



DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN

**CARRERA DE INGENIERÍA EN SISTEMAS E
INFORMÁTICA**

**TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERO EN SISTEMAS E INFORMÁTICA**

**TEMA: SISTEMA BASADO EN REDES NEURONALES
ARTIFICIALES USANDO MICROFOTOGRAFÍAS PARA EL
DIAGNÓSTICO MICOLÓGICO EN PLANTAS DE MAÍZ**

**AUTORES:
LOBATO CAMPOVERDE, MARÍA ISABEL
TOAZA MORA, JORGE FABRICIO**

**DIRECTORA: ING. CÁRDENAS DELGADO, SONIA
ELIZABETH**

SANGOLQUÍ, ECUADOR

2019

CERTIFICADO



**DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN
CARRERA DE INGENIERÍA EN SISTEMAS E INFORMÁTICA**

CERTIFICACIÓN

Certifico que el trabajo de titulación, "**SISTEMA BASADO EN REDES NEURONALES ARTIFICIALES USANDO MICROFOTOGRAFÍAS PARA EL DIAGNÓSTICO MICOLÓGICO EN PLANTAS DE MAÍZ**" fue realizado por los señores **LOBATO CAMPOVERDE, MARÍA ISABEL** y **TOAZA MORA, JORGE FABRICIO**, el mismo que ha sido revisado en su totalidad, analizado por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustenten públicamente.

Sangolquí, 25 de enero de 2019

Atentamente,

Ing. Sonia Cárdenas Delgado, Ph.D.

AUTORÍA DE RESPONSABILIDAD



DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN
CARRERA DE INGENIERÍA EN SISTEMAS E INFORMÁTICA

AUTORÍA DE RESPONSABILIDAD

Nosotros, **LOBATO CAMPOVERDE, MARÍA ISABEL**, con cédula de ciudadanía Nro. 1724685555, y **TOAZA MORA JORGE FABRICIO**, con cédula de ciudadanía Nro. 1713673406, declaramos que el contenido, ideas y criterios del trabajo de titulación: **“SISTEMA BASADO EN REDES NEURONALES ARTIFICIALES USANDO MICROFOTOGRAFÍAS PARA EL DIAGNÓSTICO MICOLÓGICO EN PLANTAS DE MAÍZ”** es de nuestra autoría y responsabilidad, cumpliendo con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Consecuentemente el contenido de la investigación mencionada es veraz.

Sangolquí, 25 de enero de 2019

LOBATO CAMPOVERDE MARÍA ISABEL

C.C.: 1724685555

TOAZA MORA JORGE FABRICIO

C.C.: 1713673406

AUTORIZACIÓN



DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN
CARRERA DE INGENIERÍA EN SISTEMAS E INFORMÁTICA

AUTORIZACIÓN

Nosotros, **LOBATO CAMPOVERDE MARÍA ISABEL** y **TOAZA MORA JORGE FABRICIO**, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: “**SISTEMA BASADO EN REDES NEURONALES ARTIFICIALES USANDO MICROFOTOGRAFÍAS PARA EL DIAGNÓSTICO MICOLÓGICO EN PLANTAS DE MAÍZ**” en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra autoría y responsabilidad.

Sangolquí, 25 de enero de 2019


.....
LOBATO CAMPOVERDE MARÍA ISABEL
1724685555


.....
TOAZA MORA JORGE FABRICIO
1713673406

DEDICATORIA

Esta tesis va dedicada en primera instancia a Dios, quien con su amor y bondad nos ha fortalecido, ayudado y nos ha guiado para cumplir nuestros objetivos y metas.

A nuestros padres, quienes nos han brindado su apoyo incondicional, quienes nos han forjado principios y quienes nos han animado a cumplir nuestros sueños tanto personales como profesionales.

A nuestros amigos, quienes nos han animado, apoyado y han estado presentes en nuestras vidas.

Esto es gracias a ustedes.

AGRADECIMIENTOS

Queremos agradecer a Dios, quien nos ha brindado sabiduría, gracia y fortaleza para culminar nuestra carrera universitaria.

A nuestros padres, hermanos y familia, quienes han estado presentes en todo momento y nos han apoyado incondicionalmente, quienes nos han brindado palabras de aliento y nos han enseñado a luchar por nuestros sueños.

A la ingeniera Sonia Cárdenas, al ingeniero. Mauricio Loachamín, al ingeniero. Alexander Toaza y al ingeniero Hernando Regalado, quienes con su conocimiento, tiempo y dedicación, nos han ayudado a culminar el proyecto de titulación.

A nuestros amigos quienes además de ser un apoyo como compañeros de carrera, nos han brindado su amistad y hemos compartido grandes momentos que serán inolvidables.

Finalmente, a todas aquellas personas quienes de una u otra forma han contribuido para que este sueño se haga realidad.

ÍNDICE

CERTIFICADO	i
AUTORÍA DE RESPONSABILIDAD.....	ii
AUTORIZACIÓN	iii
DEDICATORIA.....	iv
AGRADECIMIENTOS	v
ÍNDICE	vi
ÍNDICE DE TABLAS	x
ÍNDICE DE FIGURAS	xii
RESUMEN.....	xvii
ABSTRACT.....	xviii
CAPÍTULO 1	1
INTRODUCCIÓN.....	1
1.1. ANTECEDENTES	1
1.2. PLANTEAMIENTO DEL PROBLEMA	2
1.3. JUSTIFICACIÓN	3
1.4. OBJETIVOS.....	4
1.4.1. Objetivo General	4
1.4.2. Objetivos Específicos.....	4
1.5. ALCANCE	5
1.6. HIPÓTESIS.....	6
CAPÍTULO 2	7
MARCO TEÓRICO.....	7
2.1. INTELIGENCIA ARTIFICIAL	7

2.1.1. Definición	7
2.1.2. Tipos de Inteligencia Artificial.....	7
2.1.3. Técnicas de la Inteligencia Artificial	8
2.2. INGENIERÍA DEL CONOCIMIENTO.....	9
2.3. SISTEMAS BASADOS EN CONOCIMIENTO.....	10
2.4. SISTEMAS EXPERTOS.....	11
2.4.1. Clasificación de los Sistemas Expertos.....	13
2.4.2. Características de los Sistemas Expertos.....	13
2.4.3. Estructura.....	14
2.5. METODOLOGÍA	16
2.6. REDES NEURONALES	19
2.6.1. Redes Neuronales Biológicas	19
2.6.2. Redes Neuronales Artificiales	21
2.6.3. Redes Neuronales Profundas	28
2.7. CLASIFICADORES.....	34
2.7.1. Vecinos más cercanos (K-Nearest Neighbours)	34
2.7.2. Bosque Aleatorio (Random Forest).....	35
2.8. VISIÓN ARTIFICIAL	37
2.8.1. Definición	37
2.8.2. Fases	37
2.9. MORFOMETRÍA	39
2.9.1. Clasificación.....	40
2.9.2. Elementos	40
2.10. PLAGAS DEL MAÍZ	42
2.10.1. Hongos fitopatógenos	42
2.10.2. Maíz	43
2.10.3. Hongos que afectan al maíz	45
CAPÍTULO 3.....	51
DISEÑO Y DESARROLLO DEL SISTEMA	51

3.1. INTRODUCCIÓN	51
3.2. ANÁLISIS DEL PROBLEMA	52
3.2.1. Problema.....	52
3.2.2. Análisis de viabilidad.....	53
3.3. SOLUCIÓN	54
3.4. MODELADO DEL CONOCIMIENTO	54
3.4.1. Esquema inferencial (reglas)	56
3.4.2. Diagrama de arquitectura SBC	58
3.4.3. Creación de los clasificadores	59
3.4.4. Creación de Redes Neuronales	60
3.5. DESARROLLO DEL PROTOTIPO	62
3.5.1. Casos de uso y descripción	62
3.5.2. Diagramas de secuencia.....	76
3.5.3. Diagrama de clases	81
3.5.4. Diagrama de base de datos «labfitopatología»	82
3.5.5. Mapa de pantallas.....	83
3.5.6. Interfaces	84
3.5.7. Aplicación de Técnicas de Visión Artificial	89
3.5.8. Entrenamiento de los Clasificadores implementados.....	92
3.5.9. Entrenamiento de las redes neuronales implementadas	95
3.6. INSTALACIÓN	99
3.7. MANTENIMIENTO	99
CAPÍTULO 4	101
VALIDACIÓN Y RESULTADOS	101
4.1. RESULTADOS DE LOS CLASIFICADORES IMPLEMENTADOS	101
4.1.1. Clasificador Vecinos más cercanos	101
4.1.2. Clasificador Random Forest.....	102
4.1.3. Comparación Clasificadores	102
4.2. RESULTADOS DE LAS REDES NEURONALES IMPLEMENTADAS	103

4.2.1. Red Neuronal Convolutacional	103
4.2.2. Comparación entre Redes Neuronales	106
4.2.3. Comparativa entre Red Neuronal Convolutacional y procedimiento actual ...	107
4.3. RESULTADOS DEL MÓDULO DE MORFOMETRÍA	108
4.3.1. Procedimiento de morfometría en el cellSens.....	109
4.3.2. Procedimiento de morfometría realizado con el prototipo del sistema desarrollado	112
4.3.3. Comparativa de los resultados obtenidos entre cellSens y SDM.....	116
4.3.4. Comparación de tiempos en el módulo de Morfometría.....	119
CAPÍTULO 5	121
CONCLUSIONES Y RECOMENDACIONES	121
5.1. CONCLUSIONES	121
5.2. RECOMENDACIONES	122
REFERENCIAS BIBLIOGRÁFICAS	124
ANEXOS	132

ÍNDICE DE TABLAS

Tabla 1 <i>Diferencias entre un Sistema Experto y un Experto Humano</i>	12
Tabla 2 <i>Clasificación de los Sistemas Expertos de acuerdo al tipo de función que desempeñan</i>	13
Tabla 3 <i>Descripción de una neurona artificial</i>	22
Tabla 4 <i>Características de la planta de maíz</i>	45
Tabla 5 <i>Detalle de tareas realizadas por el experto</i>	54
Tabla 6 <i>Descripción del caso de uso «Gestión usuario»</i>	63
Tabla 7 <i>Descripción del caso de uso «Consultar perfil»</i>	64
Tabla 8 <i>Descripción del caso de uso «Crear perfil»</i>	64
Tabla 9 <i>Descripción del caso de uso «Editar perfil»</i>	65
Tabla 10 <i>Descripción del caso de uso «Eliminar perfil»</i>	65
Tabla 11 <i>Descripción del caso de uso «Consultar usuario»</i>	66
Tabla 12 <i>Descripción del caso de uso «Crear usuario»</i>	66
Tabla 13 <i>Descripción del caso de uso «Editar usuario»</i>	67
Tabla 14 <i>Descripción del caso de uso «Eliminar usuario»</i>	67
Tabla 15 <i>Descripción del caso de uso «Consultar reportes»</i>	68
Tabla 16 <i>Descripción del caso de uso «Eliminar reporte»</i>	69
Tabla 17 <i>Descripción del caso de uso «Crear reporte»</i>	69
Tabla 18 <i>Descripción del caso de uso «Consultar microorganismo»</i>	70
Tabla 19 <i>Descripción del caso de uso «Crear microorganismo»</i>	71
Tabla 20 <i>Descripción del caso de uso «Editar microorganismo»</i>	71
Tabla 21 <i>Descripción del caso de uso «Eliminar microorganismo»</i>	72
Tabla 22 <i>Descripción del caso de uso «Capturar imagen»</i>	73
Tabla 23 <i>Descripción del caso de uso «Medir»</i>	74
Tabla 24 <i>Descripción del caso de uso «Editar imagen»</i>	75
Tabla 25 <i>Descripción del caso de uso «Clasificación»</i>	75
Tabla 26 <i>Porcentaje de éxito en la clasificación</i>	105
Tabla 27 <i>Datos del microorganismo Ustilago maydis obtenidos con cellSens y SDM</i>	117

Tabla 28 *Comparación de tiempos del análisis morfométrico entre cellSens y SDM.. 119*

