INSTITUTO TECNOLÓGICO SUPERIOR DE CAJEME

Diseño de un sistema de control inteligente para detectar la roya de la hoja en el trigo por detección de patrones a partir de las imágenes digitales

TESIS

PARA OBTENER EL GRADO DE

MAESTRO EN INGENIERÍA MECATRÓNICA

PRESENTAN

ING. JAVIER AMADO LUZANILLA VARGAS

ING. MANUEL DE JESUS ROMAN ROMAN

DIRECTOR DEL PROYECTO

DR. JUAN ENRIQUE PALOMARES RUIZ

CD. OBREGÓN, SON. NOVIEMBRE DE 2020

ITESCA®
Instituto Tecnológico Superior de Cajeme

DICTAMEN DE LIBERACIÓN Y APROBACIÓN

F02PSA16.02

Fecha

26 de junio de 2020

No. de Registro

Dr. José Efrén Ruelas Ruiz
Coordinador del Programa de la Maestría en ***Ingeniería Mecatrónica***
PRESENTE

A través de este documento, me permito comunicarle que el alumno ***Manuel de Jesús Román Román*** cuyo proyecto de obtención de grado

DISEÑO DE UN SISTEMA DE CONTROL INTELIGENTE PARA DETECTAR LA ROYA DE LA HOJA EN EL TRIGO POR DETECCIÓN DE PATRONES A PARTIR DE IMÁGENES DIGITALES

Cumple satisfactoriamente, con los Lineamientos para la Operación de Estudios de Posgrado en el Sistema Nacional de Educación Superior Tecnológica, por lo que ha sido aceptado para la obtención del grado:

MAESTRO EN INGENIERÍA MECATRÓNICA

Sin más por el momento, quedo de Usted.

Juan E. Palomares

Dr. Juan Enrique Palomares Ruiz
Director de proyecto de obtención de grado

26 de Junio de 2020
Fecha

DICTAMEN DE ACEPTACION - COMISIÓN REVISORA

PRESIDENTE	Dr. Juan Enrique Palomares Ruiz	Juan E. Palomares	26 de Junio de 2020
	Nombre	**Firma**	**Fecha**
MIEMBRO 1	Dr. José Guadalupe Castro Lugo		26 de Junio de 2020
	Nombre	**Firma**	**Fecha**
MIEMBRO 2	Dr. Flavio Muñoz Beltrán	Flavio Muñoz B.	26 de Junio de 2020
	Nombre	**Firma**	**Fecha**

DEDICATORIA JAVIER AMADO LUZANILLA VARGAS

En primer lugar, le agradezco a Dios por prestarme la vida para estudiar esta maestría y por haber hecho que esto sea posible.

Le dedico este trabajo a mis padres, para que se sientan orgullosos de esa semilla que desde pequeño sembraron en mí y que el día de hoy está dando frutos.

De una manera muy en especial, esta maestría se la dedico a mi esposa Dulce María y a mis hijos, por todo el tiempo que no estuve con ustedes por estar ocupado en la maestría, porque fue un sacrificio para todos, se los dedico con mucho amor y cariño.

También le dedico este trabajo a toda mi familia y amigos, quienes me han mostrado su felicidad y apoyo por estar buscando superarme.

DEDICATORIA MANUEL DE JESÚS ROMÁN ROMÁN

Este proyecto está dedicado a las personas mas importantes en mi vida, mis seres queridos, aquellos que han sido pilar en la formación de la persona que hoy soy.

A mis padres que con mucho esfuerzo y sacrificio me dieron la educación primaria, secundaria y preparatoria, que intentaron también darme la educación superior que por diversos motivos no fue posible culminar en esos momentos. A ellos les dedico este trabajo como una pequeña retribución a todo ese esfuerzo y sacrificio.

A mis hermanos, para que este logro que hoy alcanzo les sirva como motivación y ejemplo de que nunca es tarde a para superarse y buscar algo mejor para tu vida.

A mi esposa que me apoyó en todo el proceso, que se desveló conmigo y que me daba aliento en los momentos mas desesperantes; también se alegró con cada pequeño logro que se daba en el camino y me daba la palmada que necesitaba para motivarme.

A mis sobrinos y ahijados, que me sirvieron también como motivación para llegar a ser un ejemplo para ellos, aunque sea académico; espero un día poder leer alguna de sus tesis y saber que se vieron inspirados y motivados por el logro de su tío.

A todos aquellos que me ofrecieron su apoyo en momentos difíciles y me ayudaron a seguir adelante en este camino, aquellos que me regalaron un par de zapatos para ir a la escuela, aquel que me regaló una mochila para mis útiles, a quien me prestó un libro, a quien me asesoró en temas que no dominaba; a todos los que directa o indirectamente son partícipes de este proyecto.

A todos ellos les dedico esta tesis.

AGRADECIMIENTOS JAVIER AMADO LUZANILLA VARGAS

Al CONACYT: Por haberme dado la valiosa oportunidad obtener la beca a través del Programa Nacional de Posgrados de Calidad (PNPC) y así estar concluyendo una meta más a mi vida.

Al ITESCA: Por haberme aceptado como su alumno y darme la oportunidad de estudiar esta maestría.

A mis maestros: Por toda su comprensión, esfuerzo, paciencia, y por el tiempo que se dedicaron a enseñarnos de la mejor manera todo su conocimiento, así como los varios consejos que nos dieron para sacar adelante este compromiso.

Al Dr. Juan Enrique Palomares: Gracias por ese consejo que me diste el cual me ayudo a motivarme para estudiar y que significo un cambio en mis hábitos de vida.

AGRADECIMIENTOS MANUEL DE JESÚS ROMÁN ROMÁN

A Dios: Por darme una vida dichosa y sana; por haberme puesto en las manos de los padres y hermanos ideales para mi, para mi camino y mi misión; por haber puesto en mi sendero a una mujer que me apoya e impulsa a ser mejor cada día; pero sobre todo por estar siempre ahí, sigiloso en los momentos felices y notorio en los difíciles.

A mis padres: De ustedes aprendí a trabajar duro, a amar en tiempos de crisis, a no guardar rencores, a perseguir mis sueños y lograr lo que me proponga sin dañar a nadie, éste nuevo logro en mi vida no puede pasar sin un agradecimiento a ustedes que pusieron los cimientos del mismo; muchas gracias porque, a pesar de todas las dificultades y carencias, pusieron en mis manos lápiz y cuaderno en lugar pala y azadón; gracias a mis viejos; a mi madre **María Martha Román Lugo**; a mi padre **Manuel de Jesús Román**.

A mis hermanos: Ustedes me enseñaron a ser parte de un equipo, en ocasiones siguiendo a un líder, en otras siendo yo mismo el líder a seguir; hemos sido amigos, compañeros, cómplices; juntos logramos muchas cosas buenas y dimos también sus dolores de cabeza a los viejos; juntos aprendimos a superar diferencias y seguir adelante con los proyectos a pesar de ellas. Gracias a mis hermanos: **Francisca Yadira**, **Ángel Osbaldo**, **Obed Roberto**, **Abel Alfonso** y **Martha Larissa**.

A mi esposa: Por entenderme, apoyarme, ayudarme, comprender las ausencias, compartir los desvelos, reír y llorar conmigo, por ser esa mitad que me faltaba y que me complementa, gracias a ti he logrado mas de lo que un día pensé que lograría, sin tu apoyo muchas cosas no serían posibles hoy en día, entre ellas éste logro. Gracias **María del Carmen Montoya Sánchez**

A ITESCA: La universidad que me abrió las puertas a pesar de mi avanzada edad para estudiar una Ingeniería y posteriormente la maestría que hoy culmina.

A mis maestros: Tanto de Ingeniería como de maestría, todos ellos me apoyaron de una u otra

forma para llegar hasta donde estoy ahora, gracias por su comprensión y guía, por su pasión y alegría al impartir sus clases. Muy especialmente quiero hacer mención de aquellos maestros que aportaron más que un granito de arena para seguir en este camino:

- **Mtro. José Luis Beltrán Álvarez**: Gracias por transmitirme su pasión por la inteligencia artificial y los algoritmos de aprendizaje y análisis de datos, además de aconsejarme y motivarme para que siguiera adelante con el siguiente nivel: esta maestría.
- **Dr. José Guadalupe Castro**: Gracias por recordarme lo hermosas e importantes que son las matemáticas en mi vida, despertó de nuevo en mi aquel muchacho curioso y apasionado de las ciencias exactas que dormía desde mis tiempos de preparatoria.
- **Dr. Juan Enrique Palomares Ruiz**: Gracias por ver en mi a un programador capaz de sacar adelante un proyecto de este tipo y darme la oportunidad de participar en el mismo, ha sido una gran aventura y placer.

A todo el que me dijo *"no podrás"*: Gracias, porque con la crianza que me dieron y el carácter que me forjaron, lejos de derrumbarme o desanimarme, sus palabras me ayudaron a fijarlo como una meta, a desafiarme a mi mismo para demostrar lo contrario y lograr lo que, sin ese reto impuesto indirectamente por ustedes, tal vez hoy no sería posible.

RESUMEN

En este trabajo conoceremos la importancia del trigo a nivel mundial, los avances tecnológicos que están haciendo organizaciones e instituciones internacionales para hacer más rentable la agricultura, así como los daños que pueden ocasionar las royas en el trigo.

Además, en este trabajo se pretende diseñar un sistema de control inteligente utilizando redes neuronales para detectar la roya de la hoja en el trigo por medio de detección de patrones, con apoyo de un dron y una cámara profesional.

Nos enfocaremos en desarrollar un software que nos permita detectar la enfermedad de la roya de la hoja en el trigo, utilizando los componentes en RGB de una imagen de la roya que seleccionamos previamente de internet para ir entrenando nuestra red neuronal.

El tipo de red que utilizaremos es de tipo adaline y el lenguaje de programación será JAVA.

El desarrollo de esta investigación se realizó en la ciudad de Navojoa, en un cultivo de trigo monitoreado por la JLSV (junta local de sanidad vegetal).

ABSTRACT

In this work we will know the importance of wheat worldwide, the technological advances that international organizations and institutions are making to make agriculture more profitable, as well as the damage that rust can cause in wheat.

In addition, this work aims to design an intelligent control system using neural networks to detect leaf rust in wheat through pattern detection, with the support of a drone and a professional camera.

We will focus on developing software that allows us to detect leaf rust disease in wheat, using the RGB (Red, Green and Blue) components of an image of rust that we previously selected from the internet to train our network. neuronal.

The type of network that we will use is of the adaline type and the programming language will be JAVA.

The development of this research was carried out in the city of Navojoa, in a wheat crop monitored by the JLSV (local board of plant health).

ÍNDICE

1.. Introducción 17
1.1. Antecedentes 17
1.1.1. Un método preciso para medir severidad de Roya de la hoja (Puccinia Triticina Eriksson) 17
1.1.2. Aplicación Móvil de detección y clasificación de la Roya en hojas de cfé robusta mediante aprendizaje automático 17
1.1.3. Inteligencia artificial y Big Data para combatir plagas 17
1.1.4. Redes neuronales aplicadas al control de riego usando instrumentación y análisis de imágenes para un micro invernadero aplicado al cultivo de Albahaca 19
1.1.5. Redes neuronales para modelar predicción de heladas 19
1.1.6. Redes neuronales artificiales aplicadas al cacao, tecnología al servicio del cultivo 20
1.1.7. Prototipo basado en redes neuronales para monitoreo y predicción de temperatura en invernaderos de los valles centrales de Oaxaca 21
1.1.8. Sistema inteligente para controlar sistemas de riego en México 22
1.1.9. Diseño e implementación de un sistema de seguimiento de parámetros ambientales en plantaciones de café 22
1.1.10. Automatización, monitoreo y control remoto de un sistema de riego agrícola con código abierto 24
1.1.11. Diseño y construcción de un prototipo de sistema de riego automatizado para la granja experimental Nono de la UDLA 25

1.1.12. Diagrama del prototipo de máquina inteligente de fertiriego de control remoto y bajo costo en la región lambayeque 26
1.1.13. Selección de cereales mediante drones par ala producción de bioetanol . . 26
1.1.14. Aceleración del cultivo de plantas 28
1.1.15. Drones en árboles frutales 29
1.1.16. Drones en el cultivo de piña 29
1.1.17. Drones para monitorear maíz 30
1.1.18. Inteligencia artificial incorporada a maquinaria John Deere 32
1.1.19. Microsoft y la inteligencia artificial en la agricultura 33
1.1.20. Agricultura inteligente utilizando red 5G 35
1.1.21. E-kakashi. Un cerebro de inteligencia artificial en la agricultura 36
1.1.22. Detección en tiempo real de malezas a través de técnicas de visión artificial y su incorporación en sistemas de aplicación selectiva de herbicidas . . . 39
1.1.23. Plataforma para gestionar cultivo de aguacate 40
1.1.24. Máquina clasificadora de frutas y vegetales 42
1.1.25. Inteligencia artificial en la producción de frutas y vegetales 42
1.2. Enunciado del Problema 43
1.3. Justificación 43
1.4. Objetivos 44
1.4.1. Objetivo general 44
1.4.2. Objetivos específicos 45
1.5. Alcances y limitaciones 45
1.5.1. Alcances 45
1.5.2. Limitaciones 45

2.. Marco teórico 46
2.1. Origen del trigo y su importancia mundial 46
2.2. Enfermedades del trigo 47
2.2.1. Royas del trigo 47

2.3. Agricultura de precisión 48
2.4. Drones 49
2.5. Redes neuronales artificiales 50
2.5.1. Adaline 51
2.6. Lógica difusa 52
2.7. Sistema de captura de imágenes 55
2.7.1. Imagen 55
2.7.2. Iluminación 55
2.7.3. Filtros 56
2.7.4. Difusores 56
2.7.5. Sistema óptico 56
2.7.6. Camara 56
2.8. Operaciones sobre el histograma y filtrado de la imagen 57
2.8.1. Histograma de la imagen 57
2.8.2. Filtros paso bajo 57
2.8.3. Filtros paso alto 58
2.8.4. Filtros pasa banda 59
2.9. El Color 59
2.9.1. Espacios de color 59
2.10. Transformación de imágenes 60
2.10.1. Tipos de transformaciones 60
2.11. Procesamiento morfológico 63
2.12. Segmentación de regiones 63
2.12.1. Binarización por umbral 63
2.12.2. Etiquetado de componentes conexas 63
2.13. Extracción de regiones por color 65
2.14. Clasificación y reconocimiento de patrones 65

3.. Desarrollo 68
3.1. Generación de máscara de aprendizaje 68
3.2. Programación 70
3.2.1. Generación de matriz de datos 70
3.2.2. Entrenamiento Adaline 71
3.2.3. Procesamiento de imágenes 73
3.2.4. Notas sobre ejecuciones posteriores 76
3.3. Visita a cultivos para toma de muestras 76
3.3.1. Procesamiento de muestras 77

4.. Conclusiones y recomendaciones 80
4.1. Conclusiones 80
4.2. Recomendaciones 81

Referencias bibliográficas 83

ÍNDICE DE FIGURAS

1.1. Hojas bandera afectadas por roya 18
1.2. Imágenes cargadas al teléfono para ser procesadas 18
1.3. Inteligencia Artificial y Big Data para combatir plagas 19
1.4. Red neuronal para el control de riego 20
1.5. Red neuronal para prevención de heladas 20
1.6. Aplicación de red neuronal para mejorar producción de cultivos 21
1.7. Módulo de interfaz de usuario 22
1.8. Imágenes de Magros 23
1.9. Instalación de sensores 24
1.10. Estructura funcional del sistema 25
1.11. Prototipo UDLA 26
1.12. Vista isométrica y frontal de la máquina de fertiriego 27
1.13. Captura de imágenes multiespectrales con un dron 28
1.14. Marcado y detección automática de malezas y plantas cultivadas 29
1.15. Dron sobre un huerto de fruta 30
1.16. Dron aplicado a la piña y al banano en Costa Rica 31
1.17. Análisis de información de maíz por medio de un dron 32
1.18. Tractor autónomo de la empresa John Deere 34
1.19. Microsoft Azure apuesta por una agricultura inteligente 35
1.20. Agricultura inteligente y red 5G 37
1.21. E-kakashi 39
1.22. Plataforma visual aplicada en plantes de aguacate 41
1.23. Mapa de predios infectados 44

2.1. Principales productores mundiales de trigo del ciclo 2014-2015. 46
2.2. Infección en el trigo a causa de las royas. 47
2.3. Sistema de entrenamiento para una red adaline. 52
2.4. Diagramas de Venn. 53
2.5. Diferencia entre lógica booleana y difusa. 54
2.6. Diagrama esquemático del controlador difuso. 55
2.7. Representación gráfica de un histograma. 58
2.8. Distintos valores de radio. 58
2.9. Ejemplo de utilización de un filtro paso bajo. 58
2.10. Distintos valores de radio. 59
2.11. Ejemplo de utilización de un filtro paso bajo. 59
2.12. Representación de los valores de un pixel. 61
2.13. Imágenes estereoscópicas. 61
2.14. Resultado de operaciones lógicas. 62
2.15. Binarización de imágenes. 64
2.16. Histogramas de intensidad. 64
2.17. Algoritmo iterativo para el etiquetado de componentes conexas. 65
2.18. Aplicación de algoritmo iterativo para el etiquetado de componentes conexas. . . 66
2.19. Binarización de imagen por medio de color. 66
2.20. Clasificación. Los datos se presentan por dos características x_1 y x_2 67

3.1. Creación de máscara de aprendizaje 69
3.2. Procesado de imagen utilizada para máscara 75
3.3. Primer ejemplo de procesado de imagen diferente a la base 75
3.4. Segundo ejemplo de procesado de imagen diferente a la base 75
3.5. Imagen del dron sobrevolando la parcela 77
3.6. Toma terrestre 1 78
3.7. Toma terrestre 2 78
3.8. Toma terrestre 3 78

3.9. Toma aérea 1 79

3.10. Toma aérea 2 79

3.11. Toma aérea 3 79

ÍNDICE DE TABLAS

3.1. Ejemplo de datos en la matriz 71

3.2. Ejemplo de pesos finales para las componentes R,G,B 73

1. INTRODUCCIÓN

1.1 Antecedentes

1.1.1 Un método preciso para medir severidad de Roya de la hoja (Puccinia Triticina Eriksson)

En en el estado de Sinaloa, diversas universidades de México se unieron para hacer una investigación sobre un método preciso para medir la severidad de la roya de la hoja en el trigo con un programa de procesamiento y análisis de imágenes digitales.

