras detecten lo que el ojo humano puede

captar sin necesidad de una iluminación especial [42, 43].

El principal objetivo de la iluminación dentro de un sistema de visión es controlar la forma en que la cámara captará al objeto. Si se cuenta con una correcta iluminación dentro del sistema, las aplicaciones se resolverán de forma fácil mientras que una incorrecta iluminación dificultará las tareas a resolver [42, 43].

Investigaciones realizadas a lo largo de los últimos años enfocados en visión computacional y agricultura demuestran la importancia de la iluminación dentro del sistema de visión.

Por ejemplo, para conocer la coloración ideal de las naranjas para cosecharlas es una investigación [35] en la cual se experimentó en dos ambientes diferentes. El primero en el ambiente natural del árbol, donde la iluminación utilizada es la proveniente del sol. En cambio, en el segundo se tiene un ambiente de laboratorio donde se controlan distintos factores, entre ellos la iluminación. El resultado final fue un sistema de visión portable que permite determinar el índice de coloración del fruto mientras este es cosechado o durante cualquier otro proceso, como el tratamiento para llegar a la coloración exterior específica, a través de una cámara de un dispositivo inteligente [35].

Una investigación [36] en un ambiente controlado para determinar la maduración del jitomate muestra la importancia de utilizar un buen sistema de iluminación con el fin de obtener imágenes con iluminación controlada y suficiente para el análisis de final de la coloración. En este experimento, se utilizó luz fluorescente de forma frontal buscando obtener los resultados finales con las características antes descritas [36]. Por otro lado, se han realizado investigaciones [44] con el objetivo de detectar el periodo de cosecha de los jitomates a través de sistemas de visión para en un futuro alimentar un robot manipulador que pueda cosecharlos. La captura de imágenes en este proyecto se realizó dentro del invernadero utilizando la luz solar como fuente de iluminación [44].

Con el fin de conocer el rendimiento del cultivo de mango que se tendrá en su periodo de cosecha, con base en los mangos presentes en el árbol, se ha realizado una experimentación basada en visión computacional [45, 46] con el objetivo de contar el número de frutos en el árbol. En este proyecto dividido en dos etapas se observó la importancia de iluminación dentro de un sistema de visión artificial. En la primera parte de la investigación se utilizó como fuente de iluminación la luz proveniente del sol. Al tener luz brillante e intensa, aumentan las sombras en el fruto por lo que se modifica el resultado. En cambio, al tener luz difusa, los frutos presentan menos sombras y mejoran los resultados finales. Con base en estos resultados, los autores realizaron el segundo experimento. En este utilizaron iluminación controlada, en un ambiente nocturno. Al tener este tipo de luz, el objetivo de contar el número de frutos presentes en el árbol obtuvo mejores resultados, debido a que sólo se iluminaba el árbol y se controlaban las sombras en los frutos [45, 46].

Gracias a las investigaciones y proyectos descritos anteriormente se observa la importancia de la iluminación dentro de los sistemas de visión. La mayoría de los proyectos utiliza luz natural como medio de iluminación, dependiendo del objeto de estudio de cada proyecto

esta resulta ser útil o debe sustituirse por completo para obtener mejores resultados. Es importante considerar estos trabajos para obtener buenos resultados a través de las imágenes que se capturen.

1.3.2. Cámara

Con el paso de los años, las cámaras de video han evolucionado de manera considerable. Normalmente para sistemas de visión las cámaras a utilizar requieren contar con características especiales, con el fin de obtener los mejores resultados. Esto vuelve a las cámaras utilizadas para visión artificial muy sofisticadas [42, 47].

El objetivo de las cámaras es capturar al objeto deseado y transferir la información a un medio electrónico para su interpretación, almacenaje y futura visualización [47].

En un estudio [48], al tener como objetivo contar el número de frutos en una rama de la planta de café, se utilizó un sistema de visión basado en equipos móviles. Esto representa una ventaja en el estudio, por un lado no se necesita cámaras de alta definición, iluminación controlada o equipo especial para recorrer la plantación. Por otro lado, el sistema se vuelve portátil y fácil de transportar, ayudando de esta manera capturar imágenes a distintas alturas y posiciones y con distintas condiciones de iluminación [48].

Una aplicación creada para un dispositivo móvil Android [49] con el fin de evaluar el número de frutos en una vid volvió accesible este tipo de tecnología a la mayor parte de la población y permitió el desarrollo y uso de este tipo de proyectos, gracias a que se tienen productos a precios razonables con procesadores computaciones y cámaras integradas. El realizar este tipo de aplicaciones móviles permite realizar investigaciones y proyectos sin la necesidad de equipo especializado como cámaras, lo que ayuda a ahorrar en costos de recursos. Por otro lado, en [50], se creó una aplicación móvil que utiliza algoritmos para conocer los daños que presentan las plantas debido a los insectos. En este proyecto se presentó como ventaja el uso de dispositivos móviles, ya que el uso de estos equipos permite sustituir maquinaria costosa y obtener como resultado un análisis preciso de las hojas dañadas.

1.3.3. CPU

El CPU (unidad central de procesamiento) es la parte más importante del sistema de visión [51]. Su principal función es leer instrucciones que se presentan en código binario y ejecutarlas [51].

1.3.3.1. *Tarjeta de adquisición de datos*

La adquisición de datos es un proceso primordial dentro de los sistemas de visión [52]. Este es un proceso en el cual se colectan y miden las señales captadas por sensores o cámaras,

se realizan pruebas y correcciones de la información y se mandan como señal de entrada a la computadora para su futuro procesamiento. Los pasos a seguir son los siguientes [52]:

1. Leer una señal de mundo real y convertirla a una señal de voltaje.
2. Convertir esta señal a números binarios para que la computadora pueda analizarla.

1.3.3.2. Algoritmos de procesamiento

Durante procesamiento de las imágenes, los algoritmos realizan la extracción de la información y características que estas contienen [53]. Dependiendo de la aplicación que la imagen tendrá se utiliza un tipo de procesamiento específico [53]. Existen distintos tipos de procesamiento, por ejemplo:

- *Realce*: realiza un re-escalamiento de la intensidad de los píxeles de la imagen con el fin de contrastarla [53].
- *Filtrado*: técnica utilizada para enfatizar o eliminar características de una imagen para mejorarla o enfatizarla [54].
- *Clasificación*: técnica utilizada para agrupar los píxeles con características o valores similares de las imágenes. [55]

1.3.3.3. Interfaz

Según la RAE interfaz se refiere a la conexión física y funcional entre dos sistemas o aparatos independientes [56]. Normalmente en los sistemas automatizados, estos no actúan de forma independiente, deben relacionarse con otros equipos, sistemas o personas. El emplear una interfaz permitirá un mejor diálogo y comunicación en los distintos sistemas [57].

1.4. Sistemas de control

Un sistema de control se define como un sistema que a partir de ciertos objetivos responde con una serie de acciones determinadas (Figura 13). Este sistema está compuesto por los siguientes elementos: variables a controlar, planta o sistema, sensores, señales de referencia, actuadores y controladores [58].



FIGURA 13: DIAGRAMA SISTEMA DE CONTROL

En esta sección, se describen algunos sistemas de control utilizados en proyectos para controlar la fertirrigación en los cultivos.

Con el fin de aplicar en tiempo real nutrientes a la planta del jitomate se desarrolló un sistema de control automático [59] que prepara y aplica los nutrientes en el momento requerido. La información obtenida por el sistema de control son las estimaciones de transpiración de la planta y la concentración de nutrientes obtenidas a través de mediciones eléctricas. Con este proyecto se logró ajustar la frecuencia de fertilización dentro del riego y controlar la cantidad de nutrientes suministrados, disminuyendo problemas ambientales y gastos en fertilizantes y agua [59].

Como se menciona en la sección 1.2.3.2, la fertirrigación se ha vuelto un proceso comúnmente utilizado en invernaderos con el fin de suministrar agua y nutrientes a las plantas cultivadas. Con esto en mente, se creó en España una aplicación [60] que tiene como objetivo calcular la cantidad de agua y nutrientes que la planta necesita. Este cálculo se realiza con base en la pérdida de agua que la planta sufre a través de la transpiración de esta. Estos datos se obtienen de sensores virtuales que toma información del ambiente del invernadero, lo que permite calcular el costo de energía y las condiciones de riego requeridas. De igual forma, se determina la cantidad de fertilizante que debe aplicarse por litro de agua para realizar la fertirrigación [60].

1.4.1. Actuadores externos

Se conoce como actuadores a los dispositivos que convierten las magnitudes físicas a otro tipo de magnitudes con el fin de que puedan interactuar con el entorno [61]. Existen distintos tipos de actuadores [62]:

- *Eléctricos*: actuadores que transforman la energía eléctrica en mecánica. Estos actuadores se describen como precisos y confiables.
- *Hidráulicos*: estos actuadores transforman la energía del aire en energía mecánica, entre sus ventajas destacan el precio, que son rápidos, sencillos y muy robustos.
- *Neumáticos*: la fuente de energía de estos actuadores es un fluido, generalmente un aceite mineral, una de sus principales ventajas es que son auto lubricantes.

1.5. Algoritmos de clasificación supervisados

Con el paso de los años, el procesamiento de imágenes se ha vuelto un tema de investigación recurrente debido a la amplia gama de aplicaciones que llega a tener. Lo anterior causó la introducción de técnicas basadas en el aprendizaje automático, con el objetivo de tener un proceso de decisión a partir del procesamiento de imágenes [63].