ÍNDICE DE FIGURAS

Figura 1. Esquema general de un SBC	11
Figura 2. Arquitectura de un sistema experto	15
Figura 3. Paradigma de construcción de visto desde el punto de tareas realizadas por el ingeniero de conocimiento	16
Figura 4. Interacción de usuarios con expertos en las fases de desarrollo	17
Figura 5. Fases de desarrollo de un sistema experto	18
Figura 6. Partes de una neurona biológica	20
Figura 7. Representación de una neurona artificial tipo McCulloch-Pitts	21
Figura 8. Tipos de funciones de activación	23
Figura 9. Red Neuronal Monocapa	24
Figura 10. Red Neuronal Multicapa	25
Figura 11. Perceptrón simple y función de transferencia de su neurona	26
Figura 12. Esquema básico de una red neuronal convolucional	28
Figura 13. Arquitectura general de una CNN	29
Figura 14. Ejemplo de imagen aplicada distintos filtros	30
Figura 15. Descripción del proceso de convolución	31
Figura 16. Descripción grafica de la capa de pooling	32
Figura 17. Operación de max-pooling y de average-pooling	32
Figura 18. Ejemplo del esquema de la red convolucional	33
Figura 19. Las funciones de activación más comunes, función de activación ReLU y Sigmoid	34
Figura 20. Ejemplo de vecino más cercanos con tres clases	35
Figura 21. Ejemplo Clasificador Random Forest (Data Iris)	36
Figura 22. Funcionamiento del algoritmo Random Forest	37
Figura 23. Etapas de un sistema de visión artificial	38
Figura 24. Puntos anatómicos de referencia	41
Figura 25. Estructuras características de diversos hongos fitopatógenos	43
Figura 26. Partes que conforman una planta de maíz	44

Figura 27. Clasificación de las principales enfermedades del maíz de acuerdo al momento de aparición en el cultivo y el órgano afectado	46
Figura 28. Microfotografías del hongo <i>Curvularia</i> : A-B: conidióforos y conidios; C.D.E.: disposición de los conidios en el conidióforo; F: conidios; G.H.: conidios germinando (C = 400x; los demás: 100x)	47
Figura 29. Hoja de maíz infectada por el hongo <i>Curvularia</i> en el campo	48
Figura 30. Mazorca infectada por el hongo <i>Ustilago maydis</i>	49
Figura 31. Esporas del hongo <i>Ustilago maydis</i> a 400x	49
Figura 32. Hoja infectada por <i>Helminthosporium maydis</i>	50
Figura 33. Microfotografías de <i>Helminthosporium maydis</i> (A y B: conidióforos. C y D: conidios (A.B.C. = 100x; D = 400 X). E: conidióforos y conidios	50
Figura 34. Fases de desarrollo de un Sistema Basado en Conocimiento (SBC)	52
Figura 35. Mapa de tareas para llevar a cabo la clasificación de hongos	55
Figura 36. Modelo conceptual microorganismo	56
Figura 37. Regla para la clasificación del microorganismo “ <i>Helminthosporium maydis</i> ”	57
Figura 38. Regla para la clasificación del microorganismo “ <i>Curvularia lunata</i> ”	57
Figura 39. Regla para la clasificación del microorganismo “ <i>Ustilago maydis</i> ”	58
Figura 40. Diagrama de arquitectura del Sistema de Diagnóstico Micológico SDM	58
Figura 41. Representación gráfica algoritmo Vecinos más cercanos con una métrica igual a 9	59
Figura 42. Estructura del clasificador Random Forest	60
Figura 43. Estructura del Perceptrón Simple implementado	61
Figura 44. Estructura de la red neuronal convolucional	61
Figura 45. Diagrama general de casos de uso	62
Figura 46. Diagrama de casos de uso «Gestión Usuario»	63
Figura 47. Diagrama de casos de uso «Gestión Reportes»	68
Figura 48. Diagrama de casos de uso «Gestión Microorganismo»	70
Figura 49. Diagrama de casos de uso «Medición»	72
Figura 50. Diagrama de casos de uso «Clasificación»	75
Figura 51. Diagrama de secuencia «Gestión de Usuarios»	76

Figura 52. Diagrama de secuencia «Gestión de microorganismos».....	77
Figura 53. Diagrama de secuencia «Gestión de reportes».....	77
Figura 54. Diagrama de secuencia «Realizar medición».....	78
Figura 55. Diagrama de secuencia «generar reporte»	79
Figura 56. Diagrama de secuencia «Clasificar microfotografía».....	80
Figura 57. Diagrama de clases	81
Figura 58. Modelo de la base de datos «labfitopatología».....	82
Figura 59. Navegabilidad de interfaces	83
Figura 60. Ventana de inicio de sesión.....	84
Figura 61. Ventana principal.....	84
Figura 62. Ventana de carga de imágenes.....	85
Figura 63. Ventana de reportes	85
Figura 64. Ventana de previsualización de reportes.....	86
Figura 65. Ventana de almacenamiento de reportes	86
Figura 66. Ventana de gestión de reportes.....	87
Figura 67. Ventana de gestión de usuarios	88
Figura 68. Ventana de gestión de microorganismos.....	89
Figura 69. Histograma de imagen a color.....	90
Figura 70. Histograma aplicado un factor de 0.50	91
Figura 71. Histograma aplicado un factor de 2.08	91
Figura 72. Estructura de una parte de la data.....	92
Figura 73. Gráfica de los microorganismos de la planta de maíz	93
Figura 74. Gráfica de exactitud de clasificación aplicando el algoritmo de vecinos más cercanos	94
Figura 75. Parte de la data con la que se entrenó el clasificador Random Forest.....	95
Figura 76. Porcentaje exactitud de Random Forest.....	95
Figura 77. Parte de la data con la que se entrenó el Perceptrón Simple.....	96
Figura 78. Entrenamiento Perceptrón Simple	96
Figura 79. Error en la Clasificación usando el Perceptrón Simple.....	97
Figura 80. Porcentaje de error del Perceptrón Simple.....	97

Figura 81. Descripción del porcentaje de precisión en el entrenamiento durante el entrenamiento.....	98
Figura 82. Gráfica de la precisión de la predicción en cada época.....	98
Figura 83. Gráfica del porcentaje de error que se obtuvo durante el entrenamiento de la red neuronal convolucional.....	99
Figura 84. Clasificador aplicando el algoritmo de Vecinos más cercanos	101
Figura 85. Clasificador aplicando el algoritmo Random forest.....	102
Figura 86. Porcentaje de presión de la clasificación.....	103
Figura 87. Parte de la muestra con las que se realizó las pruebas y validaciones de la red convolucional.....	104
Figura 88. Porcentaje de éxito en la clasificación por microorganismo	105
Figura 89. Porcentaje de éxito en la clasificación total de los microorganismos.....	106
Figura 90. Comparativa de porcentajes de éxito en la clasificación entre las redes neuronales.....	107
Figura 91. Comparativa del tiempo de clasificación entre la red neuronal y el procedimiento manual	108
Figura 92. Microscopio BX43 y software cellSens	109
Figura 93. Fotografía realizada durante el proceso de mediciones realizadas con cellSens	110
Figura 94. Hoja electrónica exportada por cellSens	110
Figura 95. Reporte en Excel elaborado por el experto	112
Figura 96. Sistema SDM.....	113
Figura 97. Mediciones morfométricas realizadas en SDM.....	114
Figura 98. Cuadro de diálogo del clasificador.....	114
Figura 99. Elaboración del informe de análisis en SDM	115
Figura 100. Reporte en PDF generado por SDM.....	116
Figura 101. Datos del microorganismo Ustilago maydis obtenidos con cellSens y SDM	118
Figura 102. Comparativa desviación estándar entre CellSens y SDM	118

Figura 103. Comparación de tiempos del análisis morfométrico entre cellSens y SDM

..... 119

RESUMEN

El gran desarrollo que han tenido las Redes Neuronales Artificiales (RNA) en los últimos años ha causado un enorme impacto en las diversas áreas del conocimiento, incluyendo la Biología. Las RNA pueden ser entrenadas para aprender a clasificar patrones en imágenes, con distintos propósitos. El presente proyecto de titulación tiene como objetivo desarrollar un sistema capaz de reconocer 3 tipos de hongos presentes en plantas de maíz, mediante el uso de microfotografías. El sistema está basado en Morfometría y en el uso de algoritmos de Redes Neuronales Profundas (Deep Neural Networks) con lo que se ha logrado el aprendizaje de patrones a partir de un conjunto de imágenes. Las imágenes utilizadas para el entrenamiento de la red neuronal fueron obtenidas del laboratorio de Fitopatología de la Agencia de Regulación y Control Fito y Zoosanitario - AGROCALIDAD, institución pública adscrita al Ministerio de Agricultura y Ganadería. Dichas imágenes pertenecen a 3 plagas que afectan al maíz: *Curvularia lunata*, *Ustilago maydis*, y *Helminthosporium maydis*. El módulo de Morfometría implementado permite procesar la imagen y realizar las mediciones de las plagas en cada muestra. Las mediciones se alojan en la base de conocimiento y las imágenes tratadas se guardan dentro del corpus de imágenes para su aprendizaje. Fueron implementados 4 tipos de algoritmos, 2 de Clasificación y 2 tipos de RNA, de los cuales para el módulo de Morfometría se obtuvieron mejores resultados con el algoritmo Random Forest, ya que obtuvo un margen de confiabilidad de 99 % y para el módulo de Diagnostico se obtuvo un mejor aprendizaje con la Red Neuronal Convolutiva, ya que los resultados logrados tuvieron un margen de confiabilidad del 98 %.

PALABRAS CLAVE:

- **MORFOMETRÍA**
- **REDES NEURONALES CONVOLUCIONALES**
- **CLASIFICADORES**
- **PLAGAS DEL MAÍZ**

ABSTRACT

The great development that Artificial Neural Networks (ANNs) have had in recent years has caused a huge impact on different areas of knowledge, including Biology. ANNs can be trained to learn to classify patterns in images, with different purposes. This project aims to develop a system capable of recognizing 3 types of fungi present on corn plants, through microphotographs. The system is based on Morphometry and on the use of deep neural networks algorithms, with which a learning of patterns from a set of images has been achieved. The images used for training of the neural network were obtained from the Laboratory of Phytopathology at the Phyto- and Zoosanitary Regulation and Control Agency (Agencia de Regulación y Control Fito y Zoosanitario) – Agrocalidad, public institution attached to the Ministry of Agriculture and Livestock (Ministerio de Agricultura y Ganadería). These images belong to 3 pests that affect corn: *Curvularia lunata*, *Ustilago maydis* and *Helminthosporium maydis*. The implemented morphometry module allows to process the image and to take pest measurements on each sample. Measurements are stored in the knowledge base and the treated images are stored in the images corpus for its learning. Four types of algorithms were implemented, two of classification and two types of ANNs, of which, for the morphometry module the best results were obtained with the Random Forest algorithm, with a 99% reliability margin, and for the diagnosis module the best learning was obtained with the Convolutional Neural Network, the results achieved had a 98% reliability margin.

KEYWORDS:

- **MORPHOMETRY**
- **CONVOLUTIONAL NEURAL NETWORKS**
- **CLASSIFIERS**
- **CORN DISEASES**

CAPÍTULO 1

INTRODUCCIÓN

1.1. Antecedentes

El maíz estuvo presente en las antiguas civilizaciones de América desde los olmecas y teotihuacanos en Mesoamérica, hasta los incas y quechuas en la región andina de Sudamérica por lo que se considera como el cereal de los pueblos y culturas del continente americano (Serratos, 2009). El maíz es el alimento más cosechado en América debido a que es una planta muy versátil, se puede sembrar en diferentes entornos, brinda mayor rendimiento que otros granos, por lo que se ha convertido en un cereal altamente valorado (Bembibre, 2011).

En el Ecuador existen 31 razas catalogadas de maíz, lo que le convierte en uno de los productos agrícolas más importantes de la economía del país (Serratos, 2009). El maíz se cultiva en diferentes ecosistemas, desde las zonas tropicales en la costa, hasta las zonas andinas de la sierra. Dichos cultivos suelen ser afectados por diversas enfermedades y plagas que afectan a la cosecha y postcosecha.

La calidad del maíz es muy importante ya que es materia prima de una infinidad de productos derivados como el forraje, la producción de alimentos procesados como por ejemplo el balanceado que está destinado para la industria animal y recientemente para la producción de Etanol (Standar 153-1985, 2018).

La Agencia de Regulación y Control Fito y Zoonosanitario - AGROCALIDAD, institución pública adscrita al Ministerio de Agricultura y Ganadería, es la encargada de mantener y mejorar el estatus sanitario de los productos agropecuarios del país, con el objetivo de precautelar la inocuidad en la producción primaria, contribuyendo a alcanzar la soberanía alimentaria, mejorando los flujos comerciales y apoyando el cambio de la matriz productiva del país (Agrocalidad, 2018).