El estudio consiste en tomar muestras de 5 genotipos de trigo harinero para posteriormente escanearlas y con la ayuda del programa ImageJ, procesar y analizar las imágenes [1].

1.1.2 Aplicación Móvil de detección y clasificación de la Roya en hojas de cfé robusta mediante aprendizaje automático

En Ecuador estudiantes de la ESPAM MFL (escuela superior politécnica agropecuaria de Manabí Manuel Félix López), desarrollaron una aplicación de detección y clasificación de la roya en hojas de café robusta mediante aprendizaje automático para optimizar la agricultura de Manabí debido a su importancia social [2].

1.1.3 Inteligencia artificial y Big Data para combatir plagas

En Madrid la empresa IGEO ERP diseñó un sistema de predicción que analiza el estado del cultivo, el clima y las diferentes variables que son esenciales para la agricultura, y facilita una serie de resultados, que ayudan a tomar la decisión más adecuada a los agricultores. Además, los estudios realizados con el sistema son capaces de analizar tanto el presente como el futuro



(a) Roya de la hoja (b) Imagen segmentada (c) Area dañada por la enfermedad

Fig. 1.1: Hojas bandera afectadas por roya

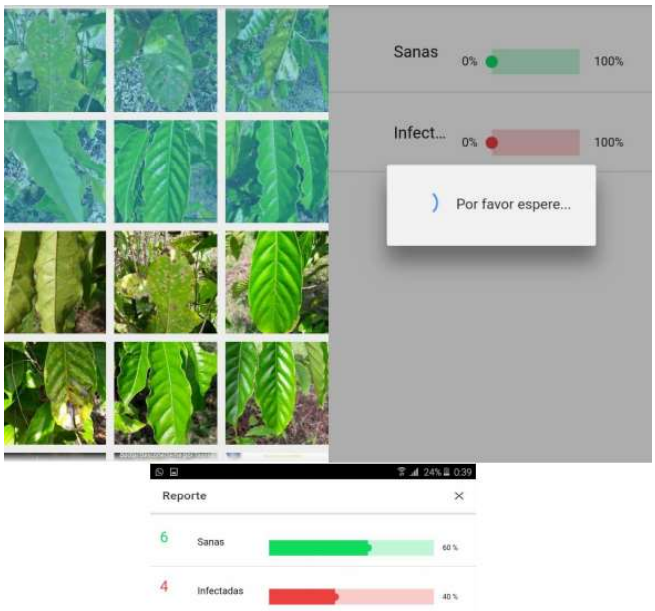


Fig. 1.2: Imágenes cargadas al teléfono para ser procesadas

y predecir la aparición de alguna plaga, gracias a que integra sofisticadas metodologías de machine-learning, reglas de asociación patentadas y algoritmos de lógica difusa [3].



Fig. 1.3: Inteligencia Artificial y Big Data para combatir plagas

1.1.4 Redes neuronales aplicadas al control de riego usando instrumentación y análisis de imágenes para un micro invernadero aplicado al cultivo de Albahaca

En México 2 universidades de Coahuila, presentaron un artículo que muestra el desarrollo de un control de riego para un micro-invernadero utilizando redes neuronales artificiales multicapa de retro-propagación. En el invernadero se analizan las plantas y se obtienen datos por medio de sensores, que permiten controlar y automatizar el riego. Mediante la interfaz se pueden observar los datos que monitorea el Sistema: la temperatura ambiente y la humedad relativa en el invernadero; la temperatura y humedad de cada una de las plantas, el tamaño de la planta, así como el porcentaje sano y dañado de cada una de las plantas. El experimento fue realizado durante 44 días, probando las redes neuronales en un rango de humedad de 20 a 21 % y una temperatura estable promedio de 30°C. Con estas condiciones se encontró que las plantas de albahaca (Ocimum basilicum), se desarrollan favorablemente. El error para el control de Riego de la Red Neuronal Artificial (RNA) fue de solo 1.67 % [4].

1.1.5 Redes neuronales para modelar predicción de heladas

En la universidad de Córdova en Argentina diseñaron unas redes neuronales tipo backpropagation, las cuales son capaces de predecir la ocurrencia de heladas a partir de datos meteorológicos de temperatura, humedad relativa, nubosidad, dirección y velocidad del viento, en el sistema agropecuario. Con esto se realiza agricultura sostenible ya que es necesario prevenir problemas y solucionar aquellos que son factibles, tratando de anticiparse a hechos

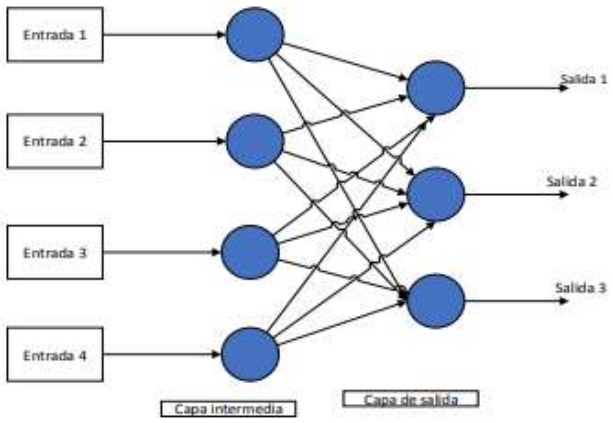


Fig. 1.4: Red neuronal para el control de riego

que indiscutiblemente ocurrirían y que en muchos casos se pueden prevenir [5].

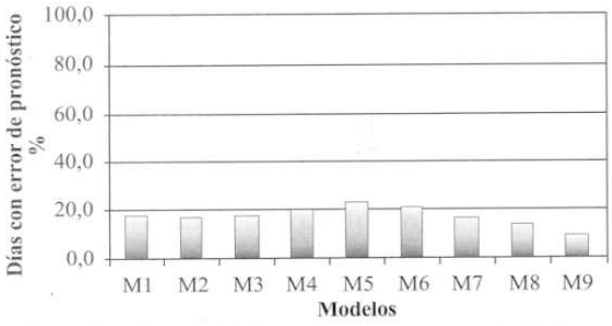


Fig. 1.5: Red neuronal para prevención de heladas

1.1.6 Redes neuronales artificiales aplicadas al cacao, tecnología al servicio del cultivo

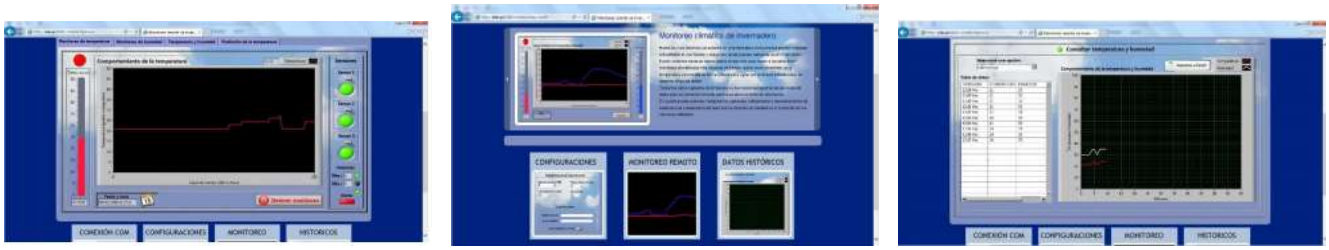
En Venezuela, la Universidad Central de Venezuela (UCV) en las facultades de agronomía y computación y la Universidad Rómulo Gallegos han venido desarrollando trabajos en Inteligencia Artificial, técnicas de RNA y Mapas auto organizados de Kohonen en el área de suelos con fines de caracterización agrológicas [6].



Fig. 1.6: Aplicación de red neuronal para mejorar producción de cultivos

1.1.7 Prototipo basado en redes neuronales para monitoreo y predicción de temperatura en invernaderos de los valles centrales de Oaxaca

El instituto tecnológico de Oaxaca en México, presento un prototipo para la predicción de temperatura en tiempo t + I en función de las condiciones climáticas actuales (t), teniendo como objetivo principal el desarrollar un sistema de monitoreo y predicción de la temperatura construido con tecnología accesible que utilice redes neuronales artificiales y la hipótesis de que es posible predecir el comportamiento de la temperatura a través de redes neuronales utilizando como patrones de entrada información climática de la región de los Valles Centrales del estado de Oaxaca se desarrolló el prototipo formado por 3 módulos: módulo de adquisición de datos compuesto por sensores DHT11 capaces de medir los valores de temperatura (T) y humedad relativa (HR), módulo de procesamiento y predicción de (MPP), formado por una red de tipo perceptrón multicapa totalmente conectada; y la interfaz gráfica de usuario (IGU). Este prototipo es capaz de predecir la temperatura con un porcentaje mayor al 80 % de asertividad en condiciones ambientales normales pudiendo ser implementado para el control de temperatura en invernaderos [7].



(a) Panel principal del sistema de monitoreo de temperatura

(b) Interfaz de monitoreo en tiempo real del sistema

(c) Interfaz de consulta de datos históricos almacenados por el sistema

Fig. 1.7: Módulo de interfaz de usuario

1.1.8 Sistema inteligente para controlar sistemas de riego en México

En México el Tecnológico Nacional de México y el Instituto Tecnológico de San Luis Potosí, están realizando una etapa de culminación y estandarización, ofreciendo la seguridad de cubrir lo que requiere el agricultor y agrónomo en México, trabajando conjuntamente con asociaciones que se encargan del cuidado de la investigación para enfocar los prototipos finales a un producto que se introduzca al mercado lo más rápido posible. A partir de obtener un sistema inteligente que es capaz de registrar las características del tipo de suelo, cultivo y sistema de riego a controlar, al obtener las estadísticas necesarias para que el sistema determine la cantidad de agua que debe soltar el aspersor para apoyar en el ahorro de agua. En una segunda etapa del proyecto, se utilizarán sensores de humedad, temperatura, presión, velocidad del viento. Los cuales se conectarán al sistema de riego de manera inalámbrica para monitorear en tiempo real las condiciones del clima y del cultivo [8].

1.1.9 Diseño e implementación de un sistema de seguimiento de parámetros ambientales en plantaciones de café

En Perú, la Facultad de ingeniería de la universidad de Piura diseñaron e implementaron un sistema de medición y monitoreo remoto basado, principalmente, en la instalación y operación de una estación meteorológica automática, para el seguimiento remoto de las condiciones ambientales bajo las cuales crece una plantación de café. La estación está dotada con los sensores correspondientes, para medir los parámetros del ambiente (Temperatura, Humedad Relativa,



(a) Aplicación de Magros



(b) Módulo de monitoreo de Magros



(c) Módulo de información diaria de Magros



(d) Generación de estadísticas

Fig. 1.8: Imágenes de Magros

Radiación solar y Lluvia), parámetros del suelo (Temperatura y Humedad del suelo a 3 diferentes niveles) y parámetros de la planta como la humedad de la hoja.

El seguimiento remoto de estos parámetros permite conocer las condiciones ambientales bajo las cuales crece la plantación y relacionarlas con su salud y productividad. Esto, a su vez, ayudará a decidir, con mejor criterio, a tomar acciones oportunas para aumentar la producción como regada, poda, fumigación, fertilización entre otras.

La aplicación de este trabajo es en la sierra piurana, zona donde se cultiva Café y cuya producción se ha visto disminuida en los últimos años por enfermedades como la roya amarilla y ojo de gallo [9].



(a) Sensores de radiación



(b) Sensores de humedad



(c) Sensor de la hoja



(d) Panel solar y pluviómetro

Fig. 1.9: Instalación de sensores

1.1.10 Automatización, monitoreo y control remoto de un sistema de riego agrícola con código abierto

Estudiantes de varias Universidades presentaron en Ecuador un prototipo de bajo costo de un sistema de riego agrícola automatizado, monitoreado y controlado remotamente desde cualquier parte del mundo donde exista servicio de telefonía celular. El prototipo utiliza principalmente Arduino, quien se encargará de la automatización del sistema y Android facilitará la interacción con el usuario, mostrándole los datos del sistema, brindándole la opción de poder monitorear y controlar el sistema de riego a través de internet, logrando seguridad y flexibilidad al agricultor [10].

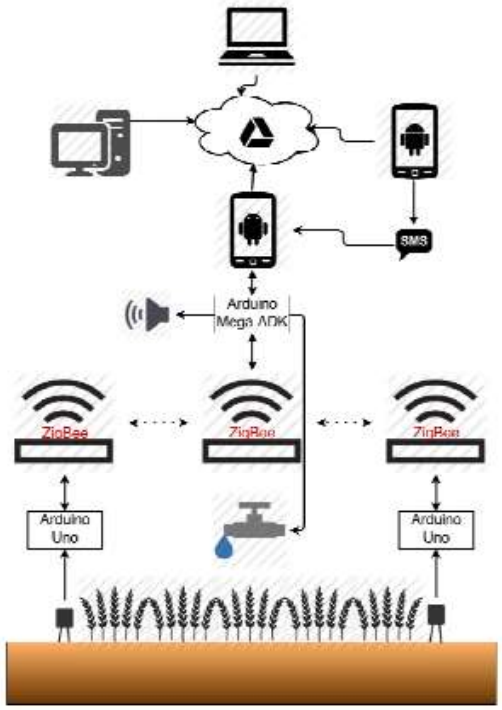


Fig. 1.10: Estructura funcional del sistema

1.1.11 Diseño y construcción de un prototipo de sistema de riego automatizado para la granja experimental Nono de la UDLA

Alumnos de la Universidad de las Américas (UDLA) en Ecuador, diseñaron y construyeron un prototipo automatizado de sistema de riego por goteo y aspersión automáticos en un invernadero de la granja experimental Nono de la UDLA[11]. Dicho sistema permite suministrar remotamente el agua, a través de un dispositivo electrónico de control que admita integrar y gestionar:

- Un servidor web, una base de datos y que sea capaz de recibir y enviar señales, tanto de control como información.
- La interfaz de comunicación entre el usuario y el sistema, será una página web, en la cual se configurará los tiempos de regadío de los cultivos y por medio de un sensor de flujo se medirá la cantidad de agua utilizada por cada vez que haya sido utilizado el sistema.
- La información de los tiempos de encendido, apagado y cantidad de agua utilizados serán

almacenados en una base de datos y presentados en una página web.



(a) Diagrama de funcionamiento



(b) Alertas de configuración



(c) Configuración de tiempo

Fig. 1.11: Prototipo UDLA

1.1.12 Diagrama del prototipo de máquina inteligente de fertiriego de control remoto y bajo costo en la región lambayeque

En Perú, la Facultad de Ingeniería de la Universidad Señor de Sipán en conjunto con la empresa RITEC desarrollaron un prototipo de maquina inteligente de fertiriego de control remoto y bajo costo, que optimiza el proceso de control y monitoreo remoto de inyección de nutrientes y ácidos en un sistema de riego tecnificado, compuesto por un hardware electrónico de bajo costo de fabricación nacional, componentes mecánicos de acción, control y un software virtual que almacena, procesa y transfiere datos e información hacia el dispositivo instalado en un sistema de riego[12].

1.1.13 Selección de cereales mediante drones par ala producción de bioetanol

En España un equipo liderado por el Consejo Superior de Investigaciones (CSIC) propone emplear drones para caracterizar de forma rápida y no destructiva los cereales y seleccionar las variedades más adecuadas para agilizar el proceso de toma de decisiones en la mejora genética de los cereales para la producción de bioetanol [13].

El bioetanol es un combustible que se obtiene a través de la fermentación de los azúcares presentes en la materia orgánica de plantas y vegetales. La caña de azúcar, la remolacha, los

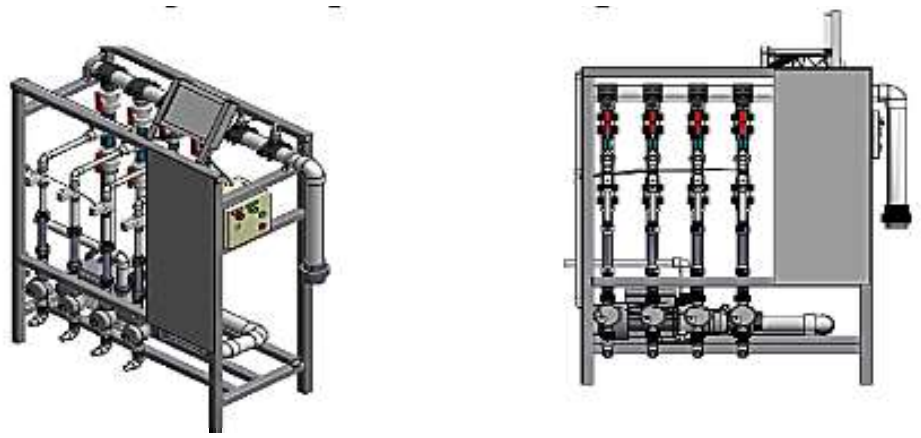


Fig. 1.12: Vista isométrica y frontal de la máquina de fertiriego

cereales y el maíz son algunas de las materias primas utilizadas para su obtención. Hasta ahora la caracterización de dichas variables se realizaba de manera destructiva al cosechar el cultivo y empleando técnicas de laboratorio que requieren de mucho trabajo y tiempo, lo que limita el desarrollo de dichos programas de mejora vegetal", explica el investigador del CSIC José Manuel Peña, del Instituto de Ciencias Agrarias. Mediante el análisis de las imágenes captadas por el dron en varias bandas espectrales, los científicos han elaborado un ranking de las variedades vegetales que poseen una mayor y menor cantidad de biomasa y azúcar liberado durante la fermentación, "variables fundamentales a la hora de producir bioetanol".

Durante los experimentos, un dron tomó imágenes multiespectrales de 66 accesiones de cuatro especies de cereales (trigo harinero, trigo duro, cebada y triticale) durante todo su ciclo de desarrollo. La hipótesis de partida era que dichas imágenes servirían para caracterizar las accesiones usando técnicas avanzadas de análisis de imágenes y la información espectral recogida en forma de índices de vegetación.