Se define como aprendizaje automático, o del inglés *machine learning*, como una serie de métodos diseñados para detectar distintos patrones de datos de manera automática y predecir acciones futuras o tomar decisiones a partir de nuevos datos [64]. Dentro de este existen distintas técnicas de aprendizaje, entre ellos se encuentra el aprendizaje supervisado, no supervisado, semi-supervisado, por refuerzo o multitarea. En el aprendizaje supervisado el algoritmo recibe información y ejemplos como entrenamiento, gracias a esto

el algoritmo es capaz de hacer predicciones con datos que no conoce. Este escenario se utiliza principalmente para realizar clasificaciones, regresiones o rankings [65].

A continuación se describen proyectos que utilizan *machine learning* y algoritmos supervisados para realizar tareas en el sector agrícola.

Con el objetivo de detectar los niveles de maduración de los jitomates P. Wan et al. han desarrollado un proyecto [36] que utiliza frutos adquiridos comercialmente para la experimentación. De estas muestras se obtuvieron varias imágenes para realizar el procesamiento. Estas imágenes fueron segmentadas para obtener los niveles de maduración. El sistema de visión utiliza un fondo negro, donde se colocan los jitomates a evaluar y luces fluorescentes para tener una iluminación uniforme. Con base en la información adquirida por el sistema de visión y las imágenes obtenidas para determinar los niveles de maduración se realiza el procesamiento de imágenes [36].

Las enfermedades en las plantas representan un gran problema en la agricultura. Con el fin de detectarlas automáticamente en la planta del jitomate se ha creado en Egipto un algoritmo [66] que consta de cinco fases. La primera fase es la adquisición de las imágenes, esta fase es muy importante dentro de cualquier sistema de visión. En la siguiente etapa, pre procesamiento de las imágenes, se trabaja con las imágenes para eliminar ruido y características que afecten el resultado final. El proceso continúa con la fase de extracción de características para describir la enfermedad presente en las hojas. Después se realiza una fase de selección donde se realiza un tamizado de las características para obtener resultados con mayor exactitud. Finalmente se realiza la fase de clasificación, en la cual se detectan las hojas enfermas. Para realizar el análisis el algoritmo cuenta con imágenes previamente capturadas de las enfermedades a estudiar. Estas imágenes deben ser cuidadosamente elegidas para obtener el resultado buscado [66].

Para detectar el nivel de severidad de las bacterias en las plantas de jitomate D. I. Borges et al. crearon un algoritmo basado en visión computacional [67]. En este proyecto se tomaron fotos de varios ejemplares de plantas con 85 días de vida, en distintas áreas del mismo campo del cultivo. Cada área del cultivo presenta distintas características, lo que permite distintas imágenes con niveles de bacterias similares. Estas fotos fueron mostradas a distintos agrónomos de forma independiente con el fin de evaluar el nivel de severidad de cada muestra y determinar los datos a comparar dentro del algoritmo [67].

1.5.1. Red neuronal artificial

Una red neural artificial (figura 14) es un método de aprendizaje supervisado que sirve para mapear una entrada en una salida deseada. Estos tipos de redes están basados en el estudio de sistemas biológicos. Las redes neuronales, aunque no están completamente relacionados con las neuronas, han permitido, a partir de la implementación de los principios estudiados, la creación de varios inventos parecidos a los sistemas biológicos. La creación de las redes neuronales artificiales fueron creadas con el objetivo de permitir que las máquinas puedan tomar decisiones a partir de la entrada de información al sistema [68, 69].




FIGURA 14: DIAGRAMA DE UNA RED NEURONAL ADAPTADO DE [70]

Las redes neuronales son capaces de aprender de los datos que se le presentan pudiendo reconocer patrones, realizar clasificación de los datos y predecir eventos futuros. Este tipo de redes son utilizadas para realizar un correcto reconocimiento de patrones visuales, sonoros o de control [71].

Por ejemplo, con el objetivo de estimar el volumen de manzanas dañadas se ha utilizado una red neuronal artificial [72]. En este modelo se utilizaron parámetros como la fuerza y energía de impacto, radio de curvatura, temperatura y rigidez acústica. Con base en la experimentación se demuestra que la utilización de redes neuronales artificiales es una solución práctica para este problema, debido a que es más rápido, preciso y objetivo que los métodos utilizados hoy en día para esta estimación [72].

Para detectar las mejores variables para deshidratar el jitomate se ha utilizado una red neuronal artificial [73]. Después de comparar los resultados obtenidos en el sistema y la data experimental se observó que estos resultados son más precisos que los obtenidos por distintas ecuaciones matemáticas [73].

1.5.2. Red neuronal profunda

Una red neuronal profunda también conocida como “deep learning” se refiere a la técnica de aprendizaje que permite que el sistema automatizado pueda aprender a través de ejemplos a realizar distintas tareas como una persona lo haría. En los últimos años se han logrado grandes avances en la investigación y la tecnología gracias a este tipo de aprendizaje que permite lograr resultados que anteriormente eran difíciles de conseguir [74].

Este tipo de aprendizaje logra realizar tareas de clasificación con base en imágenes, sonidos o texto, obteniendo una gran exactitud [74, 75]. Esta exactitud se logra debido al número de capas ocultas por la que está formada la red neuronal. Este tipo de modelos

obtienen su entrenamiento a partir de gran cantidad de datos etiquetados y redes neuronales que aprenden directamente de los datos [74, 75].

Gracias al gran potencial y resultados promisorios que presenta el “deep learning” en distintas áreas de estudio se ha experimentado en el área de la agricultura. En [76], se analizaron cuarenta diferentes trabajos de esta área con el fin de evaluar e identificar los beneficios que esta técnica de reconocimiento y clasificación de imágenes presenta y comparar los resultados con distintas técnicas utilizadas para el mismo fin. Se puede concluir que las redes neuronales profundas tienen un mejor desempeño y superan al resto de técnicas utilizadas para este tipo de análisis [76].

En [77], se ha utilizado una red neuronal profunda con el fin de facilitar la identificación y clasificación de plantas. Con base en la experimentación realizada se obtuvo como conclusión que el uso de redes neuronales profundas permite obtener mejores representaciones de las características de las plantas y resultados en la identificación de estas a comparación de la identificación y clasificación manual [77].

1.5.3. Redes neuronales convolucionales

Uno de los principales algoritmos de redes neuronales profundas son las redes neuronales convolucionales (CNN), un tipo de *machine learning* que aprende a realizar una serie de tareas a partir de una serie de imágenes, multimedia o textos. Este tipo de algoritmos se especializan en la localización de patrones teniendo como fin el reconocimiento de características a través de sistemas de visión artificial [78].

Como las diferentes redes neuronales, las CNNs cuentan con una entrada de información, varias capas intermedias ocultas y una o varias salidas de información. Dentro de esta estructura se realizan alteraciones o modificaciones en los datos con el fin de aprender las características principales de esos datos. Esta estructura está compuesta por distintas capas, donde las más comunes son [78]:

- *Convolución*: Dentro de esta capa se determinan las características de las imágenes a través de filtros convolucionales.
- *Unidad lineal rectificadora*: Se asignan valores positivos y negativos a las características de las imágenes, donde las características que logran activarse continúan a la siguiente fase.
- *Agrupación*: En este paso se realiza una disminución no lineal de la muestra, lo que tamiza y disminuye los parámetros que la red necesita para aprender.

Con el objetivo de detectar el tipo de planta a través de las características de las venas de las hojas, en [79] se implementó una red neuronal convolucional. Esta red permitió obtener resultados más precisos de los patrones de las venas sin tener que utilizar extractores estándar que pudieran dañar las plantas [79].

Buscando modelos de identificación de enfermedades en las plantas más rápidos y precisos, en [80] se optó por experimentar con redes neuronales convolucionales para tomar decisiones lo más pronto posible. Los resultados obtenidos son más precisos que el resto de arquitecturas utilizadas para identificar las enfermedades [80].

1.6. Resumen

Gracias a la información descrita anteriormente se pueden conocer los proyectos, basados en sistemas de visión y control, que se han realizado con fines agrícolas. De igual forma, se conocieron las ventajas y limitaciones que presentan cada uno de estos. En este trabajo, se busca detectar el déficit de los principales macronutrientes en la planta de jitomate saladette o roma (nitrógeno, potasio y fósforo) a través de un sistema de visión que detectará la coloración de las hojas y mandará una señal a un sistema de monitoreo para introducir manualmente en el regado, el nutriente que le falta a la planta ahorrando de esta manera recursos y evitando gastos innecesarios por falta de cuidado de la planta.

2. Metodología

En este capítulo se muestra la metodología llevada cabo para realizar la presente investigación.

La investigación será guiada por las características que presentan las hojas por exceso o déficit de ciertos elementos (nitrógeno, potasio, fósforo). Es necesario contar con imágenes de las hojas de la planta con cada uno de los síntomas que puedan presentar. Gracias a estas imágenes, el algoritmo de reconocimiento tendrá información para predecir cuál es el nutriente faltante en la planta y otorgar una respuesta acertada. Con este resultado, el sistema de control semi-automático podrá introducir el nutriente faltante en el agua de regado, en este trabajo, de forma manual.