Para el cumplimiento de sus objetivos Agrocalidad cuenta con laboratorios que permiten el proceso de análisis y diagnóstico de muestras para la detección oportuna

de enfermedades veterinarias, plagas y contaminantes en productos agropecuarios, así como también verificando la calidad de los insumos. Los servicios se gestionan para todo el sector agropecuario del Ecuador.

Las actividades de control Fito y Zoosanitarias son ejercidas por las direcciones de Sanidad Animal, Sanidad Vegetal e Inocuidad de alimentos. Dentro del Área de Diagnóstico vegetal, se encuentra el Laboratorio de Fitopatología, responsable del análisis de material vegetal, suelo, agua y biol dentro de la actividad agrícola con la finalidad de identificar los principales agentes fitopatógenos que influyen en la producción nacional. Estos análisis se realizan por medio de metodologías en constante actualización como morfología, morfometría, aislamiento en medios de cultivo y biología molecular, mismos que están enmarcados en normas nacionales e internacionales de calidad (Agrocalidad, 2018).

1.2. Planteamiento del problema

En la actualidad el Laboratorio de Fitopatología de Agrocalidad recibe una gran cantidad de muestras para que se realicen distintos tipos de análisis como morfometría, pruebas bioquímicas, entre otros, con el fin de que se determine género/especie de los hongos fitopatógenos que afectan a los principales cultivos del país, como *Zea mays* o maíz.

Para la realización de los diagnósticos morfométricos, el laboratorio cuenta con un microscopio Olympus BX43, y un software propietario de alto costo llamado “cellSens”, que por motivos de licenciamiento y sus costos, se ejecuta en una sola computadora asignada a dicho microscopio, limitando el tiempo de procesamiento y obtención de resultados.

Existen otros microscopios con cámaras en el laboratorio, los cuales son utilizados únicamente para la toma de fotografías de los microorganismos, dichas fotografías no pueden ser importadas al software “cellSens”. Para realizar el procesamiento de las muestras y las mediciones morfométricas se deben fotografiar nuevamente con el microscopio BX43.

El “cellSens” exporta las mediciones realizadas a una hoja de cálculo de Excel que la presenta de acuerdo con el orden en que se las fue realizando. A partir de los datos del archivo de Excel se realizan cálculos estadísticos, para lo cual el laboratorista copia manualmente las mediciones a un nuevo archivo, que contiene fórmulas para determinar promedio, desviación estándar, entre otras.

Para la elaboración del informe de análisis, los laboratoristas buscan manualmente la información morfométrica en papers o en compendios publicados por APS (American Phytopathological Society) Press. Se compara esta información con las observaciones realizadas a través del microscopio Olympus y con sus mediciones registradas.

Debido a que el software cellSens no permite realizar el diagnóstico clínico, el análisis que hace el experto toma mucho tiempo debido a que se lo realiza de forma manual. El proceso se basa en su experiencia y en la comparación de los datos observados y obtenidos con los que han sido publicados en artículos científicos. Luego de lo cual emite un criterio diagnóstico que confirma o descarta la existencia o no del microorganismo causante de la plaga.

Con el criterio y la conclusión del experto se crea un informe de análisis para entregar al cliente y es almacenado como evidencia del trabajo del laboratorio.

Además, no se dispone de una base de datos en la que se almacene y se actualice automáticamente toda la información, por lo que los reportes deben ser respaldados manualmente mediante copias de los archivos.

1.3. Justificación

Realizar en el momento oportuno la detección y el diagnóstico de las enfermedades o plagas en las plantas, juega un papel importante en el control y la prevención eficaz de enfermedades para lograr una agricultura sostenible y seguridad alimentaria de calidad (Pawar, Turkar, & Patil, 2016).

La prevención de enfermedades en las cosechas de maíz es muy significativa, ya que una enfermedad en dicha planta reduce considerablemente la calidad y cantidad

del producto, lo que representa pérdidas en el sector agrario. Por lo tanto, es necesario llevar a cabo procesos de diagnóstico y detección temprana de la calidad de la planta del maíz y entregar los reportes del análisis de resultados en el menor tiempo posible.

Con el desarrollo de un sistema basado en conocimiento y en aprendizaje automático, se pretende contribuir al procesamiento ágil de las imágenes microscópicas de los microorganismos en las plantas del maíz. Además, se desarrollará una red neuronal artificial que imite el proceso de aprendizaje para brindar un posterior diagnóstico fitopatológico que permita imitar y mejorar los tiempos del diagnóstico que el técnico humano realiza. El sistema será experto en el diagnóstico fitopatológico a partir de mediciones morfométricas y microfotografías.

Además, dicho sistema permitirá que los técnicos del laboratorio de Agrocalidad no ejecuten procesos de forma manual, que disminuyan los tiempos en la entrega de reportes del análisis de calidad de la planta y puedan tomar de acciones oportunas.

1.4. Objetivos

1.4.1. Objetivo General

Desarrollar un sistema basado en redes neuronales artificiales para el diagnóstico fitopatológico de plagas del maíz a partir de mediciones morfométricas en microfotografías.

1.4.2. Objetivos Específicos

- i. Desarrollar una aplicación que permita automatizar el proceso de medición y registro de medidas morfométricas de las plagas del maíz.
- ii. Crear una base de conocimiento a partir de las microfotografías que se dispone en el Laboratorio de Fitopatología de Agrocalidad.
- iii. Crear la red neuronal artificial para aprendizaje y reconocimiento de patrones de las plagas en plantas del maíz.

- iv. Realizar validaciones que permitan comprobar la confiabilidad del diagnóstico automático mediante la comparación de resultados de detección de plagas e informes manuales que realiza el experto.

1.5. Alcance

El proyecto plantea el desarrollo de un sistema para el diagnóstico micológico de plagas en plantas de maíz. Todo el conocimiento y base científica conocida sobre la morfología de las plagas que afectan al maíz serán registradas en el motor de inferencia del sistema. Para el aprendizaje automático se implementarán cuatro algoritmos, dos de clasificación y dos tipos de redes neuronales. Se realizarán las pruebas de casos mediante un protocolo establecido que permita comprobar qué algoritmo aprende mejor dicho proceso. El sistema será experto en el diagnóstico micológico a partir de mediciones morfométricas y microfotografías. En este proyecto se analizarán únicamente tres de las plagas más comunes que afectan a los cultivos del maíz en nuestro medio y que son: *Curvularia lunata*, *Ustilago maydis*, y *Helmintosporium maydis*.

El sistema constará de los siguientes componentes:

- Un módulo de Morfometría que permitirá automatizar el proceso de medición y registro de las medidas morfométricas de los microorganismos en las plantas de maíz.
- Una base de conocimiento creada con microfotografías de tres de las plagas más comunes que afectan al maíz.
- Una red neuronal artificial que realizará el aprendizaje automático para reconocer patrones de las plagas en plantas de maíz.

Finalmente, el sistema permitirá emitir un reporte en base al análisis de las mediciones morfométricas realizadas y a la información especializada pertinente a los microorganismos analizados, con la finalidad de aplicar medidas preventivas, de control y manejo de problemas fitosanitarios.

1.6. Hipótesis

La implementación del sistema en el Laboratorio de Fitopatología de Agrocalidad disminuirá el tiempo de obtención del diagnóstico de plagas que afectan al maíz.

CAPÍTULO 2

MARCO TEÓRICO

2.1. Inteligencia Artificial

2.1.1. Definición

Existen varias definiciones de Inteligencia Artificial (IA), en este espacio mencionaremos dos que nos permiten explicar sobre esta ciencia y el contexto en el que se desarrolla.

"... automatización de actividades que asociamos con el pensamiento humano, actividades como la toma de decisiones, la resolución de problemas, el aprendizaje, etc." (Bellman, 1978).

"... ciencia que realiza combinaciones de algoritmos con el propósito de crear máquinas que presenten las mismas capacidades del ser humano que requieren inteligencia" (Escolano, F., Cazorla, M. A., Alfonso, M. I., Colomina, O., & Lozano, 2003).

En este contexto la IA permite desarrollar soluciones a problemas complejos y reales en diversos campos que requieren un alto costo computacional. Estos problemas van desde el diseño de asistentes personales, traductores, vehículos autónomos, hasta sistemas de recomendaciones de productos multimedia y compras en línea, entre otros (Adams, 2017).

2.1.2. Tipos de Inteligencia Artificial

Según (Norvig, P., & Russell, 2013) expertos en ciencias de la computación diferencian varios tipos de inteligencia artificial:

- **Sistemas que piensan como humanos:** Estos sistemas tratan de automatizar actividades como la toma de decisiones, la resolución de problemas y el aprendizaje. Ejemplo: Redes Neuronales Artificiales.
- **Sistemas que actúan como humanos:** Se trata de máquinas o computadoras con la capacidad de realizar tareas de forma similar a como lo hacen los humanos. Ejemplo: los robots.
- **Sistemas que piensan racionalmente:** Sistemas que intentan emular el pensamiento lógico racional de los humanos, es decir, se investiga cómo lograr que las máquinas puedan percibir, razonar y actuar en consecuencia. Los sistemas expertos se engloban en este grupo.
- **Sistemas que actúan racionalmente:** Sistemas que tratan de imitar de manera racional el comportamiento humano, como los agentes inteligentes.

2.1.3. Técnicas de la Inteligencia Artificial

Existen varias áreas y técnicas en las que se apoya el desarrollo de la IA:

- Aprendizaje Automático
- Procesamiento del Lenguaje Natural
- Minería de Datos
- Visión por Computador
- Sistemas Basados en Conocimiento
- Algoritmos de Búsqueda
- Redes Neuronales
- Sistemas Difusos
- Sistemas de Simulación
- Robótica

Estas técnicas pueden combinarse para dar una solución más adecuada al problema planteado.

2.2. Ingeniería del Conocimiento

La Ingeniería del Conocimiento se define como el subcampo de la Inteligencia Artificial relativo a la “adquisición, representación y aplicación del conocimiento, o como la disciplina de ingeniería por la cual el conocimiento se integra dentro de un sistema de computador para resolver problemas complejos que normalmente requieren un alto nivel de experiencia humana” (Maté & Pazos, 1988).

Tiene como objetivo adquirir, formalizar, codificar y estructurar en la computadora el saber de los expertos humanos, de modo que pueda ser procesado eficientemente por la misma (L. Álvarez, 1994).

La Ingeniería del Conocimiento comprende tres procesos esenciales:

1. Adquisición del conocimiento: consiste en extraer el conocimiento de las partes o fuentes en las que se encuentra almacenado. Estas pueden ser de dos tipos:
 - a. Estáticas o secundarias: comprenden aquellas con un contenido invariable o fijo, como libros y artículos.
 - b. Dinámicas o primarias: comprenden aquellas con un contenido variable, inexacto y que se basa en la experiencia, como el experto humano.

La meta de este proceso es entender cómo una persona realiza una actividad, de manera que esta pueda ser automatizada (Scott, Calyton, & Gibson, 1991).

2. Representación del conocimiento: consiste en tomar el conocimiento que se extrajo de las fuentes estáticas y dinámicas y llevarlo a una forma que sea entendible para quienes lo vayan a utilizar. Este proceso se realiza en paralelo al de adquisición de conocimiento. Al inicio el conocimiento debe representarse en papel, al hacer la documentación. Posteriormente, se lo lleva a la computadora.

Manipulación/validación del conocimiento: consiste en validar que el conocimiento que ha sido adquirido y representado en los dos procesos anteriores, sea igual al

conocimiento que ha sido proporcionado por el experto. Para ello, se somete el conocimiento del sistema a pruebas con casos reales.

2.3. Sistemas Basados en Conocimiento

Un sistema basado en conocimiento (SBC) es un programa informático capaz de consultar una base de conocimientos, que contiene información almacenada sobre un dominio específico y que es generalmente proporcionada por un experto, con el propósito de sacar conclusiones mediante deducción, es decir, aplicando reglas de inferencia (Fernández, 2002).

Los SBC se diferencian de los programas convencionales en que el conocimiento se encuentra separado del razonamiento, siendo responsable de este último el denominado motor de inferencia. Este razona sobre posibles soluciones para el problema planteado, y emite una conclusión razonable comparable al pensamiento de un humano (Proaño, Saguay, Jácome, & Sandoval, 2017).

Los principales elementos que componen un sistema basado en conocimiento son los siguientes:

- Base de conocimiento: contiene conocimiento almacenado sobre un determinado dominio, y representado en un determinado lenguaje formal, como por ejemplo conjuntos de reglas y afirmaciones sobre hechos conocidos (Fernández, 2002).
- Motor de inferencia: saca conclusiones a partir de los datos proporcionados por el usuario del sistema, mediante la aplicación de algoritmos o reglas.
- Interfaz de usuario: permite la interacción entre el sistema y el usuario.
- Interfaz de entrenamiento: también denominada interfaz de aprendizaje, no se encuentra siempre presente en los SBC. Permite alimentar directamente la base de conocimiento con instrucciones propias de los expertos o de retroalimentación de las salidas del sistema (Proaño et al., 2017).