Los resultados de los análisis demostraron que los índices de vegetación GNDVI, ExG y NDVI (que varían según el vigor, estado fenológico y desarrollo de la vegetación) presentaron buenas correlaciones con variables fundamentales en la producción de bioetanol, como es el peso total de la biomasa seca, el azúcar liberado y el rendimiento teórico del etanol, respectivamente. Estos resultados les permitieron concluir que esta tecnología es viable para caracterizar las variables estudiadas y predecir una clasificación de las accesiones de cereales más adecuadas para la

producción de bioetanol.



Fig. 1.13: Captura de imágenes multiespectrales con un dron

1.1.14 Aceleración del cultivo de plantas

La empresa Pheno-inspect de la Universidad de Bonn en Alemania está realizando pruebas en fincas de cultivo utilizando drones para la agricultura con el fin de acelerar los cultivos de nuevas variedades con inteligencia artificial[14].

Los cultivadores de nuevas variedades tienen que recopilar datos extensos sobre ¿Cómo de grandes son las espigas de trigo en una nueva variedad? ¿El cultivo sufre de plagas o enfermedades? ¿Cómo hace frente la planta a la sequía?

Pheno-inspect está utilizando drones equipados con cámara para registrar los cultivos, luego el software evalúa automáticamente sus propiedades utilizando métodos de inteligencia artificial. Con esto se busca anticiparse y responder las preguntas rápidamente determinando si la nueva raza es un éxito.



Fig. 1.14: Marcado y detección automática de malezas y plantas cultivadas

1.1.15 Drones en árboles frutales

En Idaho Estados Unidos están haciendo una investigación para para aplicar los drones en la industria de la fruta como uvas, arándano, manzanas y peras asiáticas[15].

Según el estudio las formas más probables en que los drones sean usados para los huertos y viveros son: hacer un inventario de la altura de los árboles y el volumen del dosel; monitorear la salud, la calidad de los árboles y el manejo de agua, nutrientes, plagas y enfermedades en temporada. También será posible la estimación de la producción y rendimiento de frutas y la creación de herramientas de comercialización (vídeos para la promoción del huerto o la venta de árboles y frutas).

1.1.16 Drones en el cultivo de piña

En Costa Rica, el ingeniero industrial Sergio Ballester fundo en 2014 la empresa Indigo Agrícola, la cual analiza cultivos por medio de drones, permitiéndole determinar la situación de las plantas



Fig. 1.15: Dron sobre un huerto de fruta

para tomar decisiones que ayudan a obtener cosechas sanas con el menor impacto ambiental[16]. La empresa trabaja con productores multinacionales de piña y banano de Costa Rica, su país de origen, y ya tiene presencia en Panamá, mediante una alianza con AgDrone PTY, donde labora para productores medianos de banano, café y caña de azúcar.

El servicio de Índigo Agrícola consiste en tomar fotografías aéreas con drones y detectar con el software los cultivos sanos y enfermos, lo que disminuye el tiempo de análisis al recolectar información, automatizar los procesos y aumentar la productividad.

1.1.17 Drones para monitorear maíz

La empresa Nidera Semillas empezara a utilizar un grupo de drones que sobrevolarán los lotes de maíz recabando distintos tipos de información útil para el cultivo, que luego será analizada y compartida con los productores, como parte de la experiencia que la empresa está creando para sus clientes[17].

La iniciativa, que se circunscribe en esta primera etapa al cultivo de maíz, involucra a 40 distribuidores desplegados por distintos puntos del país, desde Charata, en Chaco, hasta Tres Arroyos, en Buenos Aires, pasando por Tucumán, Córdoba, Santa Fe y Entre Ríos.

A partir de ahora, los asesores técnicos de la red visitarán a sus clientes provistos de un dron DJI



Fig. 1.16: Dron aplicado a la piña y al banano en Costa Rica

Matrice 100, un equipo ideal para trabajar en el campo por su autonomía, robustez y resistencia a diferentes condiciones climáticas. Se trata de una plataforma que puede soportar distintos tipos de sensores o cámaras. En principio el proyecto arranca con sensores multiespectrales y sensores visuales RGB, pero en el transcurso de los años se podrían incorporar nuevos dispositivos, como sensores termales o de otras longitudes de onda y resoluciones.
En el campo se realizan dos tipos de vuelos sobre los lotes:

- El primero de reconocimiento, con una cámara que proporciona imágenes cenitales a partir de la cual se detectan fallas en la siembra, zonas con anegamiento, entre otros datos.

- El segundo se trata de un vuelo automático donde el distribuidor configura un plan de vuelo y el dron de forma autónoma sobrevuela la superficie y a partir de sus sensores recopila información que luego será analizada por la compañía norteamericana Precision Hawk, líder en este tipo de servicios. En menos de dos días, el productor recibirá todos los datos procesados en dos reportes: un mapa de ambientación y un mapa de altimetría con los que podrá tomar decisiones y realizar ajustes para lograr una producción más eficiente, optimizar su negocio y obtener mayores rendimientos.



Fig. 1.17: Análisis de información de maíz por medio de un dron

1.1.18 Inteligencia artificial incorporada a maquinaria John Deere

La empresa John Deere de fabricación de equipos para agricultura y de servicios, se está preparando para comercializar este año un rociador para cultivos que funciona con Inteligencia Artificial y utiliza cámaras y machine learning para eliminar las malezas con pesticidas, y los cultivos con fertilizantes.

El machine learning y la visión artificial aplicadas en los mejores equipos agrícolas, está permitiendo tener nuevos conocimientos, mejor toma de decisiones y mejora de la eficiencia. Estos avances van a tener un poder transformador en la agricultura en términos de coste para los productores. La tecnología de la startup interpreta los datos visuales para realizar aplicaciones precisas y medidas de pesticidas químicos planta por planta (en lugar de campo de cultivo por campo de cultivo).

Además de los rociadores de cultivos, Blue River cuenta con drones que utilizan sensores para sobrevolar los campos y recoger datos que sirven para gestionar mejor los cultivos y la producción.

John Deere ha estado construyendo su portfolio de sistemas y servicios tecnológicos desde hace tiempo:

En 1994, creó el Precision Farming Group para incorporar el GPS en tractores semi-autónomos, en colaboración con Standford. Este esfuerzo dio lugar a AutoTrac guidance system, el cual se puso en funcionamiento en 2002 y se utiliza para tareas como el arado y la siembra. El 60-70 % de las superficies de cultivo norteamericanas y el 90 % de las australianas está utilizando AutoTrac o sistemas similares hoy en día, aunque los sistemas más avanzados de John Deere todavía necesitan que vaya un humano en ellos para actuar en el caso de que haya algún problema.

El Intelligent Solutions Group (ISG) de John Deere, ha estado trabajando en servicios de datos y de software. Existen más de 200.000 máquinas de John Deere que trasmiten de forma inalámbrica datos agronómicos a determinados servidores para que realicen un análisis que pueda servir para futuras aplicaciones. Algunos ejemplos de servicios creados a partir de datos son las aplicaciones móviles integradas en la nube, y servicios como MyJohnDeere.com (portal web que da acceso a los agricultores a una serie de datos acerca de sus equipos) o John Deere Operations Center (servicio de análisis que ayuda a los agricultores a la toma de decisiones sobre que plantar utilizando sus datos).

John Deere ha estado utilizando realidad virtual a lo largo de las dos últimas décadas. Lleva sus operaciones relacionadas con esta tecnología en el VR LaB en Dubuque, Iowa, donde los consumidores pueden simular la operación de nuevos diseños de los campos de cultivo en un entorno controlado.

John Deere ha estado creando su red de centros de innovación tecnológica a lo largo de todo el mundo. Algunos de los lugares en los que tiene centros de innovación son India, China, Alemania, Illinois y Brasil[18].

Los esfuerzos que ha realizado en el pasado John Deere en lo referente a datos, analítica, cloud computing, geolocalización, IoT, vehículos autónomos y robótica están facilitando sus esfuerzos en Inteligencia Artificial y agricultura de precisión[19].

1.1.19 Microsoft y la inteligencia artificial en la agricultura

Los equipos de Internet de las cosas (IoT) instalados en el terreno y el análisis de los datos en la nube, en este caso de Microsoft Azure, ofrecen información acerca del momento óptimo para



Fig. 1.18: Tractor autónomo de la empresa John Deere

sembrar, regar, fertilizar o cosechar los cultivos, de manera que los agricultores puedan obtener una mayor trazabilidad de la producción de sus explotaciones.

Ibercaja, con la colaboración de Microsoft Azure, ha sido la encargada de poner en marcha este proyecto para apoyar a los agricultores en el crecimiento de sus explotaciones mediante el desarrollo de una agricultura inteligente. De esta manera se aporta una mayor eficiencia a las explotaciones, gracias a que la propia tecnología es más sostenible.

Con la inteligencia artificial se proporciona a los productores una mayor trazabilidad de su explotación, ya que les permite conocer el momento óptimo para sembrar, regar, fertilizar o cosechar. La información acerca del estado de los cultivos se obtiene en tiempo real para analizar la evolución de indicadores como temperatura ambiental y del suelo, humedad del suelo, presión atmosférica, vigor de la planta, precipitaciones registradas en el terreno o velocidad del viento. Así se facilita la toma de decisiones en cada uno de los momentos del ciclo productivo.

El sistema permite manejar también de forma remota y a distancia todas las variables, lo que proporciona a los agricultores una mayor eficiencia en sus explotaciones y un mayor desarrollo de su negocio que puede contribuir a mejorar el tejido productivo en el territorio.

El proyecto se ha puesto en funcionamiento en varias explotaciones agrícolas de Aragón, y se irá ampliando próximamente a otras regiones de España. Para poner en marcha esta innovadora

iniciativa, Ibercaja y Microsoft Azure han contado con la colaboración de agricultores así como de empresas punteras en tecnologías de inteligencia artificial de la Comunidad aragonesa como EFOR Internet y Tecnología y Libelium, incorporando los servicios IA de Microsoft en su estrategia IoT[20].



Fig. 1.19: Microsoft Azure apuesta por una agricultura inteligente

1.1.20 Agricultura inteligente utilizando red 5G

Intel colabora con socios de todo el mundo para implementar la tecnología 5G que respaldará una nueva era de la agricultura inteligente basada en el 5G. Dado que la demanda de alimentos va a aumentar considerablemente en las próximas décadas, la agricultura de precisión será esencial para sacar el máximo partido de cada hectárea de terreno.

La llegada del 5G dará un gran impulso a la agricultura inteligente gracias a sus enormes capacidades de datos, altas velocidades y baja latencia. Las redes 5G no solo conectarán las zonas rurales, sino que también ayudarán a soportar la conectividad de sensores de IoT necesaria para lograr innovaciones pioneras en equipos agrícolas inteligentes. El 5G y la informática de vanguardia permitirán la transferencia rápida de datos a la nube, de forma que los análisis en tiempo real y la comunicación de máquina a máquina puedan agilizar y automatizar el proceso

agrícola.

Esta agricultura inteligente basada en el 5G adoptará diversas formas, como tractores autónomos y sistemas de regadío inteligentes. Además, ofrecerá asistencia adicional para tecnologías como la IA que ayudan al sector agrícola a transformarse para la era digital. Junto con la automatización de los equipos agrícolas, el sector agrícola también utiliza la IA para distintos fines como, por ejemplo, la identificación de enfermedades de las plantas, la detección de plagas y la predicción del rendimiento de los cultivos.

El 5G también puede ayudar a los agricultores a controlar las cosechas y el ganado. Por ejemplo, los sistemas de monitorización inteligentes pueden ser de utilidad para evitar la degradación del suelo, mientras que las plataformas de monitorización del rendimiento pueden realizar un seguimiento de las cantidades totales de la cosecha. Además, se puede supervisar el estado del ganado con datos biomédicos y de GPS. En un ensayo clínico, se ha utilizado tecnología de reconocimiento facial para detectar cambios en el estado emocional de los cerdos, lo que podría ayudar a los agricultores a detectar problemas de salud y bienestar.

En otro proyecto, el reconocimiento facial basado en IA se ha utilizado para identificar vacas de manera individual, de modo que los agricultores puedan controlar sus movimientos y cualquier cambio en el comportamiento que pueda indicar enfermedades.

Desde el punto de vista de la gestión, el 5G supondrá un apoyo para el uso de plataformas que ayuden a los agricultores a analizar la producción, los riesgos y las finanzas. Los invernaderos inteligentes pueden ajustarse en función de las condiciones climáticas y utilizarse para gestionar las cosechas, mientras que los drones agrícolas facilitarán la obtención de información de campo sobre un área extensa, lo que permitirá detectar posibles problemas antes de que tengan un impacto grave[21].

1.1.21 E-kakashi. Un cerebro de inteligencia artificial en la agricultura

El Banco Interamericano de Desarrollo, a través de su laboratorio de innovación BID-Lab, aprobó un financiamiento de US$2 millones para un proyecto que buscará mejorar la productividad y la sostenibilidad del cultivo de arroz en Colombia[22].



(a) Drones agrícolas con 5G



(b) Reconocimiento facial en cerdos con 5G

Fig. 1.20: Agricultura inteligente y red 5G

El proyecto, que será liderado por el Centro Internacional de Agricultura Tropical (CIAT), implementará una nueva solución tecnológica llamada "e-kakashi", un servicio que combina Internet de las cosas (IoT), big data, inteligencia artificial (AI) y un sistema ciberfísico (CPS) para transformar la agricultura en una ciencia basada en datos en tiempo real. En resumen, e-kakashi es un cerebro de AI en la agricultura desarrollado por SoftBank Corp (SoftBank) que recopila gran cantidad de datos ambientales de los cultivos y el medio ambiente, procesa

y analiza estos datos, en combinación con conocimientos y prácticas agronómicas, para que los productores puedan manejar el proceso de cultivo y crear un ambiente óptimo para la producción de arroz.

La región de América Latina y el Caribe tiene el potencial de convertirse en una potencia mundial en la producción de alimentos y otros productos agrícolas siempre y cuando se movilicen acertadamente los recursos disponibles. Para que ese potencial se transforme en una realidad, es necesario adoptar medidas que aumenten la productividad con conciencia ambiental. La obtención de mayores rendimientos, en la zona productiva existente, por medio de prácticas agrícolas sostenibles deberá ir de la mano de nuevas tecnologías e innovaciones que permitan a los productores y otros agentes maximizar el uso eficiente de los recursos a lo largo de la cadena de valor.

E-kakashi ya ha sido probado en Colombia por el CIAT en un piloto de arrozales inundados ubicados dentro de las instalaciones del CIAT en Cali. Este programa piloto se llevó a cabo en el marco de un programa del gobierno japonés denominado SATREPS, Alianza de Investigación en Ciencia y Tecnología para el Desarrollo Sostenible. El proyecto del BID-Lab, será la primera prueba de e-kakashi con el objetivo de una implementación y expansión a nivel comercial fuera de Japón. Inicialmente, el proyecto ayudará a los pequeños productores de arroz (con un promedio de 5,9 hectáreas cada uno) en los departamentos de Cauca y Valle del Cauca. Posteriormente, se buscará ampliar su cobertura a los departamentos de Arauca y Casanare.

Además, e-kakashi contribuye a resolver problemas ambientales como los suministros de agua inestables y la emisión de gases de efecto invernadero (GEI). Los arrozales inundados emiten hasta 500 millones de toneladas de metano a nivel mundial, lo cual equivale a alrededor del 20 por ciento del total de las emisiones de este gas producidas por el hombre. El suelo cálido y encharcado de los arrozales proporciona las condiciones ideales para producir metano. Softbank ha estado desarrollando la solución e-kakashi para rastrear y calcular los niveles óptimos de agua en cada fase del crecimiento de las plantas, no solo para aumentar la productividad agrícola sino también para reducir las emisiones de metano.

El proyecto tendrá dos fases:

- Demostrar la eficacia de la solución propuesta en los arrozales en condiciones reales en colaboración con el CIAT, SoftBank, productores locales de arroz y compañías locales de molienda de arroz.
- Ampliar la solución entre los pequeños agricultores (de arroz y otros productos agrícolas) en otras ubicaciones geográficas dentro y fuera de Colombia.

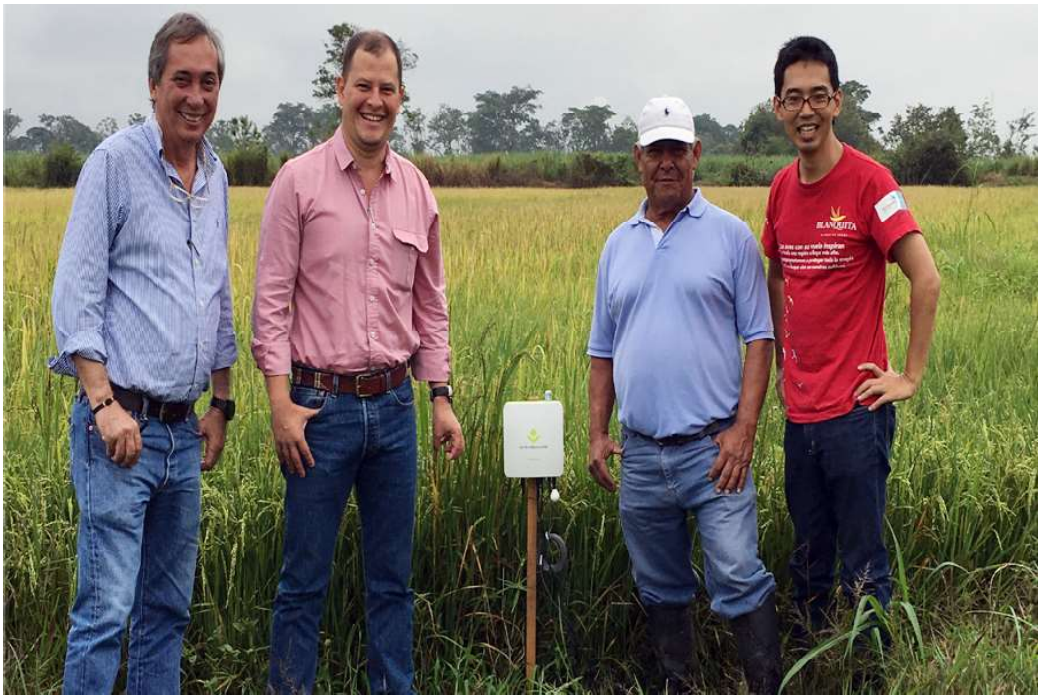


Fig. 1.21: E-kakashi

1.1.22 Detección en tiempo real de malezas a través de técnicas de visión artificial y su incorporación en sistemas de aplicación selectiva de herbicidas

La Universidad Tecnológica Nacional Facultad Regional Villa María (UTN FRVM) están investigando y desarrollando un prototipo de detección de las malezas que aparecen durante el procedimiento denominado barbecho en los cultivos agrícolas típicos de nuestra región, en particular soja, maíz y trigo. Adicionalmente, se analizarán las posibilidades de optimización económica y ambiental, que su incorporación en la maquinaria, conllevan[23].