La metodología a seguir durante el proceso de investigación es la siguiente:

1. Diseñar el prototipo a utilizar.
2. Adquirir imágenes de las hojas del jitomate con los distintos síntomas por déficit de nitrógeno, potasio y fosforo.
3. Pre-procesar las imágenes.
4. Diseñar el algoritmo de clasificación supervisado, que tomará como base las fotos capturadas anteriormente.
5. Realizar pruebas del algoritmo con la captura de nuevas imágenes.
6. Diseñar las reglas a seguir por el sistema de control con base en las salidas del algoritmo supervisado.
7. Realizar pruebas con el sistema de control.
8. Realizar pruebas de todo el sistema en el ambiente normal.
9. Analizar resultados.

2.1. Descripción del sistema de monitoreo y control

El prototipo que se utilizó para la experimentación (figura 15) está conformado por un sistema de monitoreo, el cual recibe como entrada la fotografía del cultivo capturada por la cámara de una computadora, con el fin de que el sistema de control pueda predecir el nutriente faltante en la planta y el usuario pueda agregar el componente durante el regado de la planta.

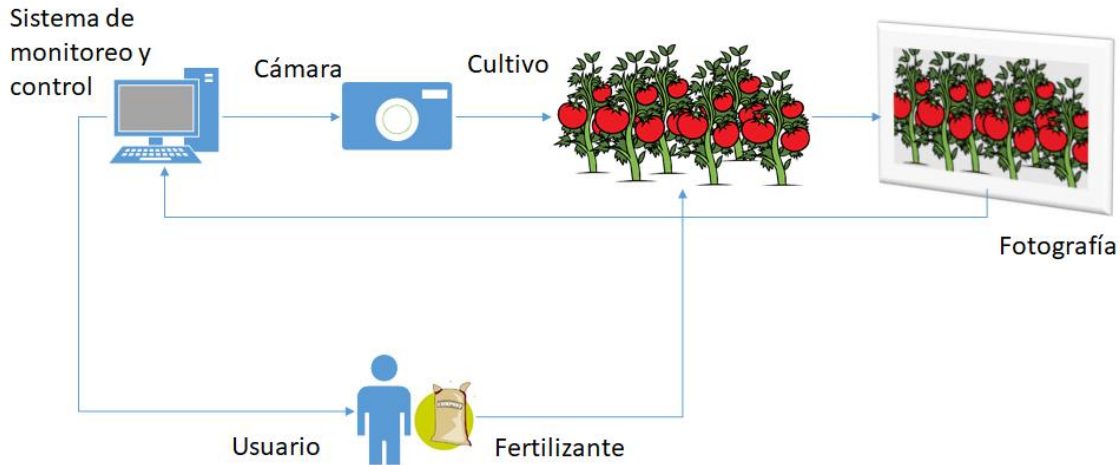


FIGURA 15: DIAGRAMA DEL PROTOTIPO PARA LA EXPERIMENTACIÓN

Se propone utilizar una cámara RGB para tomar fotografías de plantas de jitomate. A las imágenes obtenidas se les realizó una mejora del contraste y cambio del tamaño de estas para su posterior análisis. Después, cada imagen se ingresó en un modelo CNN pre-entrenado que pueda clasificar las tres posibles deficiencias de nutrientes (es decir, falta de nitrógeno, falta de fósforo y falta de potasio) o el nivel normal de nutrientes en la planta. La metodología para desarrollar el sistema de monitoreo comprende los siguientes pasos: (sección 3.1.1.) adquisición de datos, (sección 3.1.2.) pre-procesamiento de datos, (sección 3.1.3.) construcción del modelo CNN y (sección 3.1.4.) evaluación del modelo CNN. La figura 16 resume el flujo de trabajo de la implementación del sistema de monitoreo.



FIGURA 16: DIAGRAMA DEL FLUJO DE TRABAJO DE LA IMPLEMENTACIÓN DEL SISTEMA DE MONITOREO BASADO EN VISIÓN.

2.2. Experimentación

2.2.1. Adquisición de datos

Durante esta fase, la actividad principal consiste en la creación de un conjunto de datos conformado por múltiples imágenes de las hojas de la planta del jitomate y el nivel de los nutrientes que la planta tiene en el momento de la captura de la fotografía.

Se recolectaron datos y tomaron fotografías, una vez por semana durante 10 semanas, de

plantas de jitomate cultivadas en 3 macetas diferentes en la Ciudad de México. Para iniciar las mediciones la tierra utilizada para sembrar las plantas se estuvo regando con agua potable y agua de lluvia durante varios meses para eliminar cualquier tipo de nutriente. Después, se sembraron semillas de jitomate en la maceta con ese suelo neutral con el fin de obtener 3 ejemplares para separarlos en macetas diferentes. Se agregaron los nutrientes primarios una vez por semana a esas plantas. La primera medición (semana 1) se realizó en la maceta neutral y una vez obtenida la información se realizó la separación a macetas diferentes. Una vez separadas las plantas se agregaron los nutrientes primarios (nitrógeno, fósforo, potasio) uno por maceta, una vez por semana. Las siguientes mediciones (semanas 2-7) se realizaron solo del nutriente que se le agregaba a cada una de las macetas. Finalmente las últimas mediciones (semanas 8-10) se realizaron de todos los nutrientes en cada una de las macetas separadas, con el fin de conocer los cambios que pueden sufrir el resto de los nutrientes al agregar cada uno de ellos por separado. Al final de las 10 semanas, todas las plantas tenían suficientes nutrientes para ser considerados con niveles normales.



FIGURA 17: MUESTRA DE TODAS LAS MEDICIONES DEL JITOMATE

Las mediciones semanales se realizaron de forma manual, utilizando un kit para medir los nutrientes químicos como se muestra en la Figura 17. Para realizar estas mediciones se realizaron los siguientes pasos:

1. Tomar una muestra de tierra a 5 cm de profundidad desde la superficie de la maceta a evaluar y colocar a un recipiente.
2. Agregar agua al recipiente (5 veces la cantidad de la muestra de tierra).
3. Revolver el agua con la tierra y dejar reposar aproximadamente 1 hora hasta que la tierra se asiente en el fondo del recipiente.
4. Con el gotero tomar el agua de la superficie del recipiente para llenar los muestrarios de cada elemento.
5. Agregar el reactivo químico a cada muestrario y agitar hasta combinarlo con el agua.
6. Esperar a que ocurra la reacción y evaluar la cantidad de nutriente en la maceta.

Al finalizar las mediciones en la semana 10, se resumieron los datos obtenidos en la tabla 1. La tabla muestra los valores de pH que se midieron en la tierra (no utilizados para el trabajo), el nivel de nitrógeno, el nivel de fósforo y el nivel de potasio, donde cada columna corresponde a una planta. Para la medición de cada elemento se pueden reportar 5 niveles diferentes: *depleted* (agotado), *deficient* (deficiente), *adequate* (adecuado), *sufficient*

(suficiente) y *surplus* (excedente), según se especifica en las probetas para la medición.

TABLA 1: ADQUISICIÓN DE MUESTRAS DE LA TIERRA POR SEMANA

Número de semana	de Ph	Fosforo (P)	Potasio (K)	Nitrógeno (N)
1	6.5 slight acid	Adequate P2	Depleted K0	Depleted N0
2	N/A	N/A	N/A	Deficient N1 (Figura 18)
3	N/A	Adequate P2	N/A	N/A
4	N/A	N/A	Deficient K1	N/A
5	N/A	N/A	N/A	Surplus N4
6	N/A	Sufficient P3	N/A	N/A
7	N/A	N/A	Deficient K1 (Figura 19)	N/A
8	7 Neutral	Adequate P2 (Figura 20)	Deficient K1	Surplus N4 (Figura 21)
9 (Figura 17)	7 Neutral	Adequate P2	Adequate K2	Surplus N4
10	6.5 slight acid	Adequate P2	Adequate K2	Depleted N0

N/A: No Aplica.

A continuación se muestran la medición química realizada a la tierra y la fotografía de la planta que se midió. En la figura 18 se puede observar que la tierra presentaba nitrógeno deficiente y que la planta presentaba un color verde amarillo. En la figura 19 la muestra química nos indica potasio deficiente, lo que corresponde a las hojas con bordes secos o amarillos en la planta. La figura 20 muestra las venas de la planta ligeramente moradas, por lo que el fósforo es adecuado. Finalmente en la figura 21, al tener exceso de nitrógeno, la planta cambio de color de verde limón a verde oscuro.



FIGURA 18: MUESTRA DE JITOMATE CON NITRÓGENO DEFICIENTE



FIGURA 19: MUESTRA DE JITOMATE CON POTASIO DEFICIENTE



FIGURA 20: MUESTRA DE JITOMATE CON FÓSFORO ADECUADO



FIGURA 21: MUESTRA DE JITOMATE CON EXCESO DE NITRÓGENO

Una vez obtenidas las muestras de tierra, el siguiente paso fue obtener imágenes RGB usando una cámara de un dispositivo inteligente (iPhone Se), utilizando la luz solar como principal fuente de iluminación y sin condiciones de distancia predeterminadas.

Al finalizar la adquisición de datos se obtuvieron 596 fotografías en formato PNG de 3024 x 4032 pixeles. A continuación se muestra el número de imágenes clasificadas de acuerdo a la deficiencia de cada uno de los macronutrientes:

- 213 imágenes de hojas con falta de nitrógeno.
- 168 imágenes de hojas con falta de potasio.
- 94 imágenes de hojas con falta de fósforo.
- 121 imágenes de hojas con todos los nutrientes en buenas condiciones.

Se consideró como falta de nutrientes si las pruebas químicas daban como resultado *depleted* o *deficient*, en caso contrario se etiquetó como planta en condiciones normales.