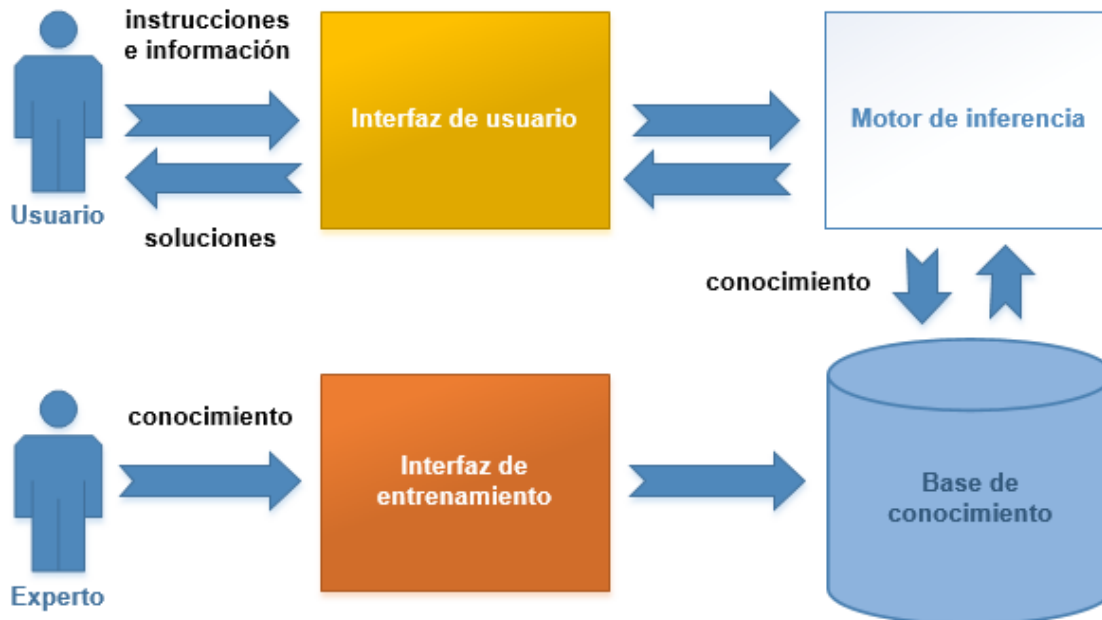


Figura 1. Esquema general de un SBC
Fuente: (Proaño et al., 2017)

2.4. Sistemas Expertos

De acuerdo con (Padilla, 2012) un Sistema Experto “es un sistema informático de hardware y/o software que se asemeja a los expertos humanos en la resolución de problemas que requieren la aplicación de la inteligencia humana en un dominio específico”.

Un sistema experto almacena datos y conocimiento, infiere conclusiones lógicas, es capaz de “tomar decisiones, aprender, comunicarse con expertos humanos o con otros Sistemas Expertos, explicar el razonamiento de su decisión y realizar acciones como consecuencia” (Quintanar, 2007).

Según (Padilla, 2012), es recomendable usar sistemas expertos cuando los expertos humanos en determinada área son escasos; en situaciones bastante complejas donde la subjetividad de la persona pueda llevar a conclusiones erradas; cuando la cantidad de datos considerados para llegar a una conclusión sea enorme; y cuando las conclusiones se obtienen mediante la aplicación de

reglas.

Un experto es una persona que ha dedicado una gran cantidad de tiempo a adquirir conocimientos de una determinada disciplina y ha llegado a dominarla lo suficiente, de modo que ante el surgimiento de un problema concreto puede aplicar sus conocimientos para encontrar una solución adecuada.

El problema con los expertos humanos es “su escaso número, su disponibilidad, el pago de remuneraciones, y por supuesto su calidad de mortales, que implica a la larga la pérdida total de la destreza adquirida” (Arenas, Canessa, Castro, & Peinado, 1987).

De ahí surge la necesidad de poner todos esos conocimientos en una computadora, de manera que se pueda trabajar con ellos sin los inconvenientes mencionados que están asociados a los expertos humanos.

Tabla 1

Diferencias entre un Sistema Experto y un Experto Humano

	Sistema Experto	Experto Humano
Conocimiento	Adquirido	Adquirido + innato
Adquisición del conocimiento	Teórico	Teórico + práctico
Campo	Único	Múltiples
Explicación	Siempre	A veces
Limitación de capacidad	Sí	Sí, no evaluable
Reproducible	Sí, idéntico	No
Vida	Infinita	Finita

Fuente: (Quintanar, 2007)

Algunas de las áreas donde se utilizan actualmente sistemas expertos son:

- Localización de problemas en las redes telefónicas.
- Análisis de la estructura del ácido desoxirribonucleico (ADN).
- Clasificación de objetivos a partir de imágenes.
- Pronóstico del tiempo.
- Regulación del tránsito vehicular.

2.4.1. Clasificación de los Sistemas Expertos

Una primera clasificación de los sistemas expertos es por la naturaleza del problema que van a resolver:

- **Deterministas:** están basados en reglas. Se basan en un conjunto de reglas para sacar sus conclusiones, mediante el razonamiento lógico.
- **Estocásticos:** están basados en la probabilidad. Sacan sus conclusiones utilizando fórmulas de la teoría de la probabilidad.

Una segunda clasificación de los sistemas expertos es por el tipo de función que desempeñan:

Tabla 2

Clasificación de los Sistemas Expertos de acuerdo al tipo de función que desempeñan

Tipo de función	Descripción	Ejemplo
Interpretación	Infiere la situación actual a partir de un conjunto de datos	Análisis de imágenes
Predicción	Infiere las consecuencias de situaciones dadas	Pronósticos del clima
Diagnóstico	Infiere el mal funcionamiento del sistema a partir de observaciones	Diagnóstico médico
Diseño	Configura objetos según restricciones establecidas	Diseño de circuitos
Planeación	Planifica acciones que cumplen una meta sin violar las restricciones establecidas	Problemas de planeación militar
Monitoreo	Compara lo observado con las expectativas	Monitoreo de tráfico aéreo
Depuración	Determina correcciones cuando diagnostica un mal funcionamiento del sistema	Depuración en editores de texto
Reparación	Ejecuta y desarrolla planes para corregir problemas diagnosticados	Mantenimiento de equipos de cómputo
Instrucción	Diagnostica las debilidades de un estudiante en un área del conocimiento y planifica un tutorial para reforzar esa área	Sistemas de instrucción en el dominio de matemáticas
Control	Modifica el comportamiento de un sistema interpretando ese comportamiento	Control de líneas de producción automatizadas
Instrucción inteligente asistida por computadora	Ayuda a capacitarse, al brindar pasos a seguir para solucionar problemas	Instrucción sobre lenguajes de programación

2.4.2. Características de los Sistemas Expertos

- Pueden solucionar problemas con datos incompletos e inciertos.

- Dan una alta calidad de respuesta, similar a la de un humano experto en esa disciplina.
- Proporcionan respuestas consistentes y confiables, ya que combinan el conocimiento de varios expertos humanos.
- Brindan respuestas rápidas en comparación con el experto humano.
- Pueden explicar qué hicieron y por qué lo hicieron.
- Su conocimiento puede ser fácilmente añadido, modificado o eliminado.
- Aprenden mediante la adición de reglas a la base de conocimiento.
- Hacen deducciones que producen nuevo conocimiento.

2.4.3. Estructura

No existe una estructura común para todos los sistemas expertos, sin embargo, los componentes básicos que conforman a la mayoría de ellos son los siguientes:

1. Base de Conocimientos

Almacena la información que fue extraída del experto humano en la especialidad. A esta información se la divide en fragmentos pequeños o reglas. Esta base es fácilmente actualizable, de modo que se pueden añadir nuevas reglas, eliminar reglas obsoletas y corregir reglas que contengan errores.

Para que el sistema experto proporcione buenas soluciones, la información de la base de conocimientos debe ser de alta calidad (sin reglas redundantes ni contradictorias) y cantidad (debe contener todas las reglas necesarias que permitan solucionar cualquier problema de la especialidad).

2. Motor de Inferencia

Es el núcleo del sistema experto. Con los datos proporcionados o hechos, recorre la base de conocimientos y obtiene así una solución.

El motor de inferencia puede trabajar de tres maneras:

- Encadenamiento hacia adelante: llamado también guiado por datos. El usuario ingresa los datos del problema y el sistema identifica el conjunto de

reglas que se pueden aplicar. A continuación, se aplican esas reglas a los datos para obtener la solución.

- Encadenamiento hacia atrás: llamado también guiado por objetivos. El sistema inicia con la solución que se desea obtener e identifica todas las reglas que permiten llegar a esa solución. Entonces esas reglas indican qué datos deben buscarse.
- Encadenamiento mixto: combina el encadenamiento hacia adelante con el encadenamiento hacia atrás.

3. Base de Hechos

Almacena la información del problema ingresada por el usuario, así como los datos y conclusiones intermedias generadas por el sistema durante la inferencia.

4. Interfaz de Usuario

Es a través de la cual el usuario explica el problema al sistema experto.

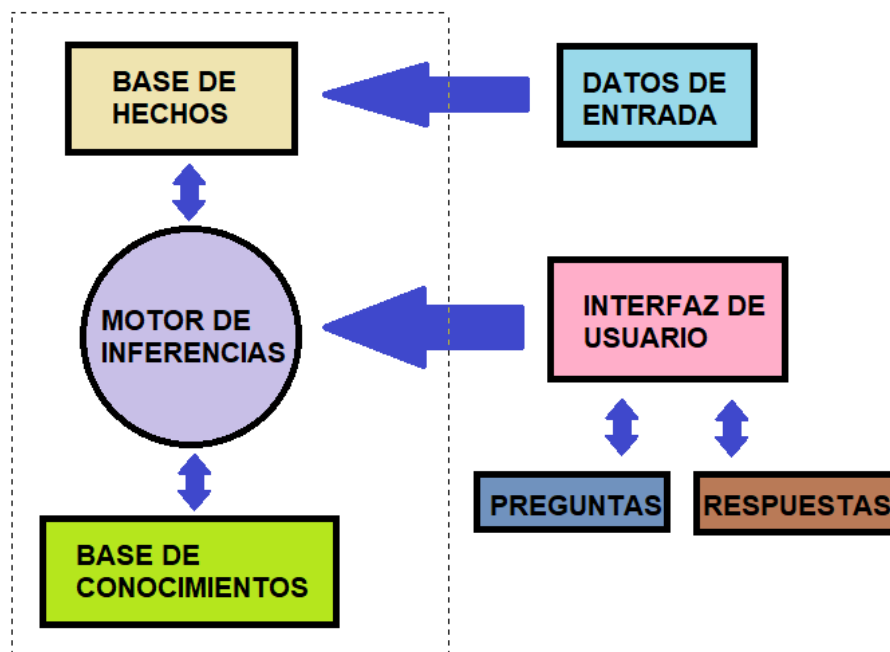


Figura 2. Arquitectura de un sistema experto

Fuente: (Arenaza, 2012)

2.5. Metodología

El modelo de prototipos o (prototipado rápido), permite construir rápidamente un sistema completo o algunos de sus módulos, con el objetivo de comprender, aclarar y modificar ciertos aspectos durante el desarrollo, en los que se asegure tener claro los requerimientos por parte de los usuarios y los desarrolladores, además de proponer una solución en respuesta de los requerimientos acordados, así lograr minimizar el riesgo y la incertidumbre en el desarrollo.

A continuación, en la figura 3 se muestra el paradigma de construcción de prototipos visto desde el punto de tareas realizadas por el ingeniero de conocimiento.

Entonces aparece un “diseño rápido” llamado prototipo.