El aporte de este proyecto, se centra en estudiar las distintas alternativas tecnológicas disponibles, a partir de los trabajos que existen en la materia y teniendo en cuenta las

características propias de las malezas de nuestra región, para desarrollar un sistema de visión artificial que permita la detección de malezas en tiempo real, y que sea susceptible de incorporar en un equipo pulverizador de herbicidas. En este último aspecto, la participación de especialistas en maquinaria agrícola, permitirá desarrollar estrategias de montaje del sistema, en el conjunto del equipo, para implementar dosificación variable y aplicación selectiva de herbicidas.

Abarcamos dentro del concepto de sistema de visión artificial, a la detección que se realiza a través del procesamiento de imágenes provenientes de cámaras de video de alta definición con sus sistemas ópticos asociados.

En este proyecto se pretende también analizar comparativamente, los resultados experimentales del prototipo propuesto, con los de los sistemas de detección más utilizados actualmente, que utilizan como método de sensado, la medición de la cantidad de luz de determinada longitud de onda, reflejada por las malezas a través del tratamiento y acondicionamiento de señales optoelectrónicas provenientes de foto detectores de diferentes rangos del espectro lumínico.

Este proyecto interfacultades integra a investigadores de las carreras de Ing. Electrónica, Ing. Mecánica y Licenciatura en Administración Rural de la FR Villa María, con los mismos de las especialidades de Ing. Electrónica, Ing. Electromecánica y Licenciatura en Administración Rural de la FR San Francisco.

La detección de malezas puede hacerse en tiempo real, es decir, a través de un sensor que informe de la presencia de las plantas no deseadas e inmediatamente la actuación sobre el sistema de pulverización para que produzca el rociado con herbicida.

1.1.23 Plataforma para gestionar cultivo de aguacate

En Valencia, existe una comunidad que tiene 43 hectáreas de aguacate que ha apostado por trabajar con este tipo de cultivo habitual en el clima tropical, gracias a una plataforma llamada Visual, que tiene como objetivo cargar información más rápido y gestionar todos los trabajos de campo[24].

Actualmente, están implementando sensores en campo vinculados a Visual, lo que permite adecuar realmente la cantidad de agua a las necesidades de cada cultivo, es decir, desarrollar

una agricultura de precisión, aportando a la planta lo que de verdad necesita, así como conocer el estado de las diferentes zonas de plantación.

Asimismo, la utilización de drones les ha servido para dibujar las parcelas y han marcado exactamente las distancias entre plantas, con la posición exacta donde debe ir cada planta.

El cultivo de aguacates necesita polinizadores, los cuales han repartido en campo y posteriormente con la información de los vuelos de drones, han logrado situarlos en la ubicación precisa para lograr esa polinización de la variedad comercial.

Además, todos los datos que facilitan los drones también los han volcado en Visual, pudiendo tener una información muy real de lo que se tiene en campo.



Fig. 1.22: Plataforma visual aplicada en plantes de aguacate

1.1.24 Máquina clasificadora de frutas y vegetales

Un fabricante de equipos, Tomra, aborda el desperdicio de alimentos al incrementar la eficiencia de la clasificación. Durante un largo tiempo, los proveedores de frutas y vegetales frescos han suministrado frutas y vegetales frescos de calidad a las empresas minoristas y servicios de alimentos en función de la demanda del consumidor de frutas y vegetales visualmente atractivos. Sin embargo, a medida que los consumidores se vuelven cada vez más conscientes de la cantidad de alimentos comestibles que se desperdician simplemente debido a que no son visualmente atractivos, muchos han reconocido el papel que sus alimentos juegan en este asunto y están cambiando las reglas del juego. Para ayudar a que las empresas vendan la mayoría de sus frutas y vegetales frescos y reduzcan los desperdicios, Tomra ha diseñado una máquina clasificadora que utiliza una variedad de sensores para analizar las estructuras molecular y superficial de un producto, así como su composición elemental para "ver los alimentos de la misma forma que lo hacen los consumidores". Esta capacidad es especialmente importante a nivel del producto crudo donde los envasadores y los procesadores pueden canalizar el producto que se procesará, al mercado de productos frescos, a jugos, alimento animal, etc. en función de su calidad[25].

1.1.25 Inteligencia artificial en la producción de frutas y vegetales

En una granja del norte de Nueva Jersey de nombre Bowery, un sistema de tecnología patentada de nombre FarmOS utiliza el aprendizaje y la visión de la máquina para comprender y responder a todas las variables que participan en la forma en que sus vegetales se producen. Los sensores instalados en toda la granja rastrean los niveles óptimos de luz y nutrientes para cada variedad de frutas y vegetales, los cuales se ajustan para afectar aspectos como el sabor. El sistema también detecta cuándo las plantas están listas para la cosecha al monitorear el crecimiento 24 horas al día y enviar estos datos de regreso al sistema operativo para determinar el punto óptimo para la cosecha. Cada vez que una planta alcanza el "momento óptimo para la cosecha", el sistema registra lo que ha aprendido acerca de la luz y los nutrientes óptimos para utilizarlos en la siguiente ronda de cultivos[25].

1.2 Enunciado del Problema

La roya es un conjunto de enfermedades causadas por hongos de las plantas que merman la producción de trigo a nivel mundial ocasionando pérdidas económicas y de desabasto. La roya del trigo se presenta en tres tipos: roya amarilla, roya del tallo y roya de la hoja.

La actual propagación de la roya del trigo está obligando a una mayor colaboración internacional para estudiar, detectar y prevenir esta amenaza que posee una gran movilidad, propagándose rápidamente a grandes distancias por el viento, y que puede causar estragos en los cultivos si no se aborda adecuadamente cuando se detecta por primera vez, ocasionando pérdidas en el rendimiento de un campesino de hasta 80 % en condiciones favorables para la esparsión de la misma [26].

La roya se presenta básicamente en tres tipos: roya amarilla, roya del tallo y roya de la hoja, esta última es la principal variadad de la enfermedad que afecta a los cultivos en el sur de Sonora [27].

Es por lo anterior que en este trabajo de investigación, se pretende aportar una nueva metodología y ayudar en la detección temprana de la roya de la hoja en el valle del Yaqui, utilizando lógica difusa, una red neuronal tipo adaline y un drón.

1.3 Justificación

Sonora es el principal productor de grano de trigo en el país con un porcentaje en el 2018 de 51.7 % de la producción total nacional [28]. Por este motivo es muy importante para el estado, para los productores y para el valle del Yaqui, el seguir manteniendo y/o mejorando su rendimiento, el cual es amenazado año tras año con la roya de la hoja. Basta con observar la figura 1.23, para darse cuenta de la magnitud de la extensión de la enfermedad en el Valle del Yaqui, en la misma podemos observar en rojo los lotes que presentaron positivo a roya de la hoja y en amarillo a roya lineal. Cabe mencionar que también resulta ser algo muy importante, el poder contribuir como país en las investigaciones que hacen otros países productores de trigo, con nuevas estrategias de detección de roya.

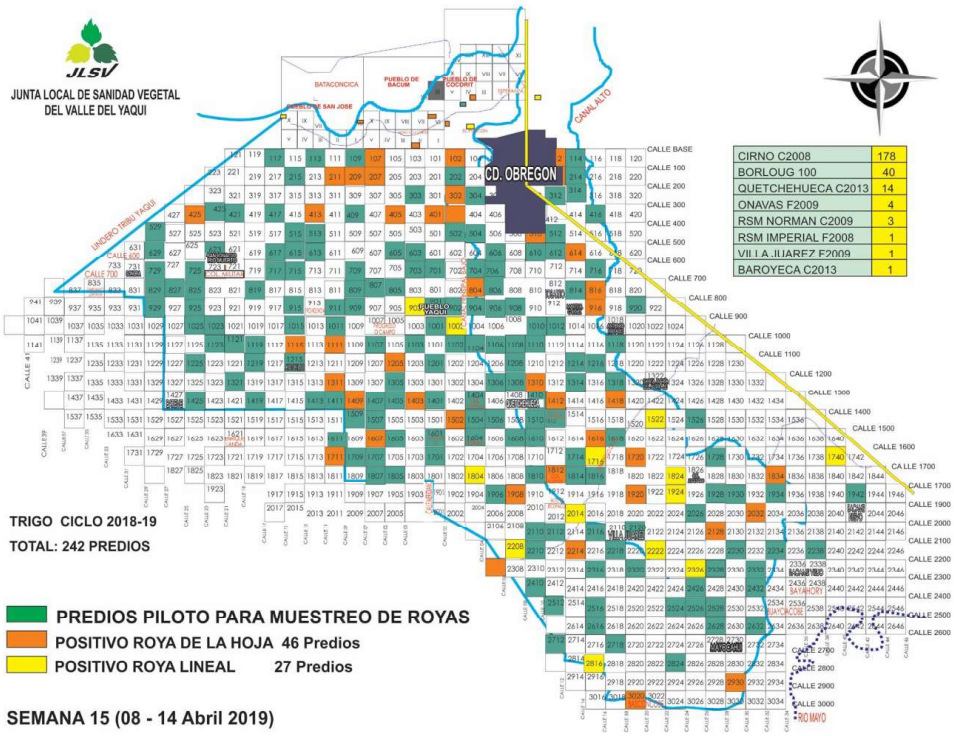


Fig. 1.23: Número de predios o tierras infectados por roya de la hoja en el valle del Yaqui.

1.4 Objetivos

- Promover la agricultura de precisión en el valle del Yaqui.
- Promover el uso de drones para actividades agrícolas en la región.
- Promover sistemas de control inteligente en la región.

1.4.1 Objetivo general

Detectar la presencia de la roya de la hoja en un cultivo de trigo en el Valle del Yaqui, diseñando un sistema de control inteligente mediante la detección de patrones a partir de las imágenes capturadas por un drón.

1.4.2 Objetivos específicos

- Establecer una estrategia de coordinación con la JLSV para ubicar el lugar donde se realizará esta investigación.
- Diseñar e implementar un programa que detecte la roya de la hoja utilizando una red neuronal tipo adaline.
- Realizar pruebas utilizando una cámara profesional en un predio de Navojoa.
- Realizar pruebas utilizando un dron en un predio de Navojoa.
- Desarrollar los resultados obtenidos.
- Análisis de resultados obtenidos.
- Conclusión del trabajo.

1.5 Alcances y limitaciones

1.5.1 Alcances

Este trabajo tiene por alcance detectar la roya de la hoja en cualquier cultivo de trigo que este en el Valle del Yaqui, en primera instancia por una cámara digital y en segunda instancia por un drón. Además, los resultados no serán en tiempo real, que es lo más conveniente para los productores.

1.5.2 Limitaciones

Este trabajo está limitado a las parcelas donde exista un brote de roya en el valle del yaqui y a la cobertura de señal que pueda recibir el drón para poder lograr que este sobrevuele el predio y realice las fotografías necesarias.

2. MARCO TEÓRICO

2.1 Origen del trigo y su importancia mundial

El trigo ha estado en movimiento desde el inicio de su cultivo en el Oriente Medio y cuando empezó a diseminarse paso a paso alrededor del mundo.

Con la adopción del pan como alimento básico y símbolo de estatus social, y el incremento de la población debido a la revolución industrial, se vigorizó su intercambio dando origen al moderno comercio internacional del trigo a mediados del siglo XIX.

Para el ciclo 2014-2015 el trigo se convierte en el grano más comercializado del mundo con un total de 2,962 millones de toneladas y el segundo cereal en importancia debido a su producción. Los 27 países de la Unión Europea tienen la mayor producción, seguidos de China, las 12 repúblicas que formaron la Unión Soviética, India y Estados Unidos, ver figura 2.1 [29].

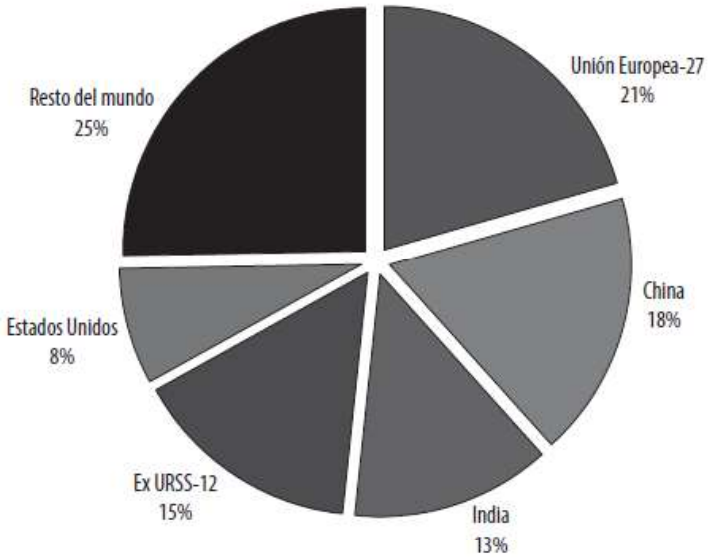
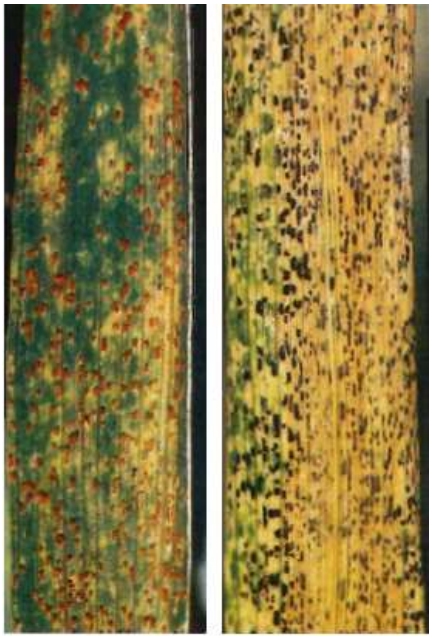


Fig. 2.1: Principales productores mundiales de trigo del ciclo 2014-2015.

2.2 Enfermedades del trigo

2.2.1 Royas del trigo

Las royas causan daños debido a la reducción del área fotosintética y del desarrollo de las raíces, lo que finalmente afecta el rendimiento y la calidad del grano, ver figura 2.2.



(a) Roya de la hoja



(b) Roya del tallo



(c) Roya lineal

Fig. 2.2: Infección en el trigo a causa de las royas.

Las plantas infectadas, normalmente, producen un menor número de espiguillas y forman una menor cantidad de granos por espiga. A su vez, los granos son de menor tamaño, generalmente chuzos, de baja calidad industrial y de menor valor alimentario.
De manera general, los agentes causales de estas enfermedades desvían los compuestos orgánicos sintetizados, convirtiéndolos en esporas que son producidas en grandes cantidades. El flujo de carbohidratos a través del floema destinado al llenado de granos, es reducido considerablemente.
La magnitud de las pérdidas de rendimiento generadas por las royas dependerá del grado de resistencia a la enfermedad de las variedades de trigo sembradas, y de cuán temprano en el ciclo de cultivo se desarrollen las epidemias.
En general, las pérdidas de rendimiento son mayores en las variedades susceptibles y con infección temprana [30].

2.3 Agricultura de precisión

A fines de la década de los 80´s y comienzo de los 90´s, se pensó en combinar diversas tecnologías para obtener información que permitieron el manejo localizado de las prácticas agrícolas, con una mayor eficiencia de aplicación de insumos, reduciendo el impacto con el medio ambiente y disminuyendo los costos de la producción de alimentos. A ese conjunto de procesos y sistemas aplicados se les denomina Agricultura de Precisión [31].

¿Cómo se define la agricultura de precisión?

García y Flego, la definen como "la aplicación correcta de insumos, en el momento adecuado y en el lugar exacto" [32].

¿Qué es la variabilidad espacial?

Es aquella diferencia de producción en un mismo campo, en un mismo ciclo y en la cosecha [31].

¿Qué es la variabilidad temporal?

Es la que expresa los cambios de producción en un mismo campo, para distintos ciclos de cosecha [31].

La agricultura de precisión se basa en el manejo especifico de un área de cultivo. Para ello se utilizan herramientas tecnológicas como el GPS (sistema de posicionamiento global), dispositivos de distribución de riego, fertilizantes y plaguicidas variables, sensores climatológicos de cultivo y, últimamente, los drones [33].

2.4 Drones

Los drones que hoy conocemos comenzaron a desarrollarse en el siglo XX, y fueron utilizados originalmente para prácticas de tiro en el entrenamiento personal de militares. Su desarrollo avanzo durante la Primera Guerra Mundial, cuando la empresa Dayton-Wright Airplane desarrollo un torpedo aéreo sin piloto capaz de caer y explotar en un tiempo establecido.

¿Qué es un drón?

Un drón es una aeronave que vuela sin tripulación, capaz de mantener un nivel de vuelo controlado y sostenido, que es propulsado por uno o más motores eléctricos, de explosión o reacción.
Los avances tecnológicos han permitido desarrollar drones con distintas formas, tamaños, configuraciones y características. Originalmente los drones eran aviones tradicionales en los que se reemplazaba al ser humano por una serie de ordenadores, conectados a varios sensores y actuadores, que realizaban las tareas de los pilotos vía control remoto [34]. Con el tiempo los avances tecnológicos han permitido desarrollar drones que pueden controlarse fácilmente desde un teléfono inteligente y porque son capaces de portar cámaras, sensores y actuadores eléctricos, razón por la que su uso se ha ido extendiendo en[35]:

- **Cartografía**: Utilizando sus cámaras precisas y diferentes tipos de sensores son capaces de hacer mapeos muy detallados en poco tiempo y a bajo costo.
- **Logística**: Como naves de transporte de carga.