2.2.2. Pre procesamiento

Durante este paso se realizaron dos pre-procesamientos de datos principales: mejora de contraste y cambio de tamaño de imagen. En el primer pre procesamiento, se aplicó la mejora de contraste a las imágenes originales para enfatizar el color en las hojas. Para este se calculó una transformación gamma en los canales RGB de las imágenes como se muestra en la ecuación 1.

$$s(r) = \begin{cases} 0 & ; r < a \\ (L - 1) \left[\frac{r-a}{b-a} \right]^{\gamma} & ; a \leq r \leq b \\ (L - 1) & ; r < b \end{cases} \quad \text{ECUACIÓN 1: TRANSFORMACIÓN GAMMA}$$

Donde las imágenes tienen para cada canal RGB, niveles de gris en el rango de (0, L-1), r es el nivel de gris de entrada a la transformación gamma, s es el nivel de gris de salida resultante y $[a, b]$ es el rango de entrada de niveles de gris de interés (es decir, para mejorar). Para todas las imágenes en la experimentación, el valor γ se estableció en 1 y se utilizó el siguiente rango de entrada de niveles de gris para mejorar el contraste: $[0.2 \times (L-1), 0.6 \times (L-1)]$ para el canal rojo, $[0.3 \times (L-1), 0.7 \times (L-1)]$ para el canal verde y $[0, (L-1)]$ para el canal azul.

En el segundo paso del pre procesamiento de datos, se redujeron las imágenes originales (3024 x 4032 píxeles) a 28 x 28 píxeles de tamaño para reducir la tarea informática en el modelo CNN para un análisis posterior.

2.2.3. Construcción del modelo de aprendizaje máquina CNN

Una vez pre-procesadas las imágenes, se entrenó un modelo de clasificación, con el objetivo de detectar las 4 diferentes clases relacionadas con el déficit de nutrientes de la planta del jitomate (nitrógeno, fósforo, potasio, normal).

Se seleccionó un modelo de clasificación debido a su capacidad para el manejo de imágenes y la extracción de características automáticamente. En este caso, se decidió utilizar una CNN la cual es un tipo de aprendizaje automático que aprende a realizar una tarea de regresión o clasificación a partir de imágenes, multimedia o textos [78].

En este trabajo, se diseñó un modelo que utiliza como entrada imágenes RGB de 28 x 28 píxeles. La imagen ingresa a una red de 3 capas convolucionales con 8, 16 y 32 filtros de 3 x 3 de tamaño. Cada una de estas capas continúa con una capa de rectificación que activa una función no lineal (unidad lineal rectificadora, ReLU) y reduce el tamaño espacial de los mapas para evitar información redundante. Al final, hay una capa totalmente conectada en la que todas las neuronas están conectadas con las unidades de la capa anterior. La última de estas capas es la que contiene las características para clasificar las imágenes. Una capa softmax normaliza la salida de la última capa completamente conectada. Finalmente,

calcula la clasificación para detectar la deficiencia de nutrientes en la imagen de entrada. La figura 22 muestra la arquitectura del modelo CNN utilizado en el trabajo.

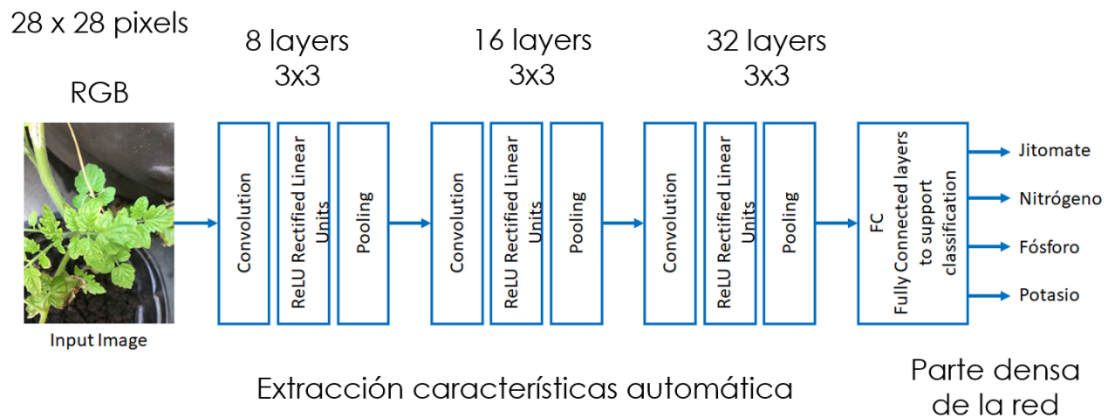


FIGURA 22: RED NEURONAL CONVOLUCIONAL

Para obtener un modelo CNN entrenado adecuado, se utilizó el algoritmo de descenso de gradiente estocástico con impulso para el entrenamiento, y se variaron dos hiper parámetros: la tasa de aprendizaje inicial (entre 1×10^{-6} y 1×10^{-2}) y el número máximo de épocas (entre 200 a 500). Se fijó el valor de impulso a 0.9 y el plazo de regularización a 1×10^{-4} .

2.2.4. Sistema de control semiautomático

El sistema de control semiautomático permitirá evaluar en tiempo real las características de una planta de jitomate a partir de la captura de una fotografía, con la cámara de la computadora, y el uso del modelo de machine learning con mejor resultado de exactitud, con el fin de obtener como resultado el nombre del nutriente faltante en esta y poder agregarlo manualmente en el regado.

2.2.5. Evaluación de resultados

Con base en el funcionamiento y resultados obtenidos en el modelo de machine learning se realizará una evaluación con el fin de verificar si el procesamiento y salidas de información son las correctas según la imagen de entrada con la que se experimenta. De igual manera se realizarán evaluaciones con nuevas imágenes con el objetivo de verificar si el sistema puede hacer predicciones a partir del aprendizaje adquirido.

Para la evaluación se calculará el porcentaje de exactitud que el modelo de *machine learning* otorga con los distintos parámetros experimentales. Para este cálculo se utiliza la fórmula de la ecuación 2.

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN}$$

ECUACIÓN 2: PORCENTAJE DE EXACTITUD

Donde:

- VP representan los verdaderos positivos.
- VN representan los verdaderos negativos.
- FP representan los falsos positivos.
- FN representan los falsos negativos.

3. Resultados obtenidos

De la metodología anterior, una parte crítica es entrenar y probar el rendimiento del modelo CNN. Sin embargo, los modelos CNN dependen de una variedad de configuraciones, como la elección de los hiper parámetros para encontrar una arquitectura adecuada, o la preparación de datos de entrada [81]. Debido a lo anterior, se llevaron a cabo cuatro experimentos relacionados con la preparación de datos de entrada de la siguiente manera:

- Experimento 1: 418 fotos originales para el entrenamiento y 178 evaluación (70%, 30%).
- Experimento 2: 418 fotos originales contrastadas para el entrenamiento y 178 evaluación (70%, 30%).
- Experimento 3: 418 fotos originales más 58 fotos de internet para entrenamiento (70%) y 178 fotos originales para la evaluación (30%).
- Experimento 4: 418 fotos originales más 58 fotos de internet contrastadas para el entrenamiento (70%) y 178 fotos originales contrastadas para la evaluación (30%).

Para poder incrementar el conjunto de datos se obtuvieron imágenes RGB de internet que representan las características presentes en la planta de jitomate al carecer de cada uno de los nutrientes. Este conjunto incrementado de datos fue utilizado en el experimento 3 y 4.

- 27 imágenes de hojas con falta de nitrógeno.
- 22 imágenes de hojas con falta de potasio.
- 26 imágenes de hojas con falta de fósforo.
- 9 imágenes de hojas con todos los nutrientes en buenas condiciones.

Todos los experimentos fueron implementados en Matlab utilizando el Deep Learning Toolbox. De igual forma, se utilizó una computadora personal con las siguientes características para la experimentación: MacBook Pro (13 pulgadas, Late 2011), procesador Intel Core i7 a 2.8 GHz, dos núcleos de CPU y RAM de 4GB 1333 MHz DDR3.

Las bases de datos utilizadas en este trabajo, así como los códigos empleados para la experimentación, se pueden encontrar en el repositorio GitHub¹⁰.

A continuación se muestran los resultados de cada experimento donde el valor inicial de aprendizaje y el número máximo de épocas por prueba varían y la exactitud se busca sea lo más cercana al 100%. Para la experimentación se utiliza el método de gradiente descendente estocástico, técnica en la cual se busca disminuir la pérdida [82], con un

¹⁰ https://github.com/ccevallo/Monitoreo_Jitomate.

momento de 0.9 y un factor de regularización de 0.0001.

3.1. Experimento 1: Fotos originales

Para el experimento 1, las imágenes originales de nuestro conjunto de datos fueron utilizadas. En la tabla 2 se muestra el resumen de resultados obtenidos.