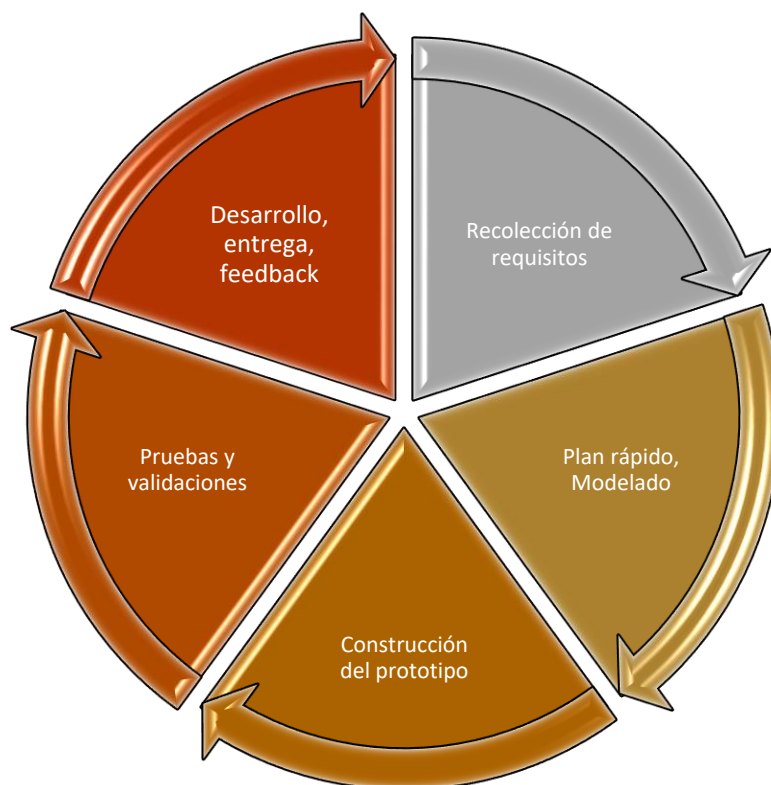


Figura 3. Paradigma de construcción de visto desde el punto de tareas realizadas por el ingeniero de conocimiento

Fuente: (Ramírez, 1999)

El prototipado es un modelo orientado a la implementación, es decir, que se tiene una inmediata presentación de un prototipo construido rápidamente en fases tempranas del desarrollo. Cada prototipo actúa como modelo para el siguiente y evoluciona en base a los conocimientos y experiencias adquiridas, hasta llegar a obtener el sistema deseado de acuerdo al dominio de aplicación.

Esta metodología resulta motivante y convincente para el experto. Por tanto, la aplicación de dicha metodología involucra una comunicación exhaustiva entre los expertos y el personal de desarrollo durante las primeras fases del desarrollo del sistema, como se muestra en la figura 4.

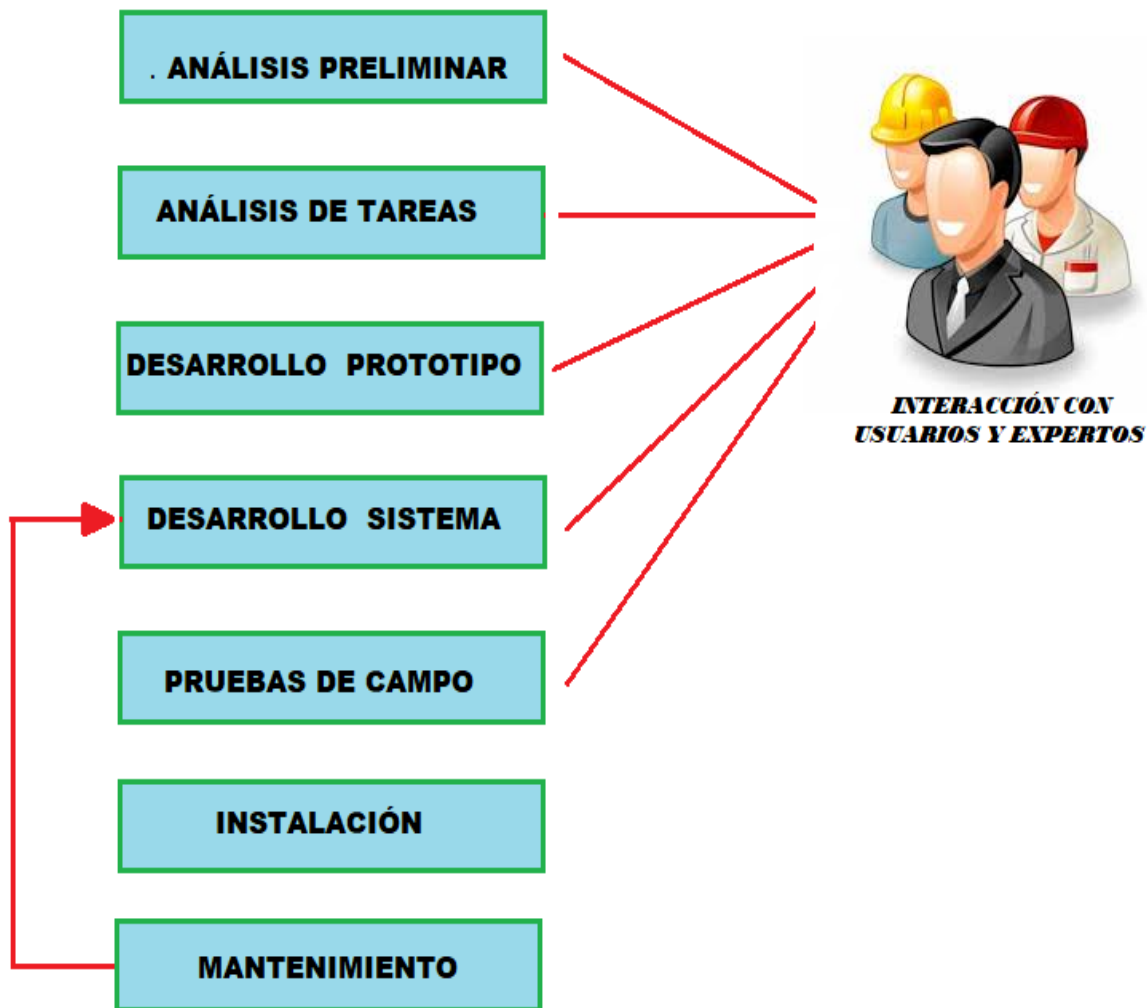


Figura 4. Interacción de usuarios con expertos en las fases de desarrollo
Fuente: (Ramírez, 1999)

En el siguiente mapa se detallan las particularidades de cada fase:



Figura 5. Fases de desarrollo de un sistema experto
Fuente: (Ramírez, 1999)

Ventajas

- Una de las principales ventajas de aplicar la metodología del prototipado es que el prototipo funcional evolutivo desarrolla un comportamiento que satisface los requisitos y necesidades del usuario.
- Una vez que se presenta el primer prototipado, se va modificando y desarrollando sobre la marcha, según las apreciaciones y acuerdos con el cliente.
- Disminuye el nivel de incertidumbre en el cliente respecto al desarrollo, ya que esta metodología requiere una participación activa del cliente.

2.6. Redes Neuronales

2.6.1. Redes Neuronales Biológicas

Dada a la amplia bibliografía sobre el funcionamiento de las redes neuronales biológicas, la mayoría de las personas que intentan entender y duplicar la funcionalidad de las redes neuronales se centran en algunas características de una neurona biológica.

A continuación, describiremos las características más importantes de una neurona biológica.

Una neurona biológica consiste en un cuerpo celular o soma, que tiene un núcleo celular, un axón y muchas dendritas.

El axón y las dendritas se ramifican a partir del cuerpo celular; las dendritas reciben señales de entradas de axones de otras neuronas mediante sinapsis de excitación o inhibición (Winston, 1994).




Figura 6. Partes de una neurona biológica
Fuente: (Bologna, 2018)

La función principal de una neurona biológica es la recogida, procesamiento y emisión de señales eléctricas, por lo cual se piensa que la capacidad de procesamiento de la información del cerebro proviene de redes de este tipo de neuronas (Norvig, P., & Russell, 2013).

Por esta razón algunos de los primeros trabajos de la Inteligencia Artificial pretendían crear redes neuronales artificiales, llevándonos al campo moderno de la neurociencia computacional, donde los investigadores de la Inteligencia Artificial y de estadística se interesaron en las propiedades abstractas de las redes neuronales, tales como su habilidad de desarrollar computación distribuida, para tolerar el ruido en la entrada y para el aprendizaje (Norvig, P., & Russell, 2013).

2.6.2 Redes Neuronales Artificiales

Las redes neuronales son un modelo computacional basado en un gran conjunto de unidades neuronales simples (neuronas artificiales), de forma aproximadamente análoga al comportamiento observado en los axones de las neuronas en el cerebro biológico (Gerven & Bohte, 2018).

Estas neuronas simuladas están muy interconectadas, al igual que las neuronas del cerebro y que son capaces de aprender de la misma forma que lo hacen las personas (Diez, Gómez, & de Abajo Martínez, 2001).

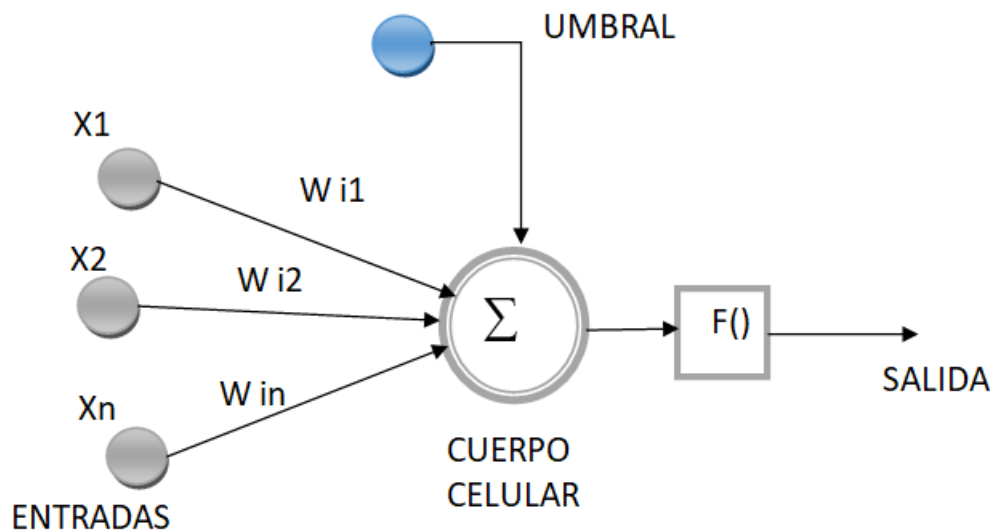


Figura 7. Representación de una neurona artificial tipo McCulloch-Pitts
Fuente: (Calvo, 2017)

La neurona simulada se ve como un nodo conectado con otros mediante enlaces, cada enlace está asociado a un peso.

El peso es semejante a la sinapsis, determina la naturaleza e intensidad de la influencia de un nodo sobre otro; donde un peso positivo grande corresponde a una excitación fuerte y un peso negativo pequeño corresponde a una inhibición débil.

Una función de activación es el resultado de la combinación de las influencias separadas de cada nodo, en una sola influencia global. Esta función de activación pasa la suma de los valores de entrada a través de una función de umbral para determinar la salida del nodo. La salida del nodo es 0 o 1, dependiendo de si la suma de las entradas está por debajo o por encima del valor de umbral utilizado por la función de umbral del nodo (Winston, 1994).

A continuación, se detalla la representación de la red neuronal.

Tabla 3

Descripción de una neurona artificial

Símbolo	Nombre	Descripción
X_n	Entradas	Reciben los datos de otras neuronas.
W_n	Peso Sináptico	A las entradas que vienen de otras neuronas se les asigna un peso. Este peso, que es un número, se modifica durante el entrenamiento de la red neuronal.
Σ	Regla de propagación	Es la sumatoria del valor de todas las entradas multiplicada por el valor de cada uno de los pesos.
$F()$	Función de Activación	El valor obtenido con la regla de propagación, se filtra a través de una función conocida como función de activación y es la que nos da la salida de la neurona, según para lo que se desee entrenar la red neuronal.

Fuente: (Ibiblio, 2018).

A continuación, se muestra los tipos de funciones de activación.

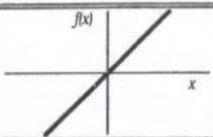
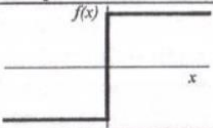
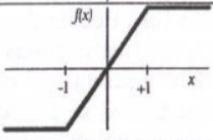
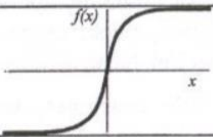
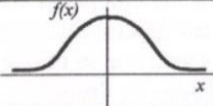
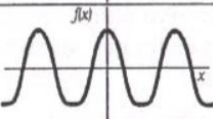
	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Figura 8. Tipos de funciones de activación
Fuente: (Ibiblio, 2018)

2.6.2.1. Estructura de las redes

Según los expertos Stuart Russell, Peter Norvig (2004), existen dos categorías principales de estructuras de redes neuronales: acíclicas o redes con alimentación hacia adelante y cíclicas o redes recurrentes.