- **Protección civil**: Utilizados en la inspección de un puente o los cables de alta tensión, en la evaluación de daños en huracanes o inundaciones.
- **Investigación y desarrollo**: Usados en la agricultura de precisión para ver los cultivos y fumigarlos.
- **Seguridad**: Diseñados para realizar vuelos de vigilancia en fronteras y/o revisar accidentes en carreteras.
- **Ocio**: Utilizados como pasatiempo al integrar cámara de video, así como para enseñar a los niños o para filmaciones de películas.

2.5 Redes neuronales artificiales

Las redes neuronales artificiales se definen como sistemas de mapeos no lineales cuya estructura se basa en principios observados en los sistemas nerviosos de humanos y animales. Constan de un gran número de procesadores simples ligados por conexiones con pesos. Las unidades de procesamiento se denominan neuronas. Cada unidad recibe entradas de otros nodos y genera una salida simple escalar que depende de la información local disponible, guardada internamente o que llega a través de las conexiones con pesos. Pueden realizarse muchas funciones complejas dependiendo de las conexiones.
Las neuronas artificiales simples fueron introducidas por McCulloch y Pitts en 1943. Una red neuronal se caracteriza por los siguientes elementos:

- Un conjunto de unidades de procesamiento o neuronas.
- Un estado de activación para cada unidad, equivalente a la salida de la unidad. Conexiones entre las unidades, generalmente definidas por un peso que determina el efecto de una señal de entrada en la unidad.
- Una regla de propagación, que determina la entrada efectiva de una unidad a partir de las entradas externas.

- Una función de activación que actualiza el nuevo nivel de activación basándose en la entrada efectiva y la activación anterior.
- Una entrada externa que corresponde a un término determinado como bias para cada unidad.
- Un método para reunir la información, correspondiente a la regla del aprendizaje
- Un ambiente en el que el sistema va a operar, con señales de entrada e incluso señales de error.

2.5.1 Adaline

La red adaline, es un tipo de red neuronal que tiene una topología similar a la del perceptrón, excepto porque emplea una función de activación lineal, usando para su entrenamiento un método de mínimos cuadrados (LMS). Entre sus aplicaciones se encuentran:

- Procesamiento de señales.
- Canceladores de ECO, en telefonía.
- Sistemas de predicción.

Un esquema de predicción básico es el siguiente, en el cual se presenta un entrenamiento con datos del sistema tanto de la entrada como de la salida. Después de realizado el entrenamiento se elimina la entrada de datos de la salida del sistema.
Las redes adaline son estructuras de una capa con una función de escalón como no linealidad. Adicionalmente, las entradas pueden ser de forma continua, mientras que en el perceptrón son binarias de 61. Los pesos son ajustados mediante la regla de Widrow Hoff para minimizar la diferencia entre la salida y el objetivo. Este algoritmo es una implementación iterativa de la regresión lineal, reduciendo el error cuadrado de un ajuste lineal [36].
Una ilustración simple del sistema de entrenamiento de la red adaline se muestra en la figura 2.3.

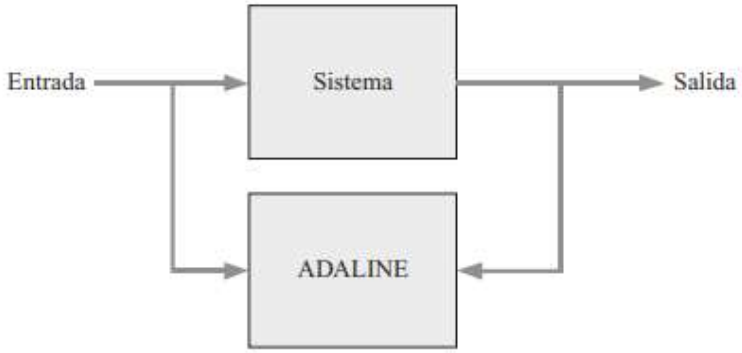


Fig. 2.3: Sistema de entrenamiento para una red adaline [36].

2.6 Lógica difusa

La lógica difusa es una rama de la IA que le permite a una computadora analizar información del mundo real en una escala entre lo falso y verdadero.

Los matemáticos dedicados a la lógica en la década de 1920 definieron un concepto clave: todo es cuestión de grado. La lógica difusa manipula conceptos vagos como "caliente" o "húmedo" y permite a los ingenieros construir televisores, acondicionadores de aire, lavadores y otros dispositivos que juzgan información difícil de definir.

Los sistemas difusos son una alternativa a las nociones de pertenencia y lógica que se iniciaron en la Grecia antigua. El lenguaje natural maneja conceptos no precisos como "hace frío" o "el precio es alto". Cuando se traduce el lenguaje humano al contexto de la lógica clásica se pierde la riqueza del significado, pérdida que puede ser importante si estamos diseñando un sistema experto.

Suponiendo que se diseña un sistema experto en reproducir la capacidad de diagnóstico de un médico, el ingeniero sabe que el médico se basa en medidas exactas, pero el diagnóstico y la receta de las medicinas están llenos de razonamiento difuso. Cuando los matemáticos carecen de algoritmos que dictan cómo un sistema debe responder a ciertas entradas, la lógica difusa puede controlar o describir el sistema usando reglas de sentido común que se refieren a cantidades indefinidas.

Los sistemas difusos frecuentemente tienen reglas tomadas de expertos, pero cuando no hay

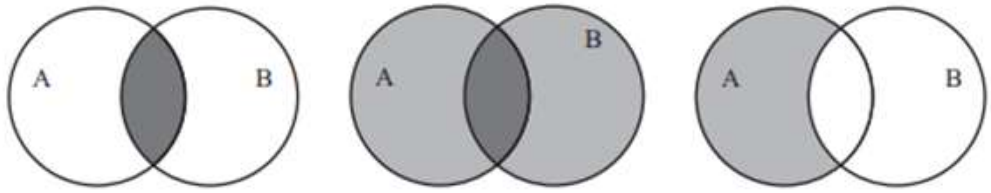
experto los sistemas difusos adaptativos aprenden las reglas observando cómo la gente manipula sistemas reales.

Tener un rango de "mucho", "poco" abre una gama de posibilidades de la fuerza con que puede ser golpeado el objeto. Los términos "mucho" y "poco" no se encasillan en una sola cantidad, aspecto que algunos sistemas en la vida cotidiana sí lo realizan.

Los interruptores de la luz son un claro ejemplo ya que sólo funcionan de dos maneras: apagado o encendido, lo que se traduciría en la lógica booleana en 1 o 0. En la figura 2.4 se muestra las operaciones básicas de la lógica booleana.

En la lógica difusa no se puede tomar valores únicos para saber si un elemento pertenece o no. Se debe tomar valores entre el 0-1, por ello las opciones de respuesta son mayores y a veces infinitas si no se acota adecuadamente el sistema o fenómeno en estudio.

La figura 2.5 ejemplifica mejor la diferencia entre ambas propuestas; también se aprecia el abanico de posibilidades que maneja la lógica difusa. Del mismo modo se puede plantear una situación similar para distintas áreas de conocimiento, ciencia o tecnología.



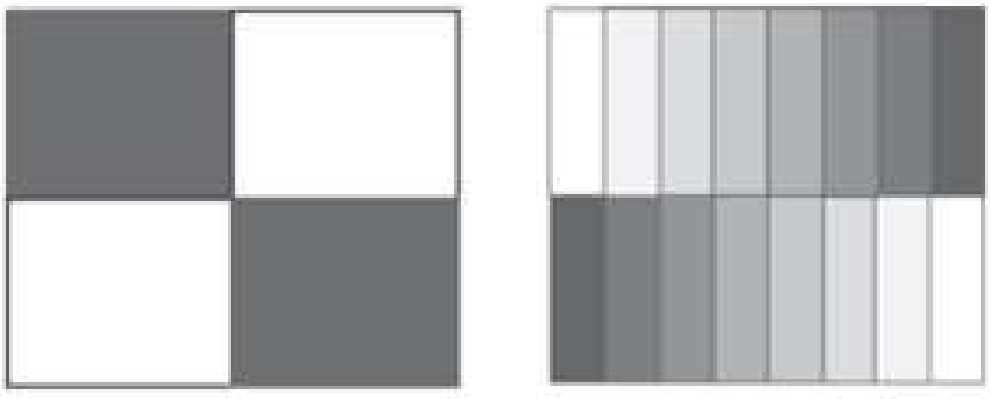
(a) AND es una intersección (b) OR es una unión (c) NOT es complemento

Fig. 2.4: Diagramas de Venn.

La lógica difusa consta de tres etapas para obtener el resultado deseado. La primera etapa se basa en un proceso donde las variables tienen un grado de incertidumbre metalingüístico. Por lo tanto, el rango de valores (universo de discurso) de cada variable puede clasificarse por conjuntos difusos, por ejemplo, baja, media, alta.

Cuando los sensores miden las variables, los valores pasan a un proceso de fusificación que consiste en pasar dichos valores a un rango de pertenencia entre cero (0) y uno (1). Se busca determinar en qué grado el valor que se está adquiriendo pertenece a un conjunto difuso.

Los conjuntos difusos son caracterizados mediante funciones de membresía, las cuales están



(a) Lógica booleana (b) Lógica difusa

Fig. 2.5: Diferencia entre lógica booleana y difusa.

sintonizadas al punto de operación adecuado para el funcionamiento del sistema. En la segunda etapa se proponen reglas lingüísticas (inferencia) que servirán de guía para que el sistema se comporte de manera más adecuada, idónea o deseada según el modelo de referencia o los objetivos del usuario. El grado de pertenencia de cada una de las variables se evalúa en un conjunto de reglas de inferencia.

Dichas reglas de inferencia fueron determinadas con ayuda de un experto. El conjunto de reglas de inferencia determina una consecuencia, es decir, asigna un grado de pertenencia a un conjunto difuso que caracteriza a las salidas.

Una vez obtenidas las consecuencias, la tercera etapa es un proceso para determinar los valores óptimos de salida, conocido como desfusificación, y que consiste en pasar el grado de pertenencia, proveniente de la consecuencia de la regla de inferencia, a un valor nítido o real. Para hacer eso, previamente se sintonizaron funciones de membresía de cada una de las salidas con el fin de obtener un valor cuantificable.

La figura 2.6 muestra el diagrama esquemático del controlador difuso. Al final el control entregará valores nítidos o reales, consecuencia de las reglas lingüísticas previamente estructuradas, con lo cual este sistema interpretará las órdenes y realizará las acciones pertinentes.

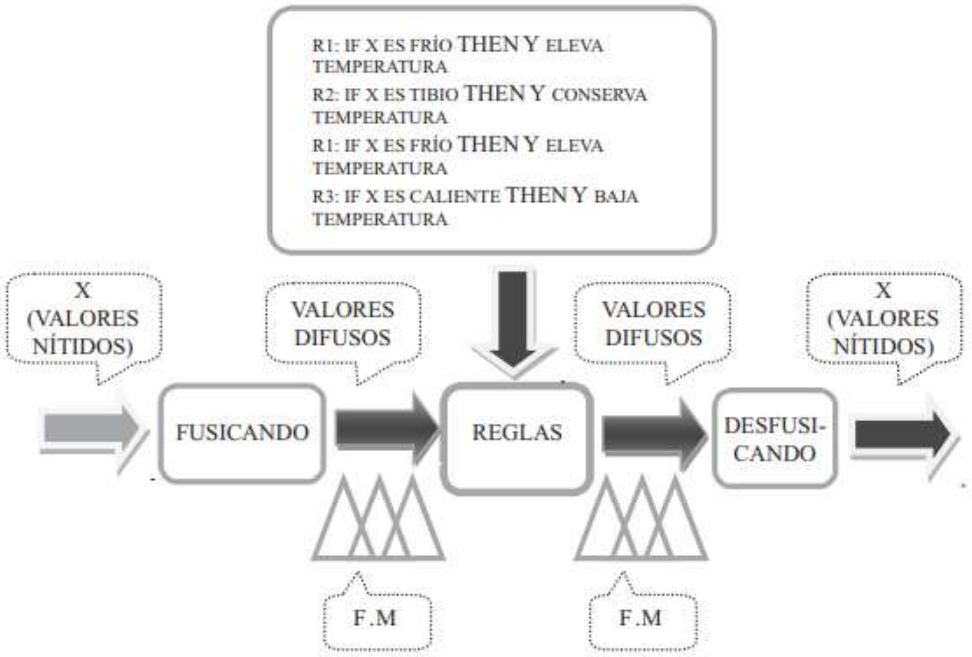


Fig. 2.6: Diagrama esquemático del controlador difuso[36].

2.7 Sistema de captura de imágenes

2.7.1 Imagen

Una imagen es una función bidimensional que proporciona cierta información electromagnética para cada uno de sus valores. A cada uno de estos elementos discretos se les denomina pixel o punto y generalmente contienen el nivel de iluminación o el color de un punto en la escena. El conjunto de puntos o pixeles forman la imagen o fotografía de la escena [37].

El proceso de captura de imágenes básicamente consiste en generar una señal electromagnética en forma de luz que se transmite, refracta y refleja en la escena hasta que alcanza el área del sensor de la cámara, el cual convierte la señal electromagnética en señal eléctrica y a partir de ese momento se dispone de un conjunto de elementos electrónicos que digitalizan, formatean, transmiten y almacenan las imágenes digitales [37].

2.7.2 Iluminación

Un sistema de iluminación bien diseñado proporciona luz a la escena de forma que la imagen que se obtiene favorezca el posterior proceso de la misma.

Tipos de iluminación artificial

- Incandescente/Halógena
- Fluorescentes
- Led
- Láser
- Fibra óptica

2.7.3 Filtros

Son dispositivos fabricados con un determinado tipo de material en el que se producen los efectos de absorción y transmisión de las longitudes de onda espectrales.

2.7.4 Difusores

Son los que reflejan la luz en una determinada dirección, en una gran variedad de direcciones diferentes.

2.7.5 Sistema óptico

Es el que está formado por lentes que modifican la dirección de los fotones cuando la luz atraviesa los mismos.

2.7.6 Camara

Es el dispositivo que, utilizando un objetivo formado por un juego de lentes y el diafragma, construye una imagen sobre el plano del sensor compuesto de elementos fotosensibles, la digitaliza y la transmite hacia la tarjeta de adquisición del procesador.
Para poder seleccionar la cámara y la óptica que compongan el sistema de visión que mejor se adecue a la aplicación que se desea resolver es necesario tener en cuenta los siguientes parámetros:

- **Campo de visión**: área del objeto que se desea capturar una imagen.

- **Resolución**: tamaño de la característica más pequeña del objeto que se desea que se vea en la imagen.
- **Distancia de trabajo**: separación que existe entre el objeto que se captura la imagen y la óptica.
- **Profundidad de campo**: máxima profundidad del objeto necesaria para conseguir un enfoque adecuado.

Los factores que son convenientes comprobar a la hora de seleccionar una cámara son:

- Iris electrónico (Electronic Light Controller (ELC))
- Auto Iris (AI) - AI vídeo y AI DC (DD)
- Sincronización a línea (Line Lock)
- Sincronización externa (Gen Lock)
- Resolución
- Sensibilidad

2.8 Operaciones sobre el histograma y filtrado de la imagen

2.8.1 Histograma de la imagen

Dada una imagen cuyos pixeles se encuentran definidos en escala de grises con valores entre 0 y 255, se llama histograma de la imagen al grafico que se obtiene de la representación de la frecuencia de aparición de cada uno de los valores, ver Fig. 2.7.
A través del histograma se pueden alterar el brillo, negativo y el contraste de la imagen.

2.8.2 Filtros paso bajo

Son aquellos que dejan pasar las bajas frecuencias y atenúan o eliminan las altas frecuencias, y se traduce en el dominio del espacio como un suavizado de la imagen (la eliminación del ruido y otros pequeños detalles en la imagen) ver figuras 2.8 y 2.9.

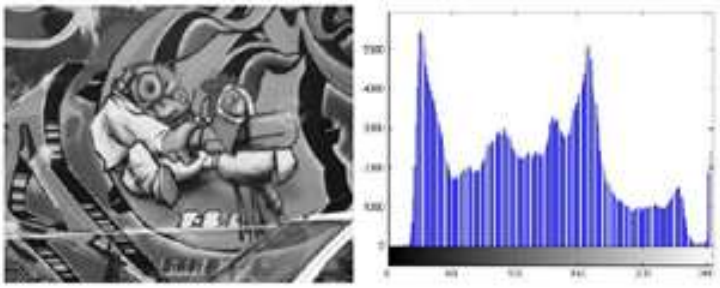


Fig. 2.7: Representación gráfica de un histograma.

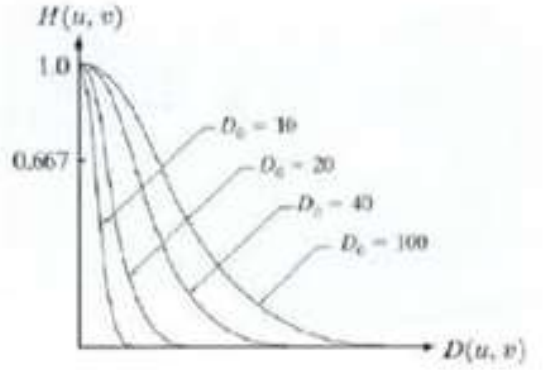


Fig. 2.8: Distintos valores de radio.



Fig. 2.9: Ejemplo de utilización de un filtro paso bajo.

2.8.3 Filtros paso alto

Son justo lo contrario, dejan pasar las altas frecuencias y atenúan o anulan las bajas frecuencias, lo que provoca que se resalten las zonas donde existen cambios bruscos en los niveles de intensidad, como son los bordes (ver figuras 2.10 y 2.11).