TABLA 2: EXACTITUD DEL MODELO CNN CON FOTOS ORIGINALES

Fotos originales				
#	Valor inicial de aprendizaje	Número máximo de épocas	Exactitud (%) evaluación	Exactitud (%) entrenamiento
1	0.000001	350	41.90	43.88
2	0.000001	500	34.64	43.88
3	0.00001	350	43.58	82.01
4	0.00001	400	46.37	88.49
5	0.00001	500	45.81	89.93
6	0.00005	200	45.81	99.04
7	0.00005	300	50.84	99.52
8	0.0001	200	51.96	99.76
9	0.0001	250	54.75	99.04
10	0.0001	300	49.72	99.76
11	0.0001	350	56.42	99.28
12	0.0001	400	50.84	99.04
13	0.0001	500	50.84	99.28
14	0.0005	200	43.02	99.04
15	0.001	300	55.31	99.52
16	0.001	350	49.72	99.04

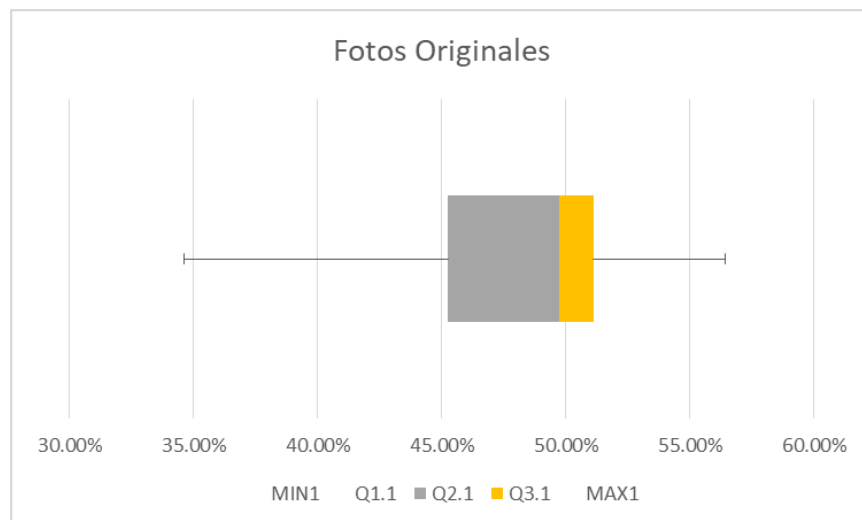


FIGURA 23: GRÁFICA DE CAJAS Y BIGOTES EXPERIMENTO 1.

Para el experimento 1, el 50% de los resultados se encuentra entre el 45% y 52% de exactitud. El mejor resultado de las pruebas fue 56.42% y el más bajo de estas fue 34.64%. Esto nos indica que entrenar y evaluar solo con las fotos originales no es la mejor opción, debido a que los resultados finales son completamente al azar. El mejor resultado tuvo como valor inicial de aprendizaje 0.0001 y número máximo de épocas 350.

3.2. Experimento 2: Fotos originales contrastadas

Para el experimento 2 se utilizaron las imágenes contrastadas de nuestro conjunto de datos de fotos originales. A continuación, en la tabla 3, se muestran los resultados obtenidos.

TABLA 3: EXACTITUD DEL MODELO CNN CON FOTOS CON CONTRASTE

#	Valor inicial de aprendizaje	Número máximo de épocas	Fotos contraste	
			Exactitud (%) evaluación	Exactitud (%) entrenamiento
1	0.00001	250	44.69	76.74
2	0.00001	300	39.11	84.65
3	0.00001	350	43.58	85.61
4	0.00001	400	48.60	89.21
5	0.00001	500	46.37	92.09
6	0.00005	350	49.72	99.52
7	0.0001	250	54.75	99.52
8	0.0001	300	43.02	99.28
9	0.0001	350	49.16	99.52
10	0.0001	400	46.37	99.76
11	0.0005	350	52.51	99.76
12	0.0005	450	45.81	99.76
13	0.001	300	45.25	99.28
14	0.001	350	50.84	99.28
15	0.001	400	47.49	99.04
16	0.001	800	43.58	99.28




FIGURA 24: GRÁFICA DE CAJAS Y BIGOTES EXPERIMENTO 2.

Con base en los resultados obtenidos en el experimento 2 se puede observar que el 50% de las mediciones de exactitud se encuentran entre el 44% y el 49%, siendo 54.75% el valor más alto de las mediciones con un valor inicial de aprendizaje de 0.0001 y el número máximo de épocas de 250. Se puede decir que a comparación con el experimento 1 este experimento no fue mejor, ya que la exactitud tiende a ser menor al 50%.

3.3. Experimento 3: Fotos originales con fotos de internet

En el experimento 3, se utilizó el conjunto de datos incrementado con imágenes obtenidas de internet. Los datos obtenidos se muestran en la tabla 4.

TABLA 4: EXACTITUD DEL MODELO CNN CON FOTOS ORIGINALES Y FOTOS DE INTERNET

Fotos originales con fotos internet				
#	Valor inicial de aprendizaje	Número máximo de épocas	Exactitud (%) evaluación	Exactitud (%) entrenamiento
1	0.00001	300	67.60	79.83
2	0.00005	350	83.24	99.16
3	0.0001	300	84.36	99.79
4	0.0001	350	85.47	98.95
5	0.0001	400	77.65	98.95
6	0.0005	300	82.68	98.95
7	0.0005	350	84.36	99.16
8	0.0005	400	79.33	99.37
9	0.001	250	84.36	99.16
10	0.001	300	86.59	99.58

11	0.001	350	84.36	99.37
12	0.001	400	83.24	99.37
13	0.001	450	82.12	99.16
14	0.01	250	79.33	98.95
15	0.01	300	82.12	98.74
16	0.01	350	82.12	99.16




FIGURA 25: GRÁFICA DE CAJAS Y BIGOTES EXPERIMENTO 3.

En el experimento 3, se observa un aumento en el porcentaje de exactitud, gracias a que el 50% de los resultados se encuentran entre el 82% y el 84%. El mejor resultado de las pruebas fue 86.59%, mientras que 67.60% fue el menor de los resultados. El entrenar con fotos originales y fotos de internet permite tener un mejor porcentaje de exactitud en los resultados finales. La configuración de hiper parámetros que permitió el mejor modelo CNN fue de 0.001 de valor inicial de aprendizaje y 300 épocas. Por lo tanto, el aumento de datos mejora el rendimiento del modelo CNN.

3.4. Experimento 4: Fotos originales con fotos de internet contrastadas

El experimento 4 utilizó las imágenes contrastadas del conjunto de datos incrementado con imágenes obtenidas de internet. En la tabla 5 se muestran los resultados que se obtuvieron.

TABLA 5: EXACTITUD DEL MODELO CNN CON FOTOS ORIGINALES Y FOTOS DE INTERNET CON CONTRASTE

Fotos contraste con fotos internet				
#	Valor inicial de aprendizaje	Número máximo de épocas	Exactitud (%) evaluación	Exactitud (%) entrenamiento
1	0.00005	350	80.45	98.74
2	0.0001	200	82.68	99.37
3	0.0001	250	85.47	99.16
4	0.0001	300	83.24	98.53
5	0.0001	350	82.12	98.95
6	0.0005	300	80.45	99.79
7	0.0005	350	86.59	99.37
8	0.001	250	86.03	99.37
9	0.001	300	86.59	99.37
10	0.001	350	85.47	99.58
11	0.001	400	83.80	99.37
12	0.001	450	84.92	99.37
13	0.01	250	83.80	99.16
14	0.01	300	85.47	99.37
15	0.01	350	84.36	98.74
16	0.01	400	84.36	99.37




FIGURA 26: GRÁFICA DE CAJAS Y BIGOTES EXPERIMENTO 4.

Finalmente para el experimento 4, se puede ver que el 50% de los resultados de exactitud se encuentran entre el 83% y el 85%. Al igual que en el experimento 3 el mejor resultado fue de 86.59%, a diferencia del resultado más bajo que fue de 80.45%. Para los mejores modelos, la tasa de aprendizaje inicial se estableció en 0.0005 y 0.001, mientras que el

número de épocas se estableció en 350 y 300, respectivamente (pruebas número 7 y 9).

En la figura 27 se muestra el mejor resultado de cada experimento con el promedio y desviación estándar de los 4 experimentos.




FIGURA 27: GRÁFICA DE RESUMEN DE EXPERIMENTOS.

3.5. Monitoreo de las hojas del jitomate con el sistema de control semiautomático

A partir de los resultados anteriores, dado que el experimento 4 (que utiliza imágenes de internet y una mejora de contraste) fue el que generó mejores resultados en la clasificación que se usó para la construcción del sistema de control. Gracias a esto se obtuvo la Tabla 6, en la cual se muestra el número de medición o muestra, la fecha en la que se realizó cada medición, el valor esperado (valor real) con base en las mediciones químicas, el valor obtenido (valor estimado) con base en el resultado del sistema de control semiautomático y el error donde 0 nos indica que el resultado obtenido por el sistema de control semiautomático fue acertado y 1 en donde la respuesta del sistema fue incorrecta. Gracias a estos resultados se logró obtener 70% de exactitud.