- **Redes con alimentación hacia adelante (acíclicas):** representa una función de sus entradas actuales; de este modo, no tiene otro estado interno que no sea el de sus propios pesos.
- **Redes recurrentes (cíclicas):** permite que sus salidas alimenten sus propias entradas, lo que significa que los niveles de activación de la red forman un sistema dinámico que debe alcanzar un estado estable, exhibir oscilaciones o incluso un

comportamiento caótico. Por tanto, las redes recurrentes a diferencia de las redes acíclicas pueden tener memoria a corto plazo.

2.6.2.2. Clasificación de las redes neuronales según su topología

Redes Monocapa

Es la red neuronal más sencilla ya que se tiene una capa de neuronas que proyectan las entradas a una capa de neuronas de salida donde se realizan los diferentes cálculos (GrupoUS, 2018).

Para unirse estas redes crean conexiones laterales para conectarse con otras neuronas de su capa.

Entre las redes neuronales monocapa como muestra la figura 8, existen algunas que permiten que las neuronas tengan conexiones a sí mismas y se denominan autorecurrentes.




Figura 9. Red Neuronal Monocapa

Las redes más representativas son la red de Hopfield, la red BRAIN-STATE-IN-A-BOX o memoria asociativa y las máquinas estocásticas de Boltzmann y Cauchy (Redes Neuronales, 2018).

Redes Neuronales Multicapa

Es una generalización de la anterior, existiendo un conjunto de capas intermedias entre la capa de entrada y la de salida (capas ocultas). Este tipo de red puede estar total o parcialmente conectada (GrupoUS, 2018).

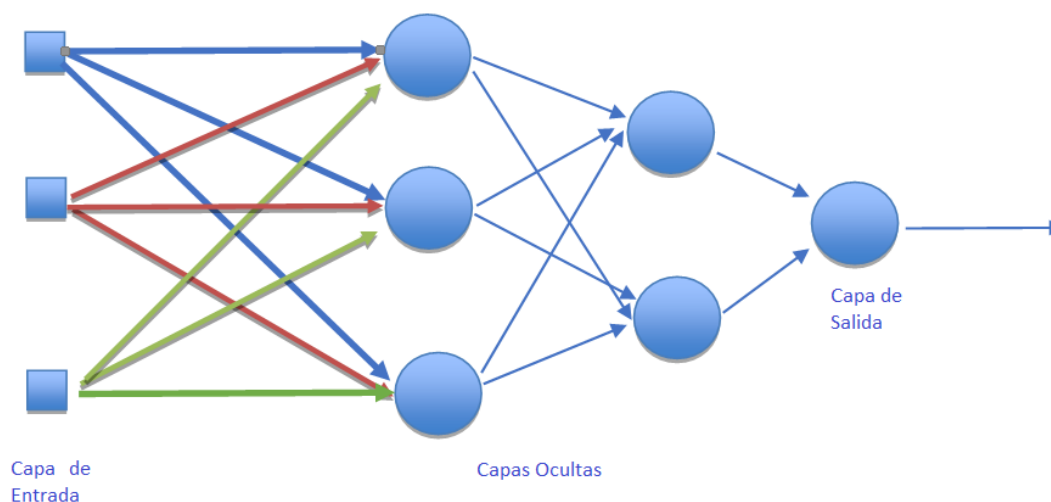


Figura 10. Red Neuronal Multicapa

Conexión feedforward (hacia adelante): Se da cuando las capas están ordenadas y reciben la señal desde la entrada hasta la salida.

Conexión feedback (retroalimentadas): Es tipo de conexión se dada cuando la señal además de ir en el orden normal también va desde la salida hasta la entrada.

2.6.2.3. Tipos de redes Neuronales

- **El Perceptrón Simple**

El Perceptrón simple es un modelo compuesto por dos capas de neuronas, una de entrada y otra de salida (Rosenblatt, 1962). la información fluye desde la capa de entrada hacia la capa de salida (Larranaga, 2018).

El espacio de hipótesis de un perceptrón puede representar que una función de activación umbral sean funciones booleanas como (AND, OR, NOT) y funciones más complejas como la función de mayoría (Norvig, P., & Russell, 2013).

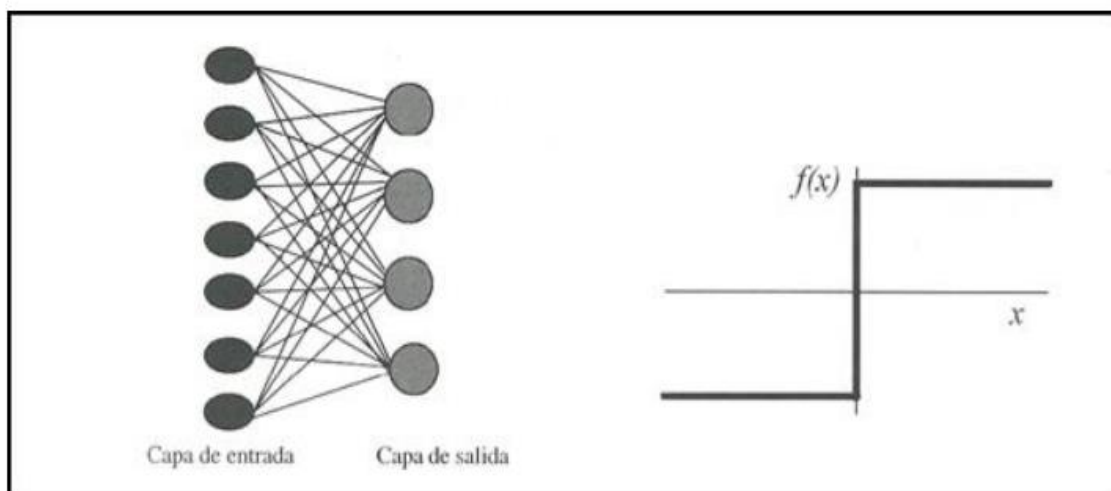


Figura 11. Perceptrón simple y función de transferencia de su neurona
Fuente: (GrupoUS, 2018).

- **El Perceptrón Multicapa**

El Perceptrón multicapa tiene sus neuronas agrupadas en capas de diferentes niveles. Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida (BiBing, 2018).

El Perceptrón se conecta con las neuronas de la siguiente capa con dirección hacia

adelante o “feedforward”. Las conexiones entre las neuronas de la red llevan también asociado un umbral, que en el caso del Perceptrón multicapa suele tratarse como una conexión más a la neurona, cuya entrada es constante e igual a 1.

Generalmente, todas las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa. Se dice entonces que existe conectividad total o que la red está totalmente conectada.

- **Diseño**

Cuando se aborda un problema utilizando el Perceptrón multicapa, uno de los primeros pasos a realizar es el diseño de la arquitectura de la red. Este diseño implica la determinación de la función de activación a emplear, el número de neuronas y el número de capas de la red (BiBing, 2018).

Para la selección del número de neuronas y de capas que se van a usar en la resolución del problema hay que tomar en cuenta parámetros del problema y parámetros elegidos por el desarrollador.

En la mayoría de los casos las entradas y las salidas son relativamente notables, ya que dichas variables vienen dadas por el problema.

Tanto el número de capas ocultas, como el número de neuronas deben ser elegidos por el diseñador ya que no existe un método o regla que determine el número óptimo de neuronas ocultas para resolver un problema dado. En la mayor parte de las aplicaciones prácticas, estos parámetros se determinan por prueba y error. Partiendo de una arquitectura ya entrenada, se realizan cambios aumentando o disminuyendo el número de neuronas ocultas y el número de capas hasta conseguir una arquitectura adecuada para el problema a resolver, que pudiera no ser la óptima, pero que proporciona una solución (BiBing, 2018).

2.6.3. Redes Neuronales Profundas

Según los expertos (Quintero, Merchán, Cornejo, & Galán, 2018) Redes Neuronales Profunda (o Deep Networks) es el nombre que se da a las nuevas arquitecturas de las redes neurales y a los nuevos algoritmos que se usan para aprender usando estas arquitecturas. Estas nuevas arquitecturas de redes han logrado cambios importantes en la dirección en la que se desarrolla la inteligencia artificial y al proveer diferentes estructuras y nuevos algoritmos para el aprendizaje que permiten incrementar el número de capas y así proveyendo de mayor flexibilidad a los modelos para el reconocimiento de patrones.

2.6.3.1. Redes neuronales convolucionales

Las redes neuronales convolucionales (también denominadas CNN o ConvNet) son una clase de redes neuronales profundas, ya que su aprendizaje es automático y basados en representaciones de datos, que se han adaptado ampliamente en varias aplicaciones de visión artificial e imágenes visuales.

Una red neuronal convolucional es un tipo de red multicapa que consta de diversas capas convolucionales y de pooling (submuestreo) alternadas, y al final tiene una serie de capas full-connected como una red perceptrón multicapa (Durán, 2017).




Figura 12. Esquema básico de una red neuronal convolucional
Fuente: (Durán, 2017).

El algoritmo toma un cuadrado pequeño (o ‘ventana’) y comienza a aplicarlo sobre la imagen. Cada filtro permite que la CNN identifique ciertos patrones en la imagen. La CNN busca partes de la imagen donde un filtro coincida con el contenido de la imagen (Bendemra, 2018).

En las primeras capas de la red se pueden detectar características simples como líneas, círculos y bordes. Estas características pueden ser combinadas en cada capa y aprender continuamente conceptos más complejos a medida que profundizamos en las capas de la red neuronal (Ibiblio, 2018).

2.6.3.2. Tipos de capas

La arquitectura general de una CNN consiste en una capa de entrada, capa(s) oculta(s) y una capa de salida. Son varios tipos de capas, por ejemplo, Convolutiva, Activación, Pooling, Dropout, Dense y capa SoftMax (Bendemra, 2018).




Figura 13. Arquitectura general de una CNN
Fuente: (Gerven & Bohte, 2018).

Capas convolucionales

La capa convolucional (o capa Conv) es el núcleo de lo que hace una red neuronal convolucional (Bendemra, 2018).

La convolución consiste en aplicar filtros a la imagen usando diferentes tipos de máscara los cuales producen distintos resultados. En la figura 10 se muestra una imagen, a la cual fue aplicada la máscara gaussiana y la máscara log.




Figura 14. Ejemplo de imagen aplicada distintos filtros
Fuente: (Loncomilla, 2018)

Según (Bendemra, 2018), Cada filtro se puede considerar como un cuadrado pequeño (con un ancho y una altura fijos) que se extiende a través de la profundidad total del volumen de entrada. Durante cada pasada, el filtro 'se desplaza' en el ancho y la altura del volumen de entrada. Este proceso da como resultado un mapa de activación bidimensional que proporciona las respuestas de ese filtro en cada posición espacial.

Según (Calvo, 2017), en la convolución se realizan operaciones de productos y sumas entre la capa de partida y los n filtros (o kernel) que genera un mapa de características. Las características extraídas corresponden a cada posible ubicación del filtro en la imagen original. La ventaja es que el mismo filtro (= neurona) sirve para extraer la misma característica en cualquier parte de la entrada, con esto se consigue reducir el número de conexiones y el número de parámetros a entrenar en comparación con una red multicapa de conexión total.




Figura 15. Descripción del proceso de convolución
Fuente: (Calvo, 2017).

Capas de Pooling (Submuestreo)

El objetivo de esta capa es el disminuir aún más la carga computacional del sistema y, al mismo tiempo, ayudar con la caracterización de la imagen obteniendo y localizando los rasgos predominantes en ella (Suárez, 2017).

En esta capa se reducen las dimensiones y los tiempos de procesamiento (Quintero et al., 2018).

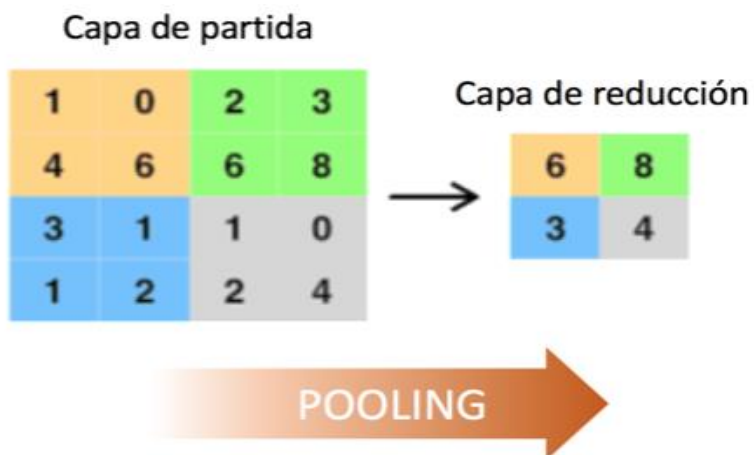


Figura 16. Descripción grafica de la capa de pooling
Fuente: (Calvo, 2017).