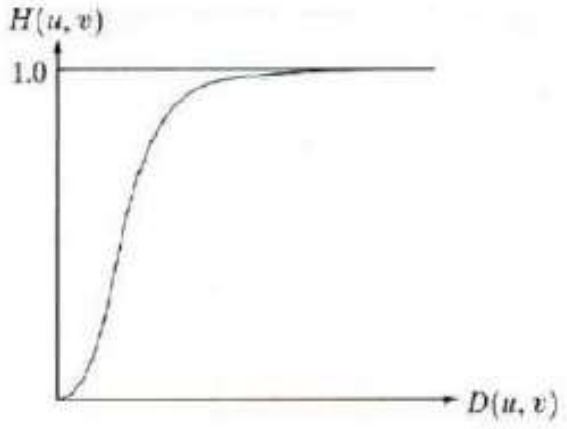


Fig. 2.10: Distintos valores de radio.



Fig. 2.11: Ejemplo de utilización de un filtro paso bajo.

2.8.4 Filtros pasa banda

Son aquellos que atenúan o eliminan las bajas y altas frecuencias dejando pasar a aquellas que pertenecen a una banda determinada.

2.9 El Color

2.9.1 Espacios de color

Un espacio de color es un método de representación por el que se puede especificar, crear o visualizar cualquier color.

Espacio RGB

Variando las cantidades de los colores primarios (rojo, verde, azul) se pueden obtener numerosos colores por mezcla o suma aritmética:

$$f(x) = R + G + B$$

Espacio HSI

Este espacio se basa en el modo que tenemos los humanos de percibir los colores, caracterizando el color en términos de tono, saturación y brillo.

Espacio XYZ

Este espacio de color tiene como finalidad evitar los coeficientes negativos, y se caracteriza por ser independiente del dispositivo que se esté usando.

2.10 Transformación de imágenes

La transformación de una imagen consiste en modificar el contenido de la misma con un objetivo concreto.

2.10.1 Tipos de transformaciones

Transformaciones basadas en los niveles de intensidad

Existen 2 transformaciones para la generación de un nuevo pixel:

- Operaciones basadas en un pixel individual de la imagen
- Operaciones involucrando pixeles vecinos.

Poro tanto, la generación de un nuevo pixel dependerá del valor concreto de cada pixel, o del valor de los pixeles próximos a él (ver figura 2.12).

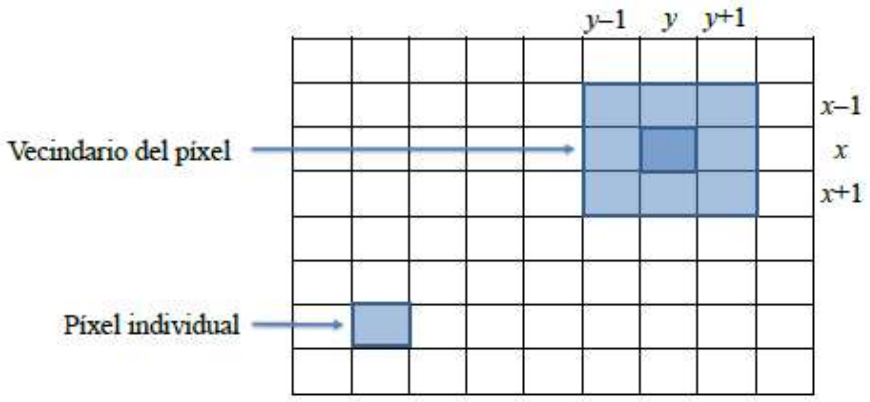


Fig. 2.12: Representación de los valores de un pixel.

Transformaciones lógicas

La figura 2.14 muestra el resultado de aplicar operaciones lógicas not, and, or y XOR.



(a) Estereoscópica izquierda (b) Estereoscópica derecha

Fig. 2.13: Imágenes estereoscópicas.



(a) Imagen binaria de 2.13a



(b) Imagen binaria de 2.13b



(c) Negación lógica de 2.14a



(d) Negación lógica de 2.14b



(e) Operacion OR entre 2.14c y 2.14d



(f) Operacion AND entre 2.14c y 2.14d



(g) Operacion XOR entre 2.14c y 2.14d



(h) Operacion $\leqslant$ entre 2.13a y 2.13b

Fig. 2.14: Resultado de operaciones lógicas.

Transformaciones geométricas

Se da mediante la manipulación de la imagen como un cambio en la posición de los pixeles en lugar de modificar su valor. Existen 3 transformaciones elementales:

- Traslación
- Rotación
- Escalado

2.11 Procesamiento morfológico

El procesamiento morfológico es una técnica de la visión artificial que analiza las imágenes basándose en propiedades de la forma, empleando álgebra de conjuntos. Estos métodos pueden emplearse para el procesamiento, realce de objetos, análisis de imágenes y en la búsqueda de patrones dentro de una imagen [37].

2.12 Segmentación de regiones

Los pixeles y las agrupaciones de pixeles que forman una imagen nos darán información acerca de las regiones de nuestro interés.

2.12.1 Binarización por umbral

La utilización de umbrales nos permite obtener una binarización de las imágenes que extraiga la mayor información posible.
El valor T es el valor de intensidad que separa los dos modos dominantes permitiendo así la identificación de objetos en la imagen.

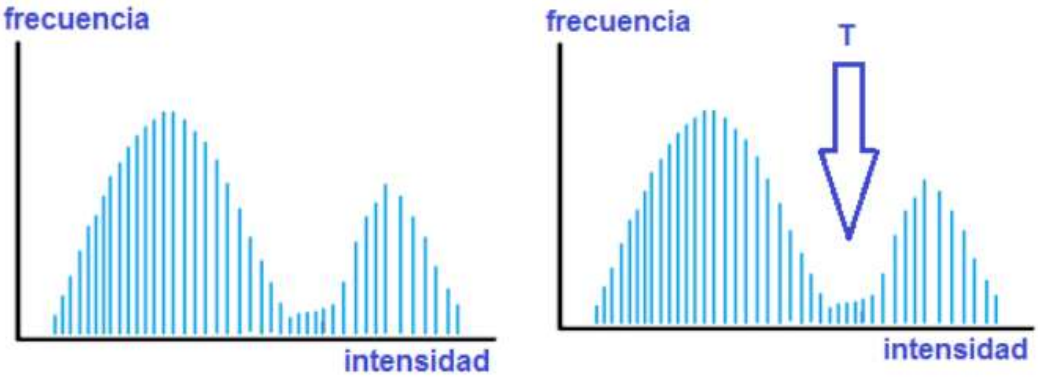
2.12.2 Etiquetado de componentes conexas

Si partimos de una imagen binarizada, las componentes conexas serán aquellas regiones cuyos pixeles posean por ejemplo un valor de “1” y estén conectados entre sí por un conjunto de pixeles



(a) Imagen original (b) Imagen resultante binarizada

Fig. 2.15: Binarización de imágenes.



(a) Histograma de intensidad (b) Identificación de valor umbral T

Fig. 2.16: Histogramas de intensidad.

del mismo valor. A estos pixeles se les asignarán la misma etiqueta identificativa, que debe ser única, constituyendo así su identificador. En la figura 2.17 se muestra un algoritmo iterativo clásico de etiquetado de componentes conexas, donde partimos de una imagen binaria (2.17a) con dos partes diferenciadas; en 2.17b se pueden ver los resultados después de la inicialización de cada pixel con valor 1 a una única etiqueta; 2.17c muestra el resultado de la primera pasada de arriba-abajo, en la cual el valor de cada pixel distinto de cero es reemplazado por el mínimo

de sus vecinos distintos de cero, de una forma recursiva de izquierda a derecha y de arriba abajo; 2.17d muestra los resultados después del primer paso abajo-arriba [37].

$$\begin{bmatrix} 0 & 1 & 1 & 0 & 1 & 1 & 0 \\ 0 & 1 & 1 & 0 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 & 0 & 0 \end{bmatrix}$$

(a)

$$\begin{bmatrix} 0 & 1 & 2 & 0 & 3 & 4 & 0 \\ 0 & 5 & 6 & 0 & 7 & 8 & 0 \\ 0 & 9 & 10 & 11 & 12 & 13 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 14 & 15 & 16 & 0 & 0 & 0 \\ 0 & 17 & 18 & 19 & 0 & 0 & 0 \end{bmatrix}$$

(b)

$$\begin{bmatrix} 0 & 1 & 1 & 0 & 2 & 2 & 0 \\ 0 & 1 & 1 & 0 & 2 & 2 & 0 \\ 0 & 1 & 1 & 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 14 & 14 & 14 & 0 & 0 & 0 \\ 0 & 14 & 14 & 14 & 0 & 0 & 0 \end{bmatrix}$$

(c)

$$\begin{bmatrix} 0 & 1 & 1 & 0 & 1 & 1 & 0 \\ 0 & 1 & 1 & 0 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 14 & 14 & 14 & 0 & 0 & 0 \\ 0 & 14 & 14 & 14 & 0 & 0 & 0 \end{bmatrix}$$

(d)

Fig. 2.17: Algoritmo iterativo para el etiquetado de componentes conexas.

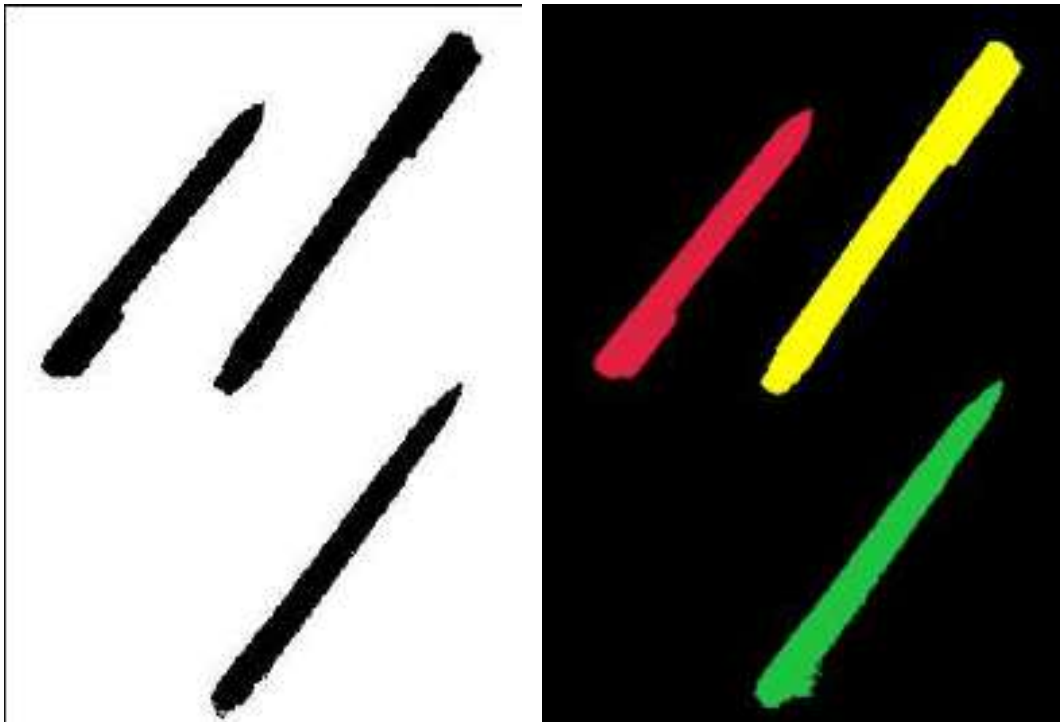
Si aplicamos el algoritmo de etiquetado de componentes conexas iterativo a la imagen binaria mostrada en la figura 2.18a, obtenemos 3 componentes como se puede ver en la figura 2.18b. Con el fin de facilitar la visualización del etiquetado se ha puesto la etiqueta de un color, como se aprecia en la imagen.

2.13 Extracción de regiones por color

Se realizan basándose en el modelo de color RGB extrayendo de la imagen aquellas regiones en las que predomine una determinada componente de color (ver figura 2.19).

2.14 Clasificación y reconocimiento de patrones

El reconocimiento de patrones consiste básicamente en asignar etiquetas a objetos indicando a que clase pertenecen, y que deber ser representados por un conjunto de medidas a las que nos referiremos como atributos o características. La tarea de reconocimiento implica un proceso de aprendizaje a partir de un conjunto de datos u objetos. Hay dos tipos de problemas de

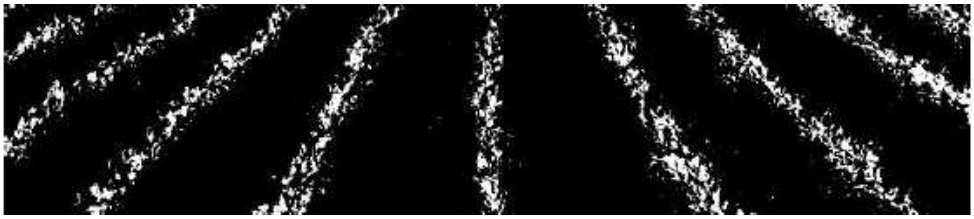


(a) Imagen binaria (b) Resultado de aplicar algoritmo

Fig. 2.18: Aplicación de algoritmo iterativo para el etiquetado de componentes conexas.



(a) Imagen RGB



(b) Resultado de aplicar algoritmo

Fig. 2.19: Binarización de imagen por medio de color.

reconocimiento de patrones: supervisado y no supervisado.

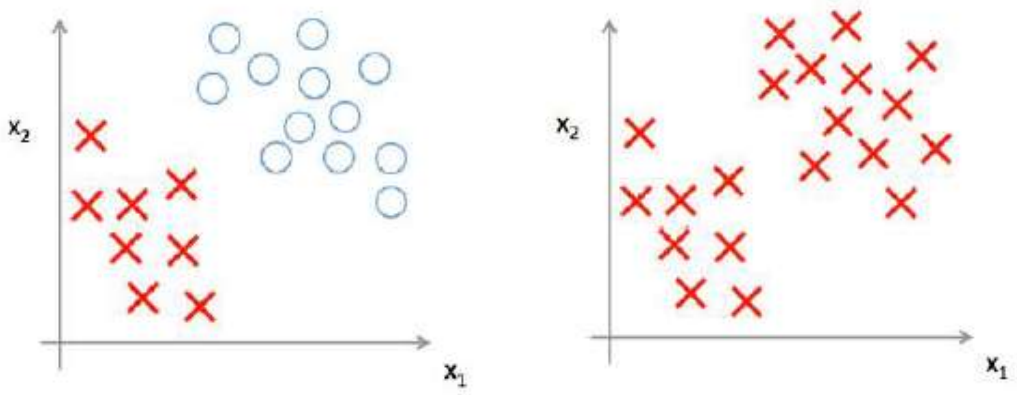
El reconocimiento óptico de caracteres sería un ejemplo de clasificación supervisada, mientras que la estimación de la edad de una persona a partir del rostro constituiría un problema de regresión, ver figura 2.20.

Clasificador

Su función es discriminar entre dos o más clases mutuamente excluyentes.

Tipos de algoritmos de clasificación:

- **El algoritmo de K-means**: Su objetivo es organizar los datos en grupos (clusters) de tal manera que los miembros de cada cluster sean similares entre sí en cuanto a que sus características estén más próximas y diferentes a los de otro cluster.
- **Regresión lineal**: Su objetivo es encontrar la función h que mejor establezca la relación entre las variables independientes (descriptores) y la variable dependiente (etiqueta numérica).
- **Regresión logística**: Su objetivo es que la etiqueta de salida sea 0 o 1, por tanto, podemos acotar la función de regresión lineal entre esos valores.



(a) Supervisada (b) No supervisada

Fig. 2.20: Clasificación. Los datos se presentan por dos características x_1 y x_2

3. DESARROLLO

Para la realización del presente proyecto se contó con el apoyo a la Junta Local de Sanidad Vegetal (JLSV) quien proporcionó la información regional necesaria para la realización del proyecto así como un catálogo de imágenes de hojas con la enfermedad tomadas en las diferentes parcelas de trigo de la región del Valle del Yaqui.

Según información de la JLSV, más del 90 % de los casos de Roya del trigo en la región del valle del Yaqui son de Roya de la hoja, por lo que se decidió concentrarse en esta modalidad de Roya.

Para la detección de Roya en el trigo se decidió utilizar la extracción de regiones por color, debido a que el color de la misma es muy característico y muy contrastante con el resto de la hoja de Trigo.

3.1 Generación de máscara de aprendizaje

Se utilizaron imágenes descargadas por internet así como las proporcionadas por la Junta Local de Sanidad Vegetal, se eligió entre ellas la que mayor detalle ofrecía (tomando en cuenta el acercamiento y la resolución de la misma) para ser tomada como base de entrenamiento, a ésta imagen se le llamó base para máscara (figura 3.1a).

Con la imagen para el entrenamiento seleccionada se precedió a clasificar las zonas significativas de la misma en 3 niveles distintos y se les asignó un color:

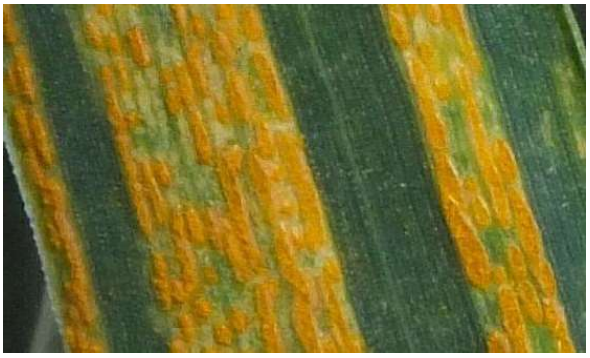
- **Sin enfermedad**: Aquellas zonas de la hoja que no presentan daño por la Roya son clasificadas como zonas sin enfermedad y se les asignó un color verde.
- **Con sospecha de enfermedad**: Aquellas zonas de la hoja que presentan un posible daño por la Roya son clasificadas como zonas sospechosas y se les asignó un color azul.

- **Con enfermedad**: Las zonas de la hoja visiblemente afectadas por la enfermedad se clasificaron como zonas enfermas y se les asignó un color rojo.