TABLA 6: RESULTADOS SISTEMA DE CONTROL SEMIAUTOMÁTICO

Muestra	Fecha	Valor Real	Valor estimado	Error
1	30-sep	Fósforo/Potasio/Nitrógeno	Potasio	0
2	30-sep	Fósforo/Potasio/Nitrógeno	Jitomate	1
3	30-sep	Fósforo/Potasio/Nitrógeno	Potasio	0
4	30-sep	Fósforo/Potasio/Nitrógeno	Fósforo	0
5	02-oct	Fósforo/Potasio/Nitrógeno	Potasio	0
6	02-oct	Fósforo/Potasio/Nitrógeno	Potasio	0
7	02-oct	Fósforo/Potasio/Nitrógeno	Fósforo	0

8	07-oct	Fósforo/Potasio/Nitrógeno	Fósforo	0
9	07-oct	Fósforo/Potasio/Nitrógeno	Nitrógeno	0
10	07-oct	Fósforo/Potasio/Nitrógeno	Nitrógeno	0
11	07-oct	Fósforo/Potasio/Nitrógeno	Nitrógeno	0
12	07-oct	Fósforo/Potasio/Nitrógeno	Fósforo	0
13	09-oct	Fósforo/Potasio/Nitrógeno	Jitomate	1
14	09-oct	Fósforo/Potasio/Nitrógeno	Nitrógeno	0
15	09-oct	Fósforo/Potasio/Nitrógeno	Potasio	0
16	09-oct	Fósforo/Potasio/Nitrógeno	Jitomate	1
17	09-oct	Fósforo/Potasio/Nitrógeno	Fósforo	0
18	09-oct	Fósforo/Potasio/Nitrógeno	Fósforo	0
19	09-oct	Fósforo/Potasio/Nitrógeno	Nitrógeno	0
20	09-oct	Fósforo/Potasio/Nitrógeno	Nitrógeno	0
21	17-oct	Fósforo/Potasio	Jitomate	1
22	17-oct	Fósforo/Potasio	Nitrógeno	1
23	17-oct	Fósforo/Potasio	Jitomate	1
24	17-oct	Fósforo/Potasio	Jitomate	1
25	17-oct	Fósforo/Potasio	Potasio	0
26	17-oct	Fósforo/Potasio	Potasio	0
27	18-oct	Fósforo/Potasio	Jitomate	1
28	18-oct	Fósforo/Potasio	Potasio	0
29	18-oct	Fósforo/Potasio	Fósforo	0
30	18-oct	Fósforo/Potasio	Jitomate	1
31	18-oct	Fósforo/Potasio	Jitomate	1
32	18-oct	Fósforo/Potasio	Fósforo	0
33	18-oct	Fósforo/Potasio	Jitomate	1
34	18-oct	Fósforo/Potasio	Potasio	0
35	18-oct	Fósforo/Potasio	Jitomate	1
36	18-oct	Fósforo/Potasio	Fósforo	0
37	18-oct	Fósforo/Potasio	Potasio	0
38	18-oct	Fósforo/Potasio	Potasio	0
39	18-oct	Fósforo/Potasio	Potasio	0
40	18-oct	Fósforo/Potasio	Fósforo	0

A continuación se muestran las imágenes obtenidas por el sistema de control semiautomático y el resultado del nutriente faltante que se obtuvo. La figura 28 tuvo como resultado déficit de potasio, debido a que las hojas se empiezan a poner amarillas en los bordes. En cambio la figura 29 muestra hojas verde amarillas lo que nos indica déficit de nitrógeno. En la figura 30, el resultado obtenido fue déficit de fósforo, lo cual es notorio en las hojas con venas moradas. Finalmente, las figura 31 nos indica que tenemos una planta en condiciones normales, ya que la mayor parte de las hojas presentan un verde oscuro.



FIGURA 28: RESULTADO SISTEMA DE CONTROL SEMIAUTOMÁTICO: POTASIO



FIGURA 29: RESULTADO SISTEMA DE CONTROL SEMIAUTOMÁTICO: NITRÓGENO



FIGURA 30: RESULTADO SISTEMA DE CONTROL SEMIAUTOMÁTICO: FÓSFORO



FIGURA 31: RESULTADO SISTEMA DE CONTROL SEMIAUTOMÁTICO: JITOMATE

3.6. Resumen experimentos

En la tabla 7, se muestran los parámetros de entrenamiento con los mejores resultados de cada uno de los 4 experimentos, donde se puede observar que el utilizar imágenes de Internet para el entrenamiento permitió obtener una mejor exactitud de aprendizaje y del sistema de control con las pruebas en tiempo real. Se puede observar que el valor inicial de aprendizaje con los mejores resultados se mantuvo entre 0.0001 y 0.001, mientras que el número máximo de épocas estuvo entre 250 y 350.

TABLA 7: RESUMEN EXPERIMENTOS

Experimento	Valor inicial de aprendizaje	Número máximo de épocas	Exactitud (%) evaluación	Exactitud (%) entrenamiento
1. Fotos originales	0.0001	350	56.42	99.28
2. Fotos originales contrastadas	0.0001	250	54.75	99.52
3. Fotos originales con imágenes de internet	0.001	300	86.59	99.58
4. Fotos originales contrastadas con imágenes de internet contrastadas	0.0005/0.001	350/300	86.59	99.37
Sistema de control en tiempo real	0.001	300	70	-

4. Discusión de resultados

A lo largo de la investigación, se realizó un análisis de las características principales de la planta del jitomate, así como los principales síntomas que esta tiene con la falta de los primordiales nutrientes. Para la experimentación se obtuvieron imágenes representativas de cada síntoma para entrenar el algoritmo y comprobar su efectividad.

Con base en los resultados obtenidos en la experimentación, se puede observar el acercamiento que tiene la exactitud del algoritmo con el 100% buscado al agregar imágenes con características muy notorias dentro del entrenamiento. Esto permite cumplir con el objetivo general de la investigación, debido a que con este algoritmo se pueden monitorear las características de las hojas de la planta del jitomate mediante un sistema de visión artificial y un algoritmo supervisado, con el fin de reducir gastos en los recursos.

Se puede observar que el mejor experimento fue el número 4, en el cual se utilizó el conjunto de datos compuesto por las fotos originales contrastadas tanto para el entrenamiento y la evaluación y las fotos de internet contrastadas para el entrenamiento, obteniendo un porcentaje de exactitud del 86.59%. De igual forma, la mayor parte de los resultados se encuentra entre 83% y 85%, lo que nos demuestra una mejor exactitud.

Gracias a los resultados obtenidos durante el monitoreo de las hojas con el sistema de control semiautomático se obtuvo un 70% de exactitud con respecto a las mediciones químicas de la tierra. Este porcentaje disminuyó debido a las condiciones ambientales en las que se realizaban las pruebas. La iluminación juega un papel importante en la evaluación final, lo que cambia el resultado final del sistema de control. Si hay poca luz durante la captura de la fotografía, se tendrá una imagen de una planta verde, lo que hará que el algoritmo la clasifique como en condiciones normales, en cambio si hay mucha iluminación la imagen será de una planta amarilla o verde limón, lo que nos dará como resultado que le hace falta nitrógeno o potasio.

Gracias al porcentaje de exactitud obtenido en la experimentación se puede decir que el utilizar este algoritmo a la par de un sistema de visión nos otorga varias ventajas:

- Reconocimiento anticipado a falta de los principales nutrientes en la tierra.
- Ahorro en recursos tales como nutrientes, debido a que se utilizarán los necesarios en el tiempo específico y aprovechamiento óptimo del cultivo.
- Aumento en la cantidad y calidad del producto final y disminución de desperdicios.
- Disminución en la contaminación de la tierra y el medio ambiente por uso controlado de los recursos.

Sin embargo, algunas de las limitantes que presenta la investigación son las siguientes:

- Se necesitan más imágenes para lograr un mejor porcentaje de exactitud en el algoritmo.

- La investigación está enfocada en la planta del jitomate y no en otras hortalizas.
- El implementar sistemas de visión en los cultivos puede llegar a ser costoso en un inicio.
- La luz es un factor muy importante durante la captura de imagen del algoritmo, lo que cambia el resultado final.

Al realizar una comparación con el trabajo ya existente se puede observar que dentro de la robótica el principal objetivo es mantener las características ambientales óptimas para mejores cultivos y resultados finales. Así mismo, se tiene la preocupación por una mayor seguridad para el usuario durante estos procesos. La implementación de tecnología en los procesos agrícolas ha contribuido en el uso de sistemas de visión para ayudar a determinar el mejor tiempo para la cosecha de ciertos frutos y vegetales, de igual forma este tipo de tecnología se ha utilizado para detectar plagas o enfermedades en un tiempo razonable para actuar proactivamente y obtener el mejor resultado al final de la cosecha.

A lo largo del trabajo se puede observar que el uso de sistemas de visión para detectar la falta de ciertos nutrientes en las plantas a través de la coloración de las hojas no se ha llevado a cabo, el enfoque principal de esta tecnología dentro de los cultivos está basado en la fase de cosecha del producto y prevención de plagas. Esto nos permite una innovación en la forma de detección y adicción de los nutrientes en el momento que la planta lo requiere.

Conclusiones

A lo largo de este trabajo se desarrolló un sistema que reconoce las características de las hojas de la planta del jitomate y que analiza los nutrientes que necesita la planta a través de un sistema de visión y un sistema de control semiautomático dando como resultado el nombre del nutriente que es necesario agregar en el regado.

Para la investigación, se creó una base de datos de fotografías de los distintos síntomas que la planta de jitomate presenta al faltarle alguno de sus principales nutrientes (nitrógeno, potasio, fósforo) con base en mediciones químicas realizadas en la tierra sin nutrientes y con la aplicación de estos a lo largo de la creación de la base de datos. Con esta base se entrenó al algoritmo supervisado y se realizaron distintos experimentos con el fin de obtener la mejor exactitud posible, la cual fue lograda con la combinación de imágenes originales contrastadas e imágenes de internet contrastadas para el entrenamiento y el uso de las imágenes originales contrastadas para la evaluación.

Durante este trabajo se monitorearon las hojas del jitomate con un sistema de visión artificial y se analizaron las imágenes capturadas por un algoritmo supervisado con 86% de exactitud y obtuvieron resultados a través del sistema de control semiautomático, logrando una exactitud del 70%, con el fin de reducir uso de recursos (nutrientes) y variar la estacionalidad de la planta para tener ejemplares sanos todo el año.