La forma de reducir parámetros se realiza mediante la extracción de estadísticas como el promedio (average-pooling) o el máximo (max-pooling) de una región fija del mapa de características, al reducir características el método pierde precisión, aunque mejora su compatibilidad (Calvo, 2017).




Figura 17. Operación de max-pooling y de average-pooling
Fuente: (Durán, 2017).

Capa full-connected

Esta se trata de la última capa del esquema de las redes neuronales convolucionales y se trata de un clasificador que determina a que clase pertenece la imagen de entrada.




Figura 18. Ejemplo del esquema de la red convolucional

Fuente: (Bendemra, 2018).

Funciones de activación

La función de activación es un nodo que se le agrega a las capas ocultas (función de activación ReLu) y a la capa de salida (función de activación SoftMax), con el objetivo de apilar capas de funciones lineales y no lineales, para detectar una amplia gama de patrones y predecir con precisión una etiqueta para una imagen determinada (Bendemra, 2018).




Figura 19. Las funciones de activación más comunes, función de activación ReLU y Sigmoid
Fuente: (Bendemra, 2018).

Cuando se trata de la evaluación del modelo y la evaluación del rendimiento, se elige una función de pérdida. En las CNN para la clasificación de imágenes, a menudo se elige la entropía cruzada categorial (en pocas palabras: corresponde a $-\log(\text{error})$). Existen varios métodos para minimizar el error usando Gradient Descent (Bendemra, 2018).

2.7. Clasificadores

2.7.1. Vecinos más cercanos (K-Nearest Neighbours)

El K-NN es un algoritmo de aprendizaje supervisado, es decir que, a partir una cantidad de datos inicial, el objetivo será el de clasificar correctamente todas las instancias nuevas. La regla típica de este tipo de algoritmos es que está formado por varios atributos descriptivos y un solo atributo objetivo o clase (DIVISADERO, 2017).

El principio detrás de los métodos vecinos más cercanos es encontrar un número predefinido de muestras de entrenamiento más cercanas al nuevo punto y predecir la etiqueta a partir de éstas. El número de muestras puede ser una constante definida por

el usuario (aprendizaje del vecino más cercano). La distancia puede, en general, ser cualquier medida métrica: la distancia estándar euclidiana es la opción más común (Unipython, 2018).

Como se muestra en la imagen, “K” significa la cantidad de “puntos vecinos” que tenemos en cuenta en las cercanías para clasificar los “n” grupos que ya se conocen de antemano, pues es un algoritmo supervisado (DIVISADERO, 2017).

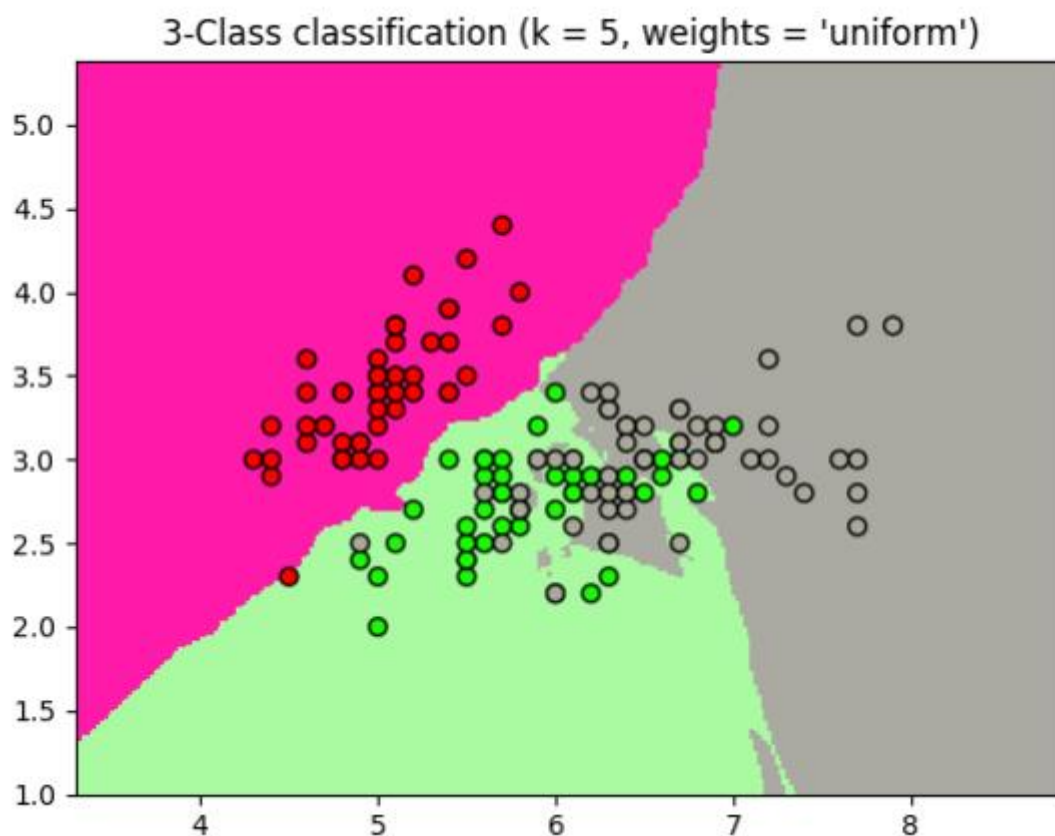


Figura 20. Ejemplo de vecino más cercanos con tres clases
Fuente: (Unipython, 2018)

2.7.2. Bosque Aleatorio (Random Forest)

Un bosque aleatorio es una meta estimada que se ajusta a una serie de clasificadores de árbol de decisión en varias submuestras del conjunto de datos y utiliza el promedio para mejorar la precisión predictiva y el ajuste excesivo del control. El tamaño de la submuestra es siempre el mismo que el tamaño de la muestra de entrada original

(Pedregosa et al., 2011).

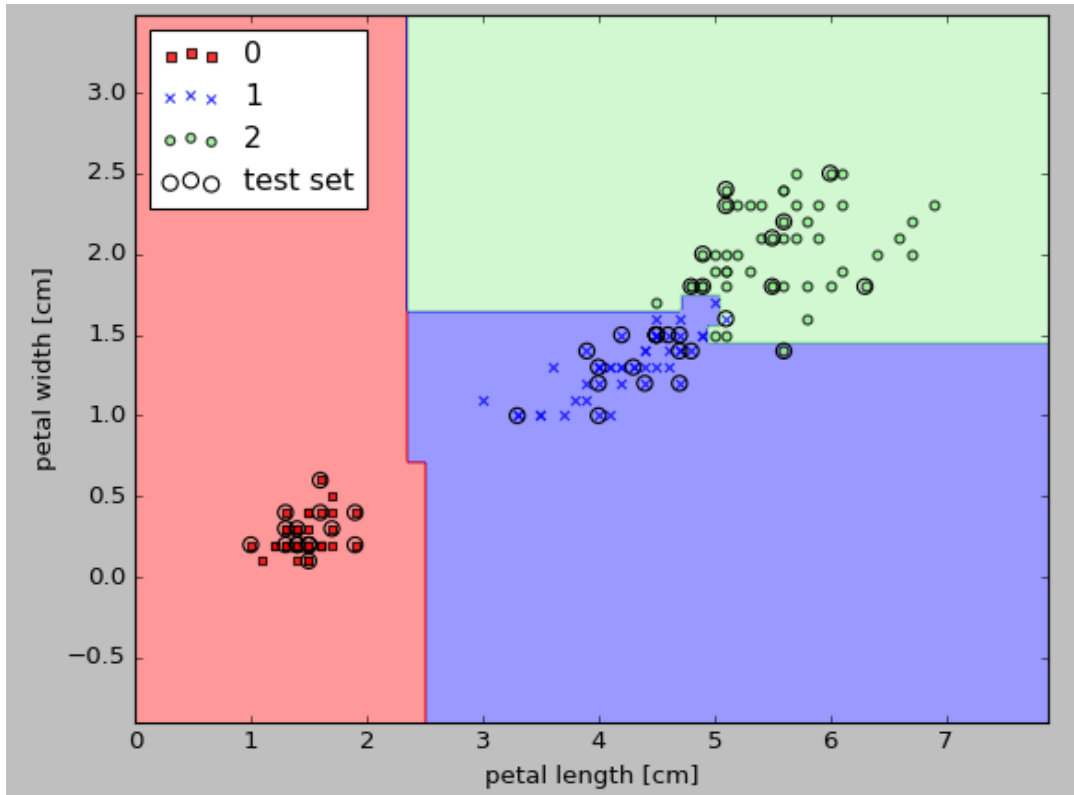


Figura 21. Ejemplo Clasificador Random Forest (Data Iris)

Fuente: (Hong, 2018)

A continuación, se muestra el funcionamiento del algoritmo Random Forest según (Avinash, 2018):

1. Selecciona muestras aleatorias de un conjunto de datos determinado.
2. Construye un árbol de decisión para cada muestra y obtenga un resultado de predicción de cada árbol de decisión.
3. Realiza una votación por cada resultado previsto.
4. Seleccione el resultado de la predicción con más votos como la predicción final.




Figura 22. Funcionamiento del algoritmo Random Forest
Fuente: (Avinash, 2018)

2.8. Visión Artificial

2.8.1. Definición

La visión artificial o visión por computadora es una rama de la inteligencia Artificial. Está conformada por una serie de etapas necesarias para dotar a la computadora de la capacidad de percibir y comprender una imagen (Cantero & Martínez, 2016).

2.8.2. Fases

Las fases que comprende la visión artificial dependen del propósito del sistema, sin embargo, la mayoría de sistemas de visión por computadora incluyen las siguientes etapas:

1. **Adquisición de la imagen:** la imagen es capturada directamente de manera digital o de manera física, en cuyo caso es digitalizada.

2. **Preprocesamiento:** esta etapa facilita el trabajo en las etapas posteriores, eliminando las partes de la imagen que no se tomarán en cuenta (M. Álvarez, 2014). Aquí es donde se realiza la detección de bordes que discrimina el fondo, separando los objetos de interés y reduciendo los datos a ser procesados (Shah, 1997).
3. **Segmentación:** se pueden seleccionar los pixeles dependiendo de si sus valores son RGB o HSV. De este modo, se destaca un objeto de un determinado color. (García, 2015).
4. **Representación y descripción:** en la representación se llevan los datos de cada objeto o región segmentada a formas con las que el ordenador trabaje más apropiadamente. En la descripción se capturan las diferencias esenciales entre los objetos que pertenecen a clases distintas (Yang, Kriegman, & Ahuja, 2002).
5. **Reconocimiento e interpretación:** se clasifican los objetos con características comunes dentro del espacio 3D y se restringe el espacio a través de técnicas de triangulación para que se seleccione una única imagen, la cual pueda ser interpretada (M. Álvarez, 2014).



Figura 23. Etapas de un sistema de visión artificial
Fuente: (Cantero & Martínez, 2016)

2.9. Morfometría

Se denomina morfometría “al conjunto de técnicas que nos permiten obtener las características dimensionales de los objetos” (Pertusa, 2003). Estas técnicas se usan para establecer de forma cuantitativa los parámetros que determinan a un objeto, como el largo, el ancho, el perímetro o el área. Estos parámetros morfométricos proporcionan al patólogo una mejor comprensión de los procesos patológicos que tienen lugar en los organismos examinados.

La morfometría permite describir tanto objetos macroscópicos como microscópicos. En el sentido microscópico, el término morfometría se refiere a la “descripción cuantitativa de imágenes microscópicas y rasgos microscópicos” (Baak & Oort, 1983).

Durante mucho tiempo, el análisis cuantitativo de las imágenes microscópicas estuvo subordinado a la descripción cualitativa, en parte debido a la preferencia de la mente humana por el reconocimiento de patrones en lugar de la valoración cuantitativa. El cerebro tiene una extraordinaria capacidad de clasificación, que se basa principalmente en comparar imágenes. Hace un análisis cualitativo e inmediato. Por ejemplo, cuando se nos presenta a alguien, se sabe de forma inmediata y solo mirando su rostro si se trata de un hombre o de una mujer; esto se hace al comparar la nueva cara con las caras de personas conocidas.