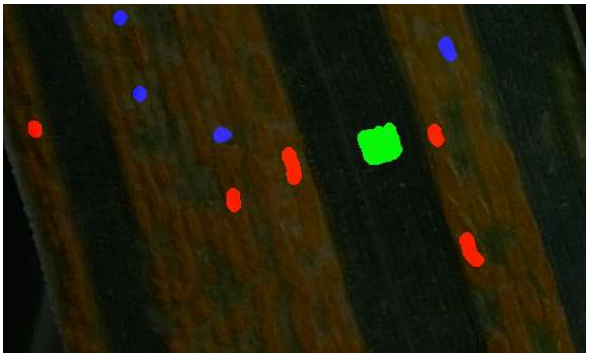
- **Zona ignorada**: La mayoría de la imagen base fue catalogada en esta zona, sin embargo, no significa que esta zona no tenga ninguna de las otras 3 zonas dentro de ella, simplemente se consideró que se tomaron suficientes muestras de las anteriores para el aprendizaje; a esta zona se le asignó el color negro.

La simulación del proceso anterior se puede observar en la figura 3.1b, en la que se aprecia qué zonas fueron coloreadas de qué color.

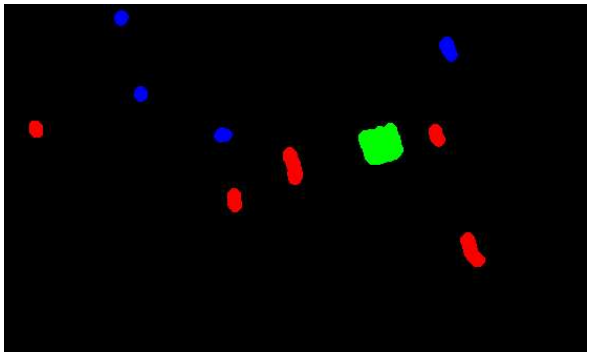
Una vez clasificadas las zonas significativas de la imagen se procedió a colorear cada zona con el color que le correspondía, resultando así en una nueva imagen con sólo 4 colores (uno para cada zona). Ésta imagen resultante fue denominada como máscara (ver figura 3.1c).



(a) Imagen original (base para la máscara)



(b) Imagen original y máscara superpuestas



(c) Resultado final (máscara)

Fig. 3.1: Creación de máscara de aprendizaje

3.2 Programación

Se realizó una aplicación de computadora en lenguaje Java que, a partir de las imágenes del proceso anterior, genera una matriz de datos que sirven como base para adaline; realiza también el proceso de aprendizaje generando los pesos que ha de tener cada una de las variables (R, G, B) y, finalmente, procesando una imagen de entrada para revisar los colores de la misma y encontrar zonas coincidentes con los característicos de la roya de la hoja. El resultado de todo este proceso es una nueva imagen con únicamente dos gamas de colores (Verde y Rojo) que identifican las zonas enfermas y sanas de la imagen procesada, el resultado se asemeja a una visión térmica que, en lugar de detectar zonas de calor, lo hace con zonas enfermas.

3.2.1 Generación de matriz de datos

El proceso de generación de matriz de datos lee los archivos base y máscara (ver figura 3.1) recorriendo en dos ciclos anidados las filas y columnas de pixeles que conforman la imagen.
La matriz consiste en cuatro columnas cuyos datos son los valores para cada uno de los componentes RGB (Rojo, verde y azul), además de una columna que indica el porcentaje de sospecha de enfermedad sobre el color conformado por las componentes (ver tabla 3.1).
Se realiza el recorrido pixel por pixel en la imagen máscara, se obtiene el color del pixel ubicado en (x, y) en dicha imagen y se realiza la acción según su valor:

- **Negro**: El pixel es ignorado y el algoritmo pasa al siguiente.
- **Otro**: Se inserta un nuevo registro en la matriz cuyos valores serán los valores RGB encontrados en el pixel de la imagen base en la misma coordenada (x, y) y cuya salida será asignada dependiendo del color del pixel (x, y) de la máscara:

  Rojo: 100.

  Azul: 50.

  Verde: 0.

Tab. 3.1: Ejemplo de datos en la matriz

RGB Base			
R	**G**	**B**	**Salida**
61	85	63	0
51	75	53	0
158	145	49	50
171	159	37	50
198	129	0	100
157	102	2	100

Al final fueron procesados todos aquellos pixeles de la imagen base que se encontraban en una zona roja, azul o verde, resultando en una matriz de 3693 datos, cada uno de ellos con el componente RGB de la imagen base y el número asignado por la zona en que se encontraba, tal como se muestra en la tabla anterior.

3.2.2 Entrenamiento Adaline

Después de procesar las imágenes base y entrenamiento se procede con el aprendizaje adaline, éste proceso consiste, a grandes rasgos, en leer la matriz de datos generada en el proceso anterior y generar como salida los pesos para cada una de las componentes.
Se programó una clase Java llamada Adaline, la cual recibe como parámetros de construcción de objeto 3 datos:

- **Factor de aprendizaje**: Es el valor que indica la cantidad de movimiento que hará el algoritmo para cada iteración.
- **Error deseado**: Es un número que indica cuál es el máximo porcentaje de desvío que deseamos tener entre el valor esperado y el calculado.
- **Límite de épocas**: Éste número sirve para detener el algoritmo si no se ha alcanzado el error deseado.

Como parte de la construcción del objeto Adaline se generan también valores aleatorios para los pesos de R,G y B que van de 0.00001 a 0.09999.
Se programó un método dentro de la clase Adaline cuyo nombre es entrenar. Éste se encarga, como la palabra lo dice, de realizar el proceso de aprendizaje; recibe para hacer su trabajo un

parámetro llamado entradas, que es un arreglo bi-dimensional de datos dobles y que viene dado por la matriz de datos ya mencionada anteriormente.

Se inicia el proceso principal con un contador de épocas totales en 0, suma de los errores cuadrados en 0 y un booleano llamado finalizado que indica si se terminó o no con el proceso de aprendizaje.

El proceso secundario, que llamamos época, consiste en recorrer cada una de las filas de los datos de entrada (matriz de datos) y, para cada uno de los registros realizar lo siguiente:

- **Calcular salida**: A partir de los de los datos de entrada RGB (primeros 3 datos del registro) se realiza la multiplicación de cada uno de las componentes por su respectivo peso, el resultado de las tres operaciones se suma y se envía como salida calculada.

  $$salidaCalculada = (valorR * pesoR) + (valorG * pesoG) + (valorB * pesoB).$$

- **Cálculo de error**: Se resta la salida calculada en el paso anterior de la esperada (última columna del registro).

  $$error = salidaEsperada - salidaCalculada.$$

- **Acumular error cuadrático**: Se eleva el error al cuadrado y se suma el resultado a la variable que guarda la suma de éstos.

  $$sumaErroresCuadrados = sumaErroresCuadrados + error^2.$$

- **Ajuste de pesos**: a partir de las entradas y el error se calcula el nuevo peso para cada una de las componentes.

  $x = x_{-1} + fa * e * y$ donde:

  x: es el nuevo peso para el componente,

  x_{-1}: es el peso anterior del mismo,

  fa: es el factor de aprendizaje,

  e: es el error y

  y: es el valor de la componente en cuestión que tiene el registro.

Cuando se termina de procesar todos los registros de la matriz de datos se procede a:

- Aumentar el uno el contador de épocas

  $$contadorEpocas = contadorEpocas + 1$$

- Se calcula el promedio de errores cuadráticos

  $$errorPromedio = \frac{sumaErroresCuadrados}{cantidadDatos}$$

- Se comprueba que el error promedio sea menor o igual que el error deseado ó que el contador de épocas sea superior o igual al límite impuesto durante la construcción del objeto.

  En caso de que cualquiera de las dos condiciones anteriores se cumpla, el algoritmo da por terminado el aprendizaje

  En caso contrario, el algoritmo procederá a procesar la siguiente época.

Cuando el algoritmo esté marcado como finalizado, ya sea porque se alcanzó el límite de épocas establecido durante la construcción del objeto o porque se ha llegado a tener un error menor o igual que el deseado; se procede a generar el archivo que guardará los pesos obtenidos durante el proceso, el formato de archivo se parece al anterior, sólo que ahora tendrá un solo registro y 3 columnas, con los pesos para cada una de las componentes.

Tab. 3.2: Ejemplo de pesos finales para las componentes R,G,B

R	G	B
0.6155111263615618	-0.09761283095348525	-0.4353775400368137

3.2.3 Procesamiento de imágenes

Para este proceso se programó un método en la clase principal de la aplicación que se encarga del procesamiento de la imagen que se desee, ésta puede estar en cualquier formato de imagen común en la computación (JPG, PNG, JFIF...).
Antes de iniciar el proceso se crea un archivo de formato JPG que servirá para guardar la información resultante del proceso.

El proceso consiste en un recorrido en dos procesos iterativos anidados (filas y columnas de pixeles); para cada uno de los pixeles encontrados en la coordenada (x, y) de la imagen se toma la componente (R, G, B) y se envía a un método que generará un nuevo color a partir de éstos. Para la generación del nuevo color se calcula primero un porcentaje de enfermedad, el cual viene dado por la suma de las multiplicaciones de cada una de las componentes por su respectivo peso: $porcentaje = (valorR * pesoR) + (valorG * pesoG) + (valorB * pesoB)$, se le aplica un filtro al porcentaje para que esté entre 0 y 100 (si es menor que 0 se le asigna 0 y si es mayor que 100 se ajusta en 100).

El nuevo color será una componente (R, G, B) compuesta de la siguiente forma:

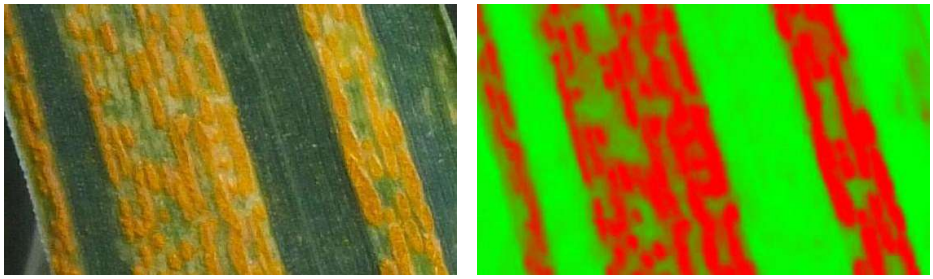
R : Será el resultado de $255 * porcentaje/100$

G : Será el resultado de $255 * (1 - porcentaje/100)$

B : Será siempre 0.

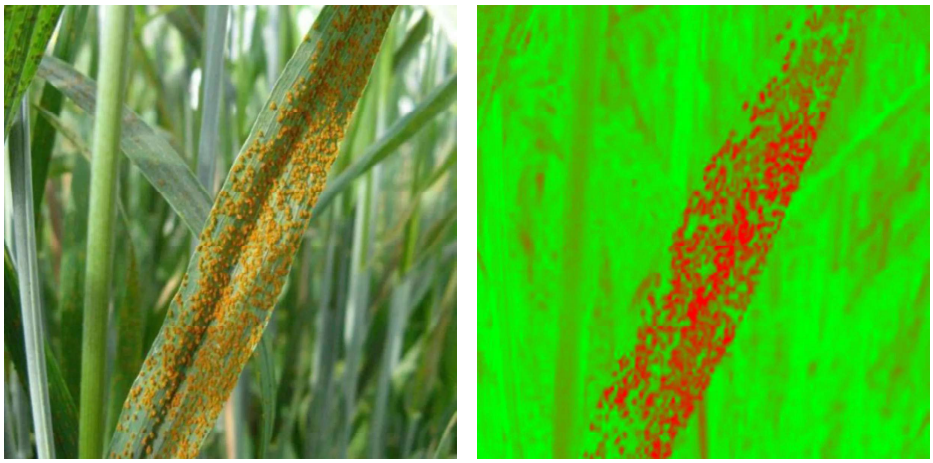
De ésta forma se puede obtener una gama de colores para cada pixel que depende del porcentaje de enfermedad que se calcula tenga ese pixel. En la figura 3.2 se puede ver el resultado de procesar la imagen tomada como base para la máscara. En la figura 3.3 se puede ver el resultado de procesar una segunda imagen que no tiene nada que ver con la imagen tomada como base para la máscara obteniendo resultados similares.

Así como esos procesamientos se realizaron varios mas con el objetivo de comprobar que los datos de aprendizaje generados y los pesos obtenidos en base a éstos podían servir para procesar cualquier imagen en busca de la enfermedad. Se puede ver un tercer ejemplo en la figura 3.4



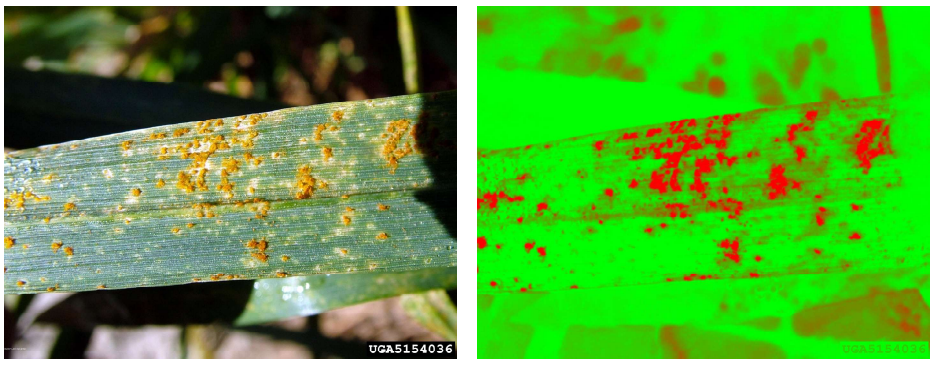
(a) Imagen de entrada (b) Imagen de salida

Fig. 3.2: Procesado de imagen utilizada para máscara



(a) Imagen de entrada (b) Imagen de salida

Fig. 3.3: Primer ejemplo de procesado de imagen diferente a la base



(a) Imagen de entrada (b) Imagen de salida

Fig. 3.4: Segundo ejemplo de procesado de imagen diferente a la base

3.2.4 Notas sobre ejecuciones posteriores

Sólo la primer ejecución del software desarrollado generará la matriz de datos y el proceso de aprendizaje, cuando estos procesos se hayan realizado correctamente se generarán los archivos necesarios para la ejecución del procesamiento de imágenes sin necesidad de pasar nuevamente por el proceso de generación de datos y/o aprendizaje adaline.
Si fuera necesaria el generar nuevamente la matriz y los pesos de aprendizaje se podría proceder de dos formas:

- Indicar al algoritmo que vuelva a generar los archivos. Éste cuenta con un parámetro booleano que le indica si ha o no de borrar los datos existentes para poder trabajar con datos nuevos.

- Borrar manualmente los datos generados por el algoritmo anteriormente (el archivo matriz y el archivo de pesos). Al intentar leer los archivos el algoritmo no los encontrará y procederá a generarlos nuevamente.

3.3 Visita a cultivos para toma de muestras

Con apoyo de la Junta Local de Sanidad Vegetal se pudo realizar una visita a un cultivo enfermo en el municipio de Navojoa, Sonora; en dicha visita se procedió a sacar fotografías de las zonas donde se nos indicó existía la enfermedad, así como también a zonas sanas del cultivo para realizar las pruebas al software desarrollado.
Se realizaron fotografías desde tierra, las cuales fueron tomadas con una cámara DSLR de la marca Sony modelo α35, así como también se realizaron fotos aéreas tomadas con un dron proporcionado amablemente por la institución educativa en la cual se realiza este trabajo y pilotado por el Dr. Baldomero Lucero Velázquez de la división de Maestría en Mecatrónica de ITESCA.



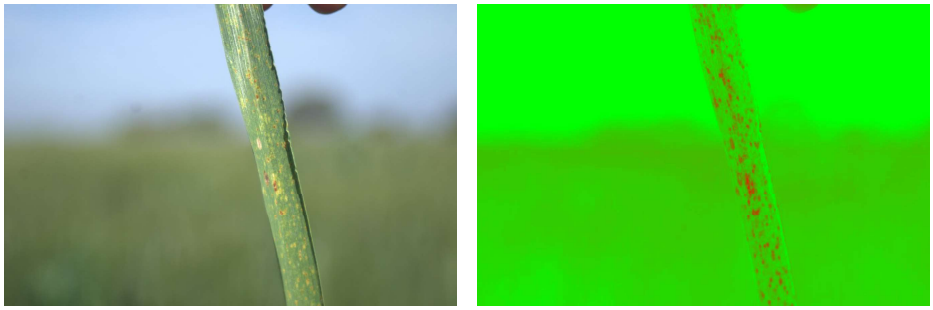
Fig. 3.5: Imagen del dron sobrevolando la parcela

3.3.1 Procesamiento de muestras

Las fotografías tomadas en nuestra visita la parcela afectada en Navojoa fueron procesadas por el software desarrollado para tal efecto obteniendo los siguientes resultados.

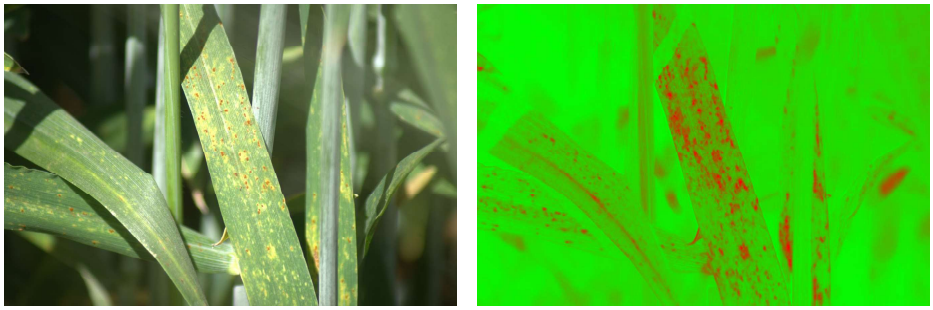
El nivel de detalle otorgado por las diferentes tomas es notablemente diferente, éstas diferencias también se puede notar al procesar las imágenes, ya que como se puede apreciar en cualquiera de las tomas aéreas (la figura 3.11, por ejemplo), el nivel de detalle no permite observar (ni a simple vista ni por medio del algoritmo) si hay o no presencia de roya en las hojas.