Con base en lo anterior, se puede afirmar que la hipótesis y objetivo general de la tesis se cumplió. De igual forma, se confirma que se cumplieron los objetivos específicos a lo largo de la investigación, experimentación y obtención de resultados finales.

Gracias a los resultados obtenidos y el cumplimiento de hipótesis y objetivos se sugiere para futuros trabajos lo siguiente:

- Incrementar la base de datos de fotos con las características de la planta del jitomate para el algoritmo.
- Extender la investigación con distintas plantas y sus síntomas para beneficiar una mayor parte del sector agrícola.
- Implementar una aplicación donde se puedan tomar fotos de la planta y con el aprendizaje obtenido por el algoritmo obtener en tiempo real el nutriente que le falta o si la planta se encuentra sana.
- Implementar un sistema robótico o sistema de control automático para el uso eficiente de nutrientes (nitrógeno, fósforo, potasio) en las plantas de jitomate.

Referencias

- [1] Infoagro, «El control de plagas reduce el desperdicio de alimentos,» Infoagro, Mexico, 2016.
- [2] Organización para las Naciones Unidas para la Alimentación y la Agricultura, «Pérdidas y Desperdicios de Alimentos en América Latina y el Caribe,» 2016.
- [3] Infoagro, «Buenas prácticas en el uso de fertilizantes,» Mexico, 2017.
- [4] Conoce Hidroponía, «IMPORTANCIA DEL CULTIVO DE JITOMATE EN MÉXICO,» Conoce Hidropónía, 19 11 2015. [En línea]. Available: <http://hidroponia.mx/importancia-del-cultivo-de-jitomate-en-mexico/>. [Último acceso: 27 04 2018].
- [5] D. Blancard, *Tomato Diseases: Identification, Biology and Control*, Versailles Cedex: Elsevier, 2009.
- [6] Agrológica, «Deficiencias y excesos nutricionales en tomate: síntomas y corrección,» Agrológica, 02 12 2012. [En línea]. Available: <http://blog.agrologica.es/deficiencias-y-excesos-nutricionales-en-cultivo-tomate-sintomas-y-correccion-fertilizantes-nitrogeno-fosforo-potasio-magnesio-calcio-azufre-hierro-zinc-manganeso-boro-molibdeno-cloro/#>. [Último acceso: 02 03 2018].
- [7] N. Noguchi y O. Barawid, «Robot Farming System Using Multiple Robot Tractors in Japan Agriculture,» vol. 44, nº 633-637, 2016.
- [8] E. v. Henten, C. Bac, J. Hemming y Y. Edan, «Robotics in protected cultivation,» vol. 46, nº 18, 2016.
- [9] L. F. Santos, S. Barbon, N. Valous y D. Fernandes, «Predicting the ripening of papaya fruit with digital imaging and random,» vol. 145, 2018.
- [10] K. P. Ferentinos, «Deep learning models for plant disease detection and diagnosis,» vol. 145, 2018.
- [11] J. De Baerdemaeker, «Precision Agriculture Technology and Robotics for Good Agricultural Practices,» vol. 44, nº 1-4, 2016.
- [12] A. Opic, *Manual De Manejo Sustentable Del Cultivo De Jitomate En Invernadero*, Mexico: Palibrio, 2013.
- [13] Diario de Siembra, «TALLER DE TRATAMIENTOS CASEROS Y NATURALES PARA CUIDAR NUESTRAS PLANTAS,» Diario de Siembra, 18 01 2017. [En línea]. Available: <https://diariodesiembra.com/2017/01/18/taller-de-tratamientos-caseros-y-naturales-para-cuidar-nuestras-plantas/>. [Último acceso: 02 03 2018].
- [14] BIOGUÍA, «Guía de falta de nutrientes,» LA BIOGUÍA OFICIAL, 12 05 2013. [En línea]. Available: https://www.bioguia.com/ambiente/guia-de-falta-de-nutrientes_29268950.html. [Último acceso: 23 01 2020].
- [15] Jardinería Plantas y Flores, «Como Identificar la falta de nutrientes en las plantas,» Jardinería Plantas y Flores, 2014. [En línea]. Available: <https://jardineriaplantasyflores.com/como-identificar-la-falta-de-nutrientes-en-las-plantas/>. [Último acceso: 27 04 2018].
- [16] J. A. Oliveira, E. A. Khouri y M. M. López, *Análisis de suelos y plantas y recomendaciones de abonado*, Asturias: Universidad de Oviedo, 2006.
- [17] J. Santos, «Fixes for Nutrient Deficient Soil,» Permaculture Research Institute, 04 07 2018. [En línea]. Available: <https://permaculturenews.org/2018/07/04/fixes-nutrient-deficient->

- soil/. [Último acceso: 23 01 2020].
- [18] E. Heuvelink, TOMATOES, Netherlands: CABI, 2005.
- [19] Infoagro, «EL CULTIVO DEL TOMATE (1ª parte),» Infoagro, [En línea]. Available: <http://www.infoagro.com/hortalizas/tomate.htm>. [Último acceso: 10 05 2018].
- [20] Infojardin, «Tomate, Tomatera, Jitomate,» Infojardin, [En línea]. Available: <http://fichas.infojardin.com/hortalizas-verduras/tomate-tomatera-jitomate.htm>. [Último acceso: 10 05 2018].
- [21] J. B. Jones, Tomato Plant Culture: In the Field, Greenhouse, and Home Garden, Second Edition, Florida: CRC Press, 2007.
- [22] G. Harland y S. L. Craxton, Tomato, New York: Penguin, 2009.
- [23] FAO, «El Cultivo de Tomate con Buenas Prácticas Agrícolas en la Agricultura Urbana y Periurbana,» Paraguay, 2013.
- [24] SAGARPA, «Planeación Agrícola Nacional,» 2017. [En línea]. Available: <https://www.gob.mx/cms/uploads/attachment/file/257077/Potencial-Jitomate.pdf>. [Último acceso: 13 06 2018].
- [25] Infoagro, «Principales variedades de tomate y su relación en el mercado internacional,» Infoagro.com, 28 03 2016. [En línea]. Available: <http://infoagro.com/mexico/principales-variedades-de-tomate/>. [Último acceso: 13 06 2018].
- [26] J. A. L. Chanabá, Efecto De La Fertilizacion Quimica Y Organica En El Tomate De Arbol, Quito: INIAP Archivo Historico, 2003.
- [27] A. M. Vega, Manejo y mantenimiento de invernaderos, Navarra: Mundi-Prensa Libros, 2017.
- [28] N. Ross, Jardinería de Invernadero, Babelcube Inc, 2017.
- [29] E. Barrera, R. Herrero y A. Meraz, «Invernadero Inteligente,» México, 2014.
- [30] Migo Glass, «Migo Glass,» Migo Glass, [En línea]. Available: <http://otq.migoglass.net/greenhouse-glass/clear-greenhouse-glass/4mm-19mm-low-iron-greenhouse-glass-for-agriculture.html>. [Último acceso: 02 03 2018].
- [31] Novedades Agrícolas, «¿En qué consiste un invernadero inteligente?,» Novedades Agrícolas S.A., 16 01 2015. [En línea]. Available: <http://www.novedades-agricolas.com/es/blog/articulos/item/1320-que-es-un-invernadero-inteligente>. [Último acceso: 27 02 2018].
- [32] Asociación de Agrónomos Indígenas de Cañar, Proceso de fertirrigación en el cultivo de tomate en invernadero, Ecuador: INIAP Archivo Histórico, 2004.
- [33] D. Horcajo, «Riego por goteo,» Agrohuerto, 09 07 2014. [En línea]. Available: <https://www.agrohuerto.com/riego-por-goteo-que-es/>. [Último acceso: 03 03 2018].
- [34] Orcelis, «Orcelis Fitocontrol escogida mejor aplicación para la fertirrigación del olivar,» Orcelis, [En línea]. Available: <https://fitocontrol.com/aplicacion-informatica-para-la-optimizacion-de-la-fertirrigacion-en-olivar/>. [Último acceso: 03 03 2018].
- [35] S. Cubero, F. Albert, J. M. Prats-Moltabán, D. G. Fernández-Pacheco, J. Blasco y N. Aleixos, «Application for the estimation of the standard citrus colour index (CCI) using image processing in mobile devices,» vol. 167, 2017.
- [36] P. Wan, A. Toudeshki, H. Tan y R. Ehsani, «A methodology for fresh tomato maturity detection using computer vision,» vol. 146, 2018.

- [37] N. El-Bendary, E. E. Hariri, A. E. Hassanien y A. Badr, «Using machine learning techniques for evaluating tomato ripeness,» vol. 42, nº 4, 2014.
- [38] Megha.P.Arakeri y Lakshmana, «Computer Vision Based Fruit Grading System for Quality Evaluation of Tomato in Agriculture industry,» vol. 79, 2016.
- [39] N. Goel y P. Sehgal, «Fuzzy classification of pre-harvest tomatoes for ripeness estimation – An approach based on automatic rule learning using decision tree,» vol. 36, 2015.
- [40] J. M. i. Bustio, *Sistemas de identificación y control automático*, España: Marcombo, 2009.
- [41] Cognex, «Visión Artificial,» Cognex, [En línea]. Available: <https://www.cognex.com/es/ve/what-is/machine-vision/components>. [Último acceso: 11 05 18].
- [42] G. Hernández y J. Mendoza, *Fundamentos y planeación de la manufactura automatizada: un enfoque de los sistemas integrados de la manufactura*, Mexico: Pearson, 2015.
- [43] INFAIMON, «Tecnología Iluminación,» INFAIMON, 03 07 2014. [En línea]. Available: <https://www.infaimon.com/es/tecnologia-iluminacion>. [Último acceso: 15 05 2018].
- [44] Y. Zhao, L. Gong, B. Zhou, Y. Huang y C. Liu, «Detecting tomatoes in greenhouse scenes by combining AdaBoost classifier and colour analysis,» vol. 148, 2016.
- [45] A. Payne, K. Walsh, P. Subedi y D. Jarvis, «Estimation of mango crop yield using image analysis – Segmentation method,» vol. 91, 2013.
- [46] A. Payne, K. Walsh, P. Subedi y D. Jarvis, «Estimating mango crop yield using image analysis using fruit at ‘stone hardening’ stage and night time imaging,» vol. 100, 2014.
- [47] INFAIMON, «Tecnología Camaras,» INFAIMON, 28 07 2014. [En línea]. Available: <https://www.infaimon.com/es/tecnologia-camaras>. [Último acceso: 18 05 2018].
- [48] P.J.Ramos, F.A.Prieto, E.C.Montoya y C.E.Oliveros, «Automatic fruit count on coffee branches using computer vision,» vol. 137, 2017.
- [49] A. Aquino, I. Barrio, M.-P. Diago, B. Millan y J. Tardaguila, «vitisBerry: An Android-smartphone application to early evaluate the number of grapevine berries by means of image analysis,» vol. 148, 2018.
- [50] B. B. Machado, J. Orue, M. Arruda, C. Santos, D. Sarath, W. Goncalves, G. Silva, H. Pistori, A. Roel y J. Rodrigues, «BioLeaf: A professional mobile application to measure foliar damage caused by insect herbivory,» vol. 129, 2016.
- [51] J. Niño, *Sistemas operativos monopuesto*, Editex, 2011.
- [52] National Instruments, *Data Acquisition: 7 Steps to Success*, National Instruments, 2006.
- [53] F. Mora y G. Passariello, *Imágenes médicas. Adquisición, Analisis, Procesamiento e Interpretación*, Venezuela: Equinoccio.
- [54] «Image Filtering,» Mathworks, [En línea]. Available: <https://www.mathworks.com/help/images/linear-filtering.html>. [Último acceso: 05 02 2020].
- [55] ARSET, «Clasificación supervisada Introducción Parte 1 - ARSET,» 2017. [En línea]. Available: [https://arset.gsfc.nasa.gov/sites/default/files/land/webinars/Advanced_Land_Classification/Exercise%201%20-%20Creating%20a%20Supervised%20Land%20Cover%20Classification%20\(Spanish\).pdf](https://arset.gsfc.nasa.gov/sites/default/files/land/webinars/Advanced_Land_Classification/Exercise%201%20-%20Creating%20a%20Supervised%20Land%20Cover%20Classification%20(Spanish).pdf). [Último acceso: 04 02 2020].
- [56] RAE, «Real Academia Española,» RAE, 2019. [En línea]. Available: <https://dle.rae.es/?w=interfaz>. [Último acceso: 14 02 2020].

- [57] J. L. Pardo, Montaje y puesta en marcha de sistemas robóticos y sistemas de visión, en bienes de equipo y maquinaria industrial, IC Editorial, 2013.
- [58] R. P. Ñeco, O. Reinoso y N. García, Apuntes de sistemas de control, Elche: Editorial Club Universitario, 2003.
- [59] A. J. Steidle, S. Zolnier y D. d. Carvalho, «Development and evaluation of an automated system for fertigation control in soilless tomato production,» *Computers and Electronics in Agriculture*, vol. 103, pp. 17-25, 2014.
- [60] A. Pérez-Castro, J. Sánchez-Molina, M. Castilla, J. Sánchez-Moreno, J. Moreno-Úbeda y J. Magán, «cFertigUAL: A fertigation management app for greenhouse vegetable crops,» *Agricultural Water Management*, vol. 183, pp. 186-193, 2017.
- [61] L. G. Corona Ramírez, G. S. Abarca Jiménez, y J. Mares Carreño, Sensores y Actuadores, México: Grupo Editorial Patria, 2014.
- [62] J. A. Somolinos Sánchez, Avances en robótica y visión por computador, España: Univ de Castilla La Mancha, 2002.
- [63] E. F. Martínez y Á. S. Calle, Aplicaciones de la visión artificial y la biometría informática, Madrid: DYKINSON, 2005, p. 113.
- [64] K. P. Murphy, Machine Learning: A Probabilistic Perspective, Massachusetts: MIT Press, 2012.
- [65] M. Mohri, A. Rostamizadeh y A. Talwalkar, Foundations of Machine Learning, MIT Press, 2012.
- [66] A. E. Hassanien, T. Gaber, U. Mokhtar y H. Hefny, «An improved moth flame optimization algorithm based on rough sets for tomato diseases detection,» *Computers and Electronics in Agriculture*, vol. 136, pp. 86-96, 2017.
- [67] D. L. Borges, S. T. d. M. Guedes, A. R. Nascimento y P. Melo-Pinto, «Detecting and grading severity of bacterial spot caused by *Xanthomonas* spp. in tomato (*Solanum lycopersicon*) fields using visible spectrum images,» *Computers and Electronics in Agriculture*, vol. 125, pp. 149-159, 2016.
- [68] K. L. Priddy y P. E. Keller, Artificial Neural Networks: An Introduction, Washington: SPIE Press, 2005.
- [69] K. Mehrotra, C. K. Mohan y S. Ranka, Elements of Artificial Neural Networks, Massachusetts: MIT Press, 1997.
- [70] I. Molina, «¿Cómo aprende una red neuronal de IA?,» QUORA, 10 07 2019. [En línea]. Available: <https://es.quora.com/C%C3%B3mo-aprende-una-red-neuronal-de-IA>. [Último acceso: 14 02 2020].
- [71] MathWorks, «Redes neuronales,» MathWorks, [En línea]. Available: <https://la.mathworks.com/discovery/neural-network.html>. [Último acceso: 04 January 2019].
- [72] S. Zarifneshat, A. Rohani, H. R. Ghassemzadeh, M. Sadeghi, E. Ahmad y M. Zarifneshat, «Predictions of apple bruise volume using artificial neural network,» *Computers and Electronics in Agriculture*, vol. 82, pp. 75-86, 2012.
- [73] K. Movagharnejad y M. Nikzad, «Modeling of tomato drying using artificial neural network,» *Computers and Electronics in Agriculture*, vol. 59, nº 1-2, pp. 78-85, 2007.
- [74] MathWorks, «Deep Learning,» MathWorks, [En línea]. Available: <https://la.mathworks.com/discovery/deep-learning.html>. [Último acceso: 07 01 2019].

- [75] M. M. Najafabadi, F. Villanustre, T. M. Khoshgoftaar, N. Seliya, R. Wald y E. Muharemagic, «Deep learning applications and challenges in big data analytics,» *Journal of Big Data*, vol. 2, nº 1, 2015.
- [76] A. Kamilaris y F. X. Prenafeta-Boldú, «Deep learning in agriculture: A survey,» *Computers and Electronics in Agriculture*, vol. 147, pp. 70-90, 2018.
- [77] S. H. Lee, C. S. Chan, S. J. Mayo y P. Remagnino, «How deep learning extracts and learns leaf features for plant classification,» *Pattern Recognition*, vol. 71, pp. 1-13, 2017.
- [78] MathWorks, «Redes Neuronales Convolucionales,» MathWorks, [En línea]. Available: <https://la.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>. [Último acceso: 07 01 2019].
- [79] G. L. Grinblat, L. C. Uzal, M. G. Larese y P. M. Granitto, «Deep learning for plant identification using vein morphological patterns,» *Computers and Electronics in Agriculture*, vol. 127, pp. 418-424, 2016.
- [80] E. C. Too, L. Yujian, S. Njuki y L. Yingchun, «A comparative study of fine-tuning deep learning models for plant disease identification,» *Computers and Electronics in Agriculture*, 2018.
- [81] A. Khan, A. Sohail, U. Zahoora y A. S. Qureshi, «A Survey of the Recent Architectures of Deep Convolutional Neural Networks,» *CoRR*, 2019.
- [82] G. Montavon, G. Orr y K.-R. Müller, *Neural Networks: Tricks of the Trade*, Springer, 2012.
- [83] M. A. O. Cámara, «¿Qué es la fertirrigación?,» *Fertirrigación*, 03 12 2017. [En línea]. Available: <http://www.fertirrigacion.com/que-es-la-fertirrigacion/>. [Último acceso: 03 03 2018].
- [84] W. Pérez y G. Forbes, *Guía de identificación de plagas que afectan a la papa en la zona andina.*, Peru: International Potato Center, 2011.
- [85] M. Á. Maya Álvarez, *Preparación del terreno para la instalación de infraestructuras, siembra y plantación de cultivos herbáceos.*, IC Editorial, 2018.
- [86] E. López González, *Trabajos auxiliares en la elaboración de composiciones con flores y plantas*, España: Editorial Elearning, S.L., 2015.
- [87] G. Vargas Rojas, *Botánica General. Desde Los Musgos Hasta Los Árboles*, San José: EUNED, 2011.