Caso contrario con las imágenes que presentan un nivel de detalle mas alto como cualquiera de las tomas terrestres (la figura 3.7 por ejemplo), donde se puede apreciar (tanto a simple vista como con ayuda del algoritmo) la presencia de Roya en la hoja.



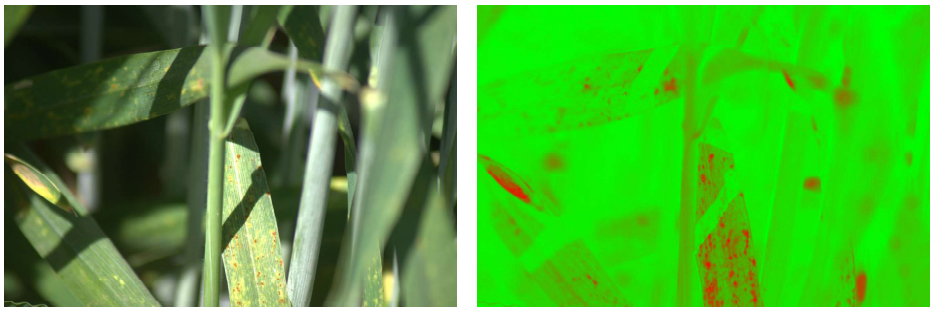
(a) Imagen de entrada (b) Imagen de salida

Fig. 3.6: Toma terrestre 1



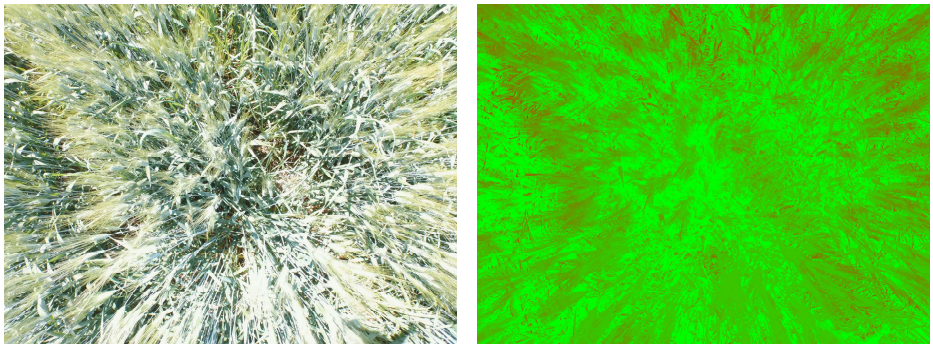
(a) Imagen de entrada (b) Imagen de salida

Fig. 3.7: Toma terrestre 2



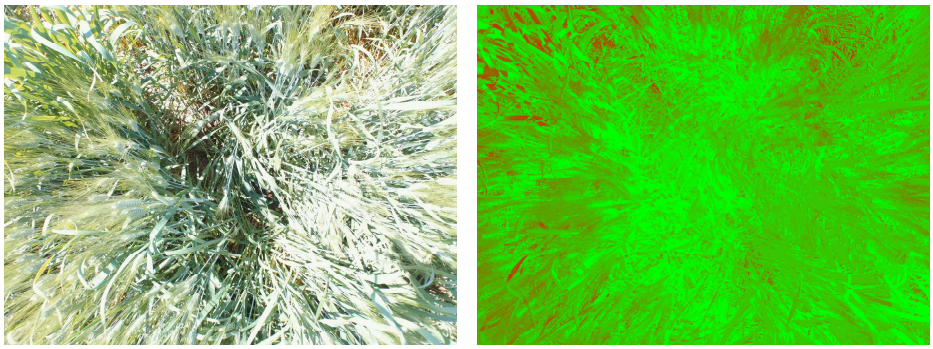
(a) Imagen de entrada (b) Imagen de salida

Fig. 3.8: Toma terrestre 3



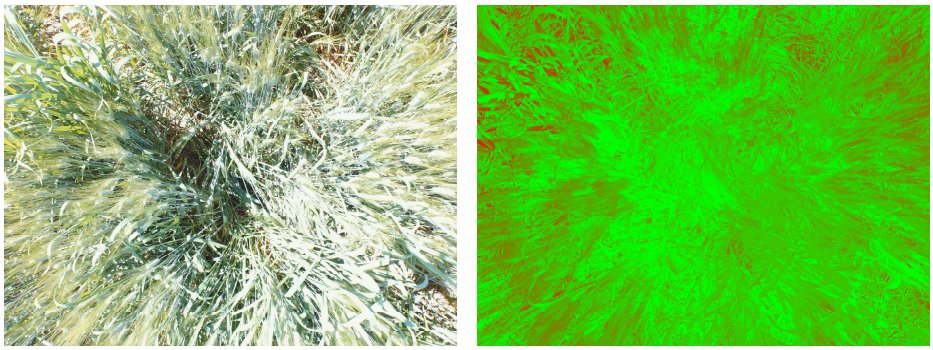
(a) Imagen de entrada (b) Imagen de salida

Fig. 3.9: Toma aérea 1



(a) Imagen de entrada (b) Imagen de salida

Fig. 3.10: Toma aérea 2



(a) Imagen de entrada (b) Imagen de salida

Fig. 3.11: Toma aérea 3

4. CONCLUSIONES Y RECOMENDACIONES

4.1 Conclusiones

Coordinarse con las instituciones directamente relacionadas con la problemática nos brinda información de primera mano, así como la oportunidad de obtener información que de otra forma no sería posible, las personas encargadas de dichas instituciones cuentan con archivos fotográficos y datos estadísticos de gran ayuda para la investigación, así como la experiencia necesaria para entrar en los cultivos para la recolección de información sin ponerlos en riesgo.

La red neuronal adaline resultó muy efectiva para la detección de la roya de la hoja en el trigo, gracias al contraste de color que tiene la hoja con el de ésta enfermedad es posible detectarla rápidamente utilizando una red correctamente entrenada. Las técnicas utilizadas en este trabajo demostraron ser efectivas para la detección de la enfermedad de la roya de la hoja en el trigo, las imágenes resultantes muestran una clara separación entre las zonas sanas y enfermas de la misma.

Aunque existen lenguajes de programación que cuentan con librerías que facilitan enormemente el trabajo de reconocimiento de patrones en imágenes, el realizar el código de entrenamiento y reconocimiento desde cero permite conocer mas a fondo el funcionamiento de las redes neuronales, así como entender claramente el problema desde el punto de vista de desarrollo de software, logrando así un mayor control y conocimiento sobre el software desarrollado. Demostrando además que cualquier lenguaje de programación puede ser utilizado para un objetivo distinto del que se cree que éste tiene.

La claridad y nitidez que ofrecen las imágenes tomadas por una cámara profesional es sin duda uno de los pilares fundamentales para la detección de patrones y anomalías en una imagen dada, aunado a ésto, el contar con un tele objetivo de 450mm brinda la comodidad de realizar tomas

nítidas, cercanas y claras sin la necesidad de llegar a invadir al cultivo ni provocar daños en el mismo.

Hablando de la invasión y los daños que se pueden provocar en un cultivo a la hora de recolectar muestras; recabarlas con un dron puede resultar muy útil, rápido y cómodo, sin embargo, aquí se pierde la claridad y nitidez que ofrece una toma de cámara fotográfica profesional, en éste trabajo se concluye que las tomas realizadas con éste tipo de vehículos pertenecientes a la gama utilizada en el mismo o inferiores no ofrecen el nivel de detalle suficiente para la correcta detección de la enfermedad en la hoja.

4.2 Recomendaciones

Uno de los mayores problemas a la hora de recolectar las imágenes para su análisis se deriva en la calidad y claridad de las mismas, siendo necesario una toma con el suficiente acercamiento y resolución para que el detalle de la hoja pueda ser analizado correctamente por el software realizado en el presente trabajo. Para subsanar dicho problema se pueden utilizar diferentes técnicas o herramientas fotográficas, siendo una de ellas la recolección por vía terrestre con un vehículo de radio control que circule por el surco, sin embargo, dicho vehículo habrá de ser habilitado para terreno fangoso e incluso para agua. Otra de las herramientas que se pueden utilizar es un dron equipado con una cámara con un acercamiento y resolución suficiente para la detección de los detalles en la hoja. Se pudieran realizar también pruebas con la instalación de sensores, así como la recolección y monitoreo de los datos arrojados por los mismos; en la investigación se aborda el tema de las temperaturas y porcentaje de humedad idóneos para el desarrollo de ésta enfermedad; se puede aprovechar dicha información para vigilar estas dos variables en un cultivo determinado y calcular el riesgo de desarrollo de la roya para su ataque temprano.

En las universidades de la región existen ingenierías enfocadas al desarrollo de software que abordan temas de reconocimiento de imágenes, patrones, análisis de datos, etc; sin embargo, se considera que el agregar a éstos temas un enfoque de resolución de problemas propios de la comunidad agregaría más interés por parte del alumnado en profundizar en este tipo de

tecnologías a la vez que se estaría contribuyendo en el desarrollo de la agricultura o cualquier otra actividad económica regional y, por añadidura, al desarrollo de la comunidad.

A la comunidad de agricultores de la región se les recomienda que recauden y almacenen toda la información que les sea posible sobre las enfermedades o problemas que afectan los cultivos, una gran cantidad de datos puede ser determinante a la hora de realizar una análisis profundo sobre un problema en específico. Para el caso de este trabajo fue de gran ayuda las imágenes proporcionadas por la JLSV así como la información sobre la variedad que más afecta los cultivos de la región. De la misma forma, una buena cantidad de datos almacenados sobre cualquier problema ayudarán a investigadores posteriores con sus respectivos trabajos.

REFERENCIAS BIBLIOGRÁFICAS

[1] C. P. Sauceda Acosta, G. A. Lugo Garcia, H. E. Villaseñor Mir, L. Partida Ruvalcaba, and A. Reyes Olivas. Un método preciso para medir severidad de roya de la hoja (puccinia triticina eriksson) en trigo. *Revista Fitotecnia Mexicana*, 38(4):427–434, 2015.

[2] K. D. Cusme Zambrano and A. M. Loor Pinagorte. Aplicación móvil de detección y clasificación de la roya en hojas de café rubusta mediante aprendizaje automático., 2019. http://repositorio.espam.edu.ec/bitstream/42000/1104/1/TTC21.pdf.

[3] higieneambiental. Inteligencia artificial y big data para combatir plagas., 2019. https://higieneambiental.com/control-de-plagas/inteligencia-artificial-y-big-data-para-combatir-plagas.

[4] M. G. Vázquez Rueda, M. Ibarra Reyes, F. G. Flores García, and H. A. Moreno Casillas. Redes neuronales aplicadas al control de riego usando instrumentación y análisis de imágenes para un micro-invernadero aplicado al cultivo de albahaca. *Instituto tecnológico de la Laguna*, 147(5):93–100, 2018. https://www.rcs.cic.ipn.mx/2018_147_5/Redes%20neuronales%20aplicadas%20al%20control%20de%20riego%20usando%20instrumentacion%20y%20analisis%20de%20imagenes.pdf.

[5] Gustavo Ovando, Mónica Bocco, and Silvina Sayago. Redes neuronales para modelar predicción de heladas. *Agricultura Técnica*, 65:65 – 73, 03 2005.

[6] L. Elías. Redes neuronales artificiales aplicadas al cacao, tecnología al servicio del cultivo., 2019. https://vivaelcacao.com/redes-neuronales-artificials-aplicadas-al-cacao-tecnologia-al-servicio-del\-cultivo/.

[7] Alejandro Pérez Pérez, Idarh Claudio Matadamas Ortiz, Maricela Morales Hernández, and Marisol Altamirano Cabrera. Prototipo basado en redes neuronales para el monitoreo y predicción de temperatura en invernaderos de los valles centrales de oaxaca. *Revista de Prototipos Tecnológicos*, 3(9):14 – 23, 2017.

[8] Gloria del Carmen Rendón Sustaita, Jose Ángel Domínguez López, Myriam Araceli Martínez Rodríguez, Oscar Adrián Garay Molina, and Dante Israel Juárez Pedraza. Sistema inteligente para controlar sistemas de riego en méxico. *Ventana Informática*, 37:45 – 57, 2017.

[9] Ana Abad Alameda. Diseño e implementación de un sistema de seguimiento de parámetros ambientales en plantaciones de café, Junio 2016.

[10] Bladimir Pérez, José Koo, Fernando Garcia, and Juan Carmona Fernández. Automatización, monitoreo y control remoto de un sistema de riego agrícola con código abierto. Julio 2014.

[11] Edison David Alomoto Barahona and Jhony Fernando Ramírez Encalada. Diseño y construcción de un prototipo de sistema de riego automatizado para la granja experimental nono de la udla, 2016.

[12] Víctor Ramírez Lora, Antonio Junior Fuentes Alcántara, and Susana Elizabeth Fuentes Alcántara. Desarrollo de prototipo de máquina inteligente de fertiriego de control remoto y bajo costo en la región lambayeque. *TzhoeCoen. Revista científica*, 8(2).

[13] Selección de cereales mediante drones para la producción de bioetanol., 2019. `https://www.interempresas.net/Grandes-cultivos/Articulos/252676-Seleccion-de-cereales-mediante-drones-para-la-produccion-de-bioetanol.html`.

[14] Pheno-inspect accelerates plant cultivation., 2019. `https://www.uni-bonn.de/news/226-2019`.

[15] Drones podrían brindar datos confiables y precisos a productores frutícolas., 2020. https://elabcrural.com/drones-podrian-brindar-datos-confiables-y-precisos-a-productores-fruticolas/.

[16] Este emprendedor costarricense usa drones para la agricultura., 2020. https://www.forbes.com.mx/este-emprendedor-costarricense-usa-drones-para-la-agricultura/.

[17] Semillera incorpora drones para monitorear el maíz., 2018. http://agrovoz.lavoz.com.ar/agricultura/semillera-incorpora-drones-para-monitorear-el-maiz.

[18] John deere y la inteligencia artificial en la agricultura. https://www.aecoc.es/innovation-hub-noticias/john-deere-y-la-inteligencia-artificial-en-la\-agricultura/.

[19] Inteligencia artificial para tractores sin conductor. https://www.tynmagazine.com/inteligencia-artificial-para-tractores-sin-conductor/.

[20] Guía para iniciarse en microsoft azure machine learning studio. https://mvpcluster.com/microsoft-azure-machine-learning-studio/.

[21] Intel 2020 vision: Sembrar las semillas de la agricultura inteligente. https://www.intel.es/content/www/es/es/it-managers/2020-vision-the-smart-farm.html.

[22] Silvana Pineda. Un cerebro de inteligencia artificial en la agricultura. https://blog.ciat.cgiar.org/es/agriculture-ai-brain/.

[23] Detección en tiempo real de malezas a través de técnicas de visión artificial y su incorporación en sistemas de aplicación selectiva de herbicidas. http://cyt.frvm.utn.edu.ar/investigacion/proyectos/homologados-utn/63-tun4300.

[24] Controlando aguacates con drones y sensores., Junio 2019. https://www.visualnacert.com/controlando-el-cultivo-de-aguacates-con-drones-y-sensores/.

[25] ¿de qué forma está la inteligencia artificial moldeando a la industria de las frutas y vegetales frescos?., Mayo 2017. https://www.pma.com/es/Content/Articles/2017/06/De-que-Forma-Esta-la-Inteligencia-Artificial-Moldeando.

[26] K. J. Jurriaans. La FAO y sus socios redoblan sus esfuerzos frente a la dañina roya del trigo, 2016. http://www.fao.org/news/story/es/item/410264/icode/.

[27] JLSVYAQUI. Trigo, 2019. http://jlsvyaqui.org.mx/?page_id=931.

[28] SAGARPA. Resumen nacional intención de siembra 2019, 2019. http://infosiap.siap.gob.mx/opt/agricultura/intension/Intenci%C3%B3n%20de%20siembra_por%20cultivo%20OI%202019.pdf.

[29] S. R. Márquez Berber, G. Almaguer Vargas, R. Schwentesius Rindermann, and A. V. Ayala Garay. *Trigo en Sonora y su contexto nacional e internacional*. CEDRSSA, 2014. http://biblioteca.diputados.gob.mx/janium/bv/cedrssa/lxii/trig_soncon_nacint.pdf.

[30] Marcelo Carmona and Francisco Sautua. Epidemias de roya amarilla del trigo. nuevas razas en el mundo, monitoreo y decisión de uso de fungicidas. *Revista de la Facultad de Agromomía UBA*, 38:37–58, 09 2018.

[31] R. Bongiovanni, E. C. Montovani, S. Best, and A. Roel. Agricultura de precision: Integrando conocimientos para una agricultura moderna y sustentable., 2006. http://www.procisur.org.uy/agricultura-de-precision-integrando-conocimientos-para-una-agricultura-\moderna-y-sustentable/es.

[32] E. García and F. Flego. Agricultura de precisión. https://www.palermo.edu/ingenieria/downloads/pdfwebc&T8/8CyT12.pdf.

[33] A. González, G. Amarillo, M. Amarillo, and F. Sarmiento. Drones aplicados a la agricultura de precisión., 2016. https://www.researchgate.net/publication/315988656_Drones_Aplicados_a_la_Agricultura_de_Precision.

[34] M. Elías Rodríguez. Sistema de posicionamiento para un dron., 2015. https://riull.ull.es/xmlui/bitstream/handle/915/1137/Sistema%20de%20posicionamiento%20para%20un%20drone.pdf?sequence=1&isAllowed=y.

[35] A. Velázquez Olivera. El mundo de los drones. http://www.cienciorama.unam.mx/#!titulo/538/?el-mundo-de-los-drones.

[36] P. Ponce Cruz. Inteligencia artificial con aplicaciones a la ingeniería., 2010. https://lelinopontes.files.wordpress.com/2014/09/inteligencia-artificial-con-aplicaciones-a-la-ingenierc3ada.pdf.

[37] Alegre E, G. Pajares, and A. de la Escalera. Conceptos y métodos en visión por computador, 2016. https://intranet.ceautomatica.es/sites/default/files/upload/8/files/ConceptosyMetodosenVxC.pdf.