De acuerdo con (Pertusa, 2003) se puede hablar de “las bondades del cerebro humano en el reconocimiento de las más sutiles características de las imágenes y su «incapacidad» para apreciar las dimensiones de las cosas”. Es más fácil recordar las formas de los objetos que medirlos.

La recopilación y el cálculo de la información cuantitativa tomaba mucho tiempo. Es por ello que los patólogos preferían sacar sus conclusiones al comparar las imágenes observadas con la imagen que tenían en mente del patrón normal. Pero en décadas recientes, el desarrollo de las computadoras benefició grandemente a la morfometría. “Ahora es posible automatizar el proceso de toma de mediciones, la manipulación

computarizada de grandes matrices de datos y los análisis multivariados con un despliegue de gráficas muy elaboradas” (Jaramillo, 2011).

Las herramientas informáticas permiten analizar las imágenes extrayendo información de las mismas, con lo que “se pretende encontrar los parámetros más representativos y descriptivos de una imagen dada, con el objeto de representarlos de una forma numérica, de este modo el valor cuantitativo se estima como más objetivo y preciso que el que se pueda realizar mediante una mera observación cualitativa” (Moro, 2006).

2.9.1. Clasificación

La morfometría se divide en dos grandes tipos:

- Morfometría tradicional (MT): basada en el análisis univariado o multivariado de conjuntos de mediciones de distancias lineales entre puntos (largo, ancho, alto, ángulo, proporción entre medidas). Mientras más mediciones se utilicen, es más exacta.
- Morfometría geométrica (MG): basada en el uso de coordenadas en el plano (x,y) o en el espacio (x,y,z). Describe y analiza la variación existente entre formas. Permite reconstruir la forma del objeto ya que mantiene la relación geométrica que existe entre los puntos.

2.9.2. Elementos

Los puntos llamados “«puntos homólogos» o mejor «puntos anatómicos de referencia» (PAR)” (Jaramillo, 2011), son puntos específicos, ubicados conforme a un criterio definido, sobre una estructura biológica o sobre una imagen de la misma. Estos puntos deben ser fácilmente reconocibles, preferiblemente situados en la intersección de dos estructuras y deben estar presentes en todos los organismos analizados.

(Toro, Manriquez, & Suazo, 2010) clasificaron de la siguiente manera los puntos según su facilidad para reconocerlos:

Tipo I: se ubican en la intersección de tres estructuras, centros de estructuras muy pequeñas, intersecciones de curvas y pequeños forámenes.

Tipo II: se ubican en curvaturas máximas, valores extremos donde se aplican fuerzas biomecánicas.

Tipo III: corresponden a puntos que separan los extremos de una estructura. Gran parte de los puntos empleados en morfometría tradicional corresponden a este tipo; miden diámetros, largos máximos y constructos geométricos.




Figura 24. Puntos anatómicos de referencia
Fuente: (Jaramillo, 2011)

El análisis computarizado de imágenes microscópicas o morfometría microscópica se utiliza principalmente para realizar:

- Conteo de objetos
- Mediciones lineales

Los equipos necesarios para llevar a cabo estos procedimientos comprenden: microscopio óptico, cámara de video, computadora y software apropiado para el análisis de imágenes.

2.10. Plagas del maíz

Uno de los principales factores que afectan de forma negativa la actividad agrícola es las enfermedades de las plantas.

Se considera como planta enferma u *hospedante* a aquella que ha sufrido una alteración desfavorable en su desarrollo morfológico y fisiológico debido a un agente extraño o *agente causal*. Esta alteración que se manifiesta de forma visible se denomina *síntoma*.

Si la enfermedad es causada por un agente transmisible se denomina *enfermedad infecciosa*. Este agente denominado *patógeno* puede ser un microorganismo o un virus y su capacidad de producir la enfermedad se llama *patogenicidad*. “Cerca del 75 por ciento de todas las patologías vegetales son de origen fúngico” (Benítez, 2012).

2.10.1. Hongos fitopatógenos

Los hongos fitopatógenos son organismos microscópicos que carecen de clorofila. Como no pueden elaborar su propio alimento, “viven a expensas de la planta porque extraen de ella sus nutrientes” (Ames, 1997).

De acuerdo con (Ames, 1997), los hongos fitopatógenos están “constituidos por un conjunto de filamentos llamados hifas. El conjunto de hifas forma el micelio”. El micelio, según la condición reinante en el medio ambiente circundante, es capaz de formar distintas estructuras:

- Estructuras de propagación (conidias) cuando hay cultivo, las cuales se esparcen constantemente y mantienen el campo infectado.
- Estructuras de conservación (clamidosporas y esclerocios) cuando no hay cultivo, manteniendo al hongo vivo pero inactivo.
- Estructuras de reproducción.

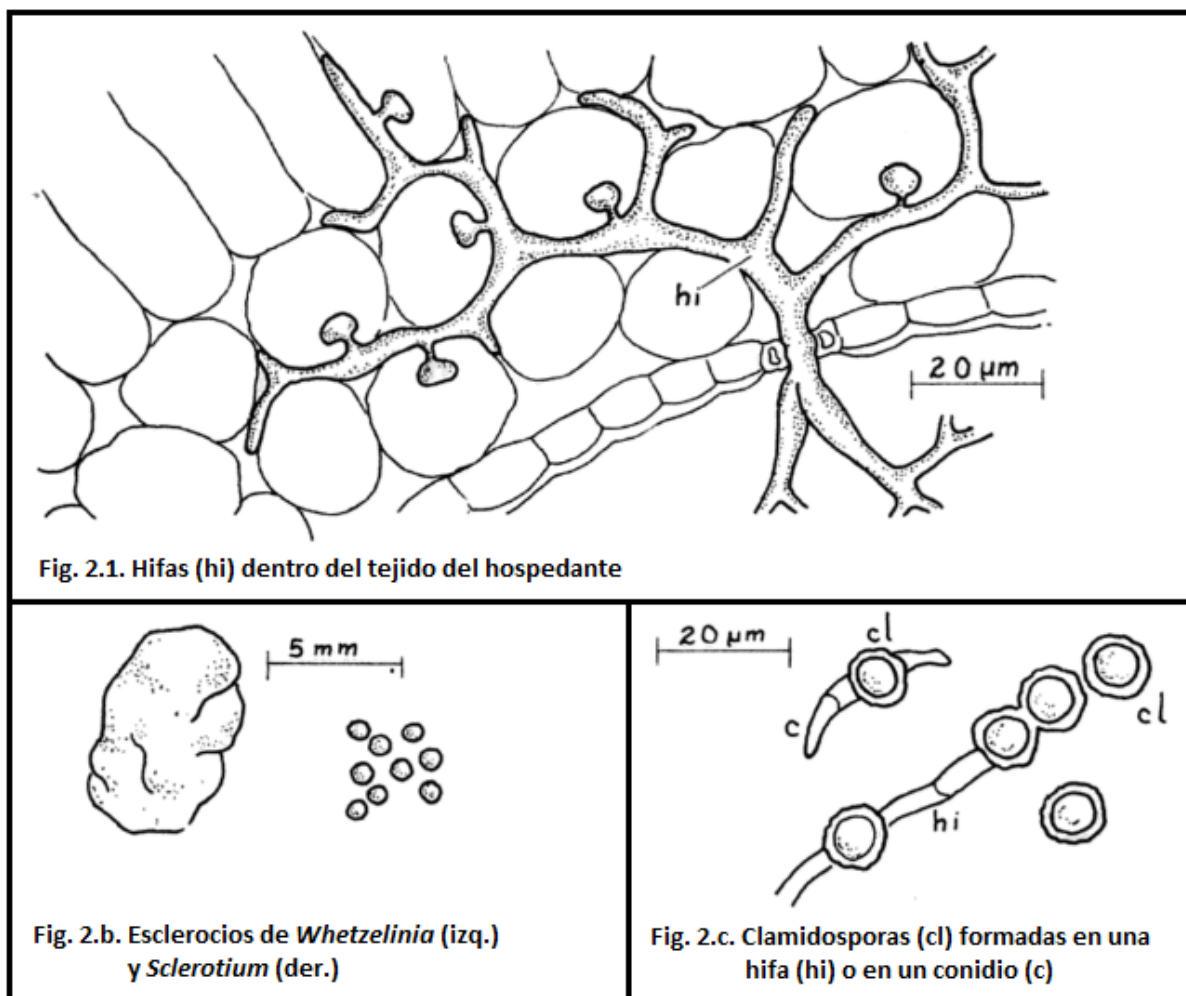


Figura 25. Estructuras características de diversos hongos fitopatógenos
Fuente: (González, 1985)

Los hongos no aparecen espontáneamente, sino que son diseminados por factores como el viento, el agua (de lluvia o de riego), insectos y ácaros, y el movimiento de personas, animales y maquinaria (Lastres & Soza, 2009).

2.10.2. Maíz

El maíz (*Zea mays*), perteneciente a la familia de las gramíneas, es una planta anual originaria de la región central de México. Su nombre científico proviene del griego Zeo, que significa vivir, y de la palabra Mahíz, que los nativos del Caribe taínos utilizaban para nombrar al grano (MAYA S.L., 2017).

Es uno de los granos más antiguos que se conocen. No crece en forma salvaje, por lo que es totalmente dependiente de los cuidados del ser humano (Agencia de Servicios a la Comercialización y Desarrollo de Mercados Agropecuarios, 2018).

Se estima que el maíz ha sido cultivado desde hace aproximadamente diez mil años, siendo la evidencia hallada más antigua de hace 6,250 años, encontrada en la cueva de Guilá Naqitz, en Oaxaca (Agencia de Servicios a la Comercialización y Desarrollo de Mercados Agropecuarios, 2018).

Hasta antes de la llegada de los europeos a América en el siglo XV, el maíz se distribuyó por casi todo el continente americano desde Canadá hasta Chile. Viajó al Caribe a través del Atlántico y a Argentina y Brasil llegó en el siglo XVII. Cristóbal Colón se llevó plantas de maíz a España, y poco tiempo después ya se plantaba en varios países de Europa. Más tarde se expandió a África y a Asia (MAYA S.L., 2017).

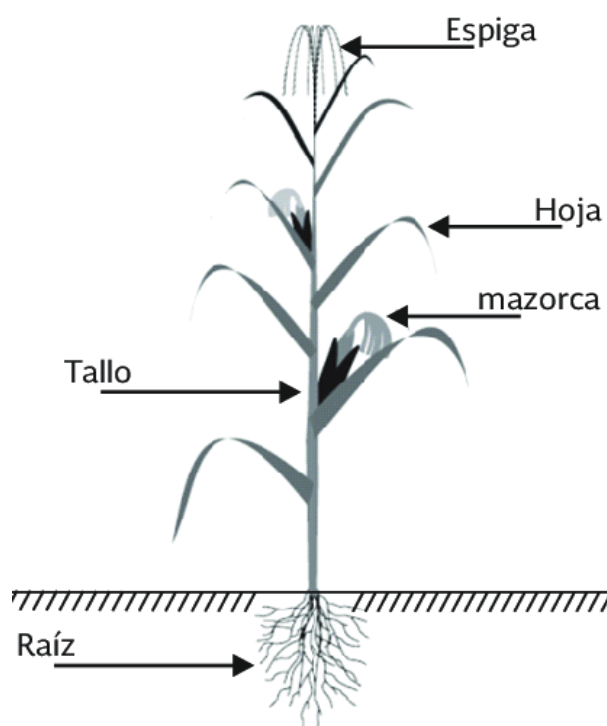


Figura 26. Partes que conforman una planta de maíz
Fuente: (Flores, Santana, Castillo, & Domínguez, 2017)

De acuerdo con (MAYA S.L., 2017), la planta de maíz posee las siguientes características:

Tabla 4

Características de la planta de maíz

Altura de la planta	de 1.2 a 3 m.
Tallos	el maíz tiene un solo tallo y raramente hijuelos.
Hojas	el maíz forma de 16 a 22 hojas por planta. Las hojas se forman en cada nodo y alternos.
Espiga	se forma en la parte superior de la planta y proporciona el polen para fertilizar la mazorca.
Floración	el maíz suele formar una sola mazorca. Las mazorcas son generalmente de 15 a 39 cm de largo.
Semilla	el grano de maíz generalmente pesa alrededor de 25-40 g por cada 100 granos.

Fuente: (MAYA S.L., 2017)

2.10.3. Hongos que afectan al maíz

El maíz, al igual que cualquier producto agrícola, no está exento de pestes, y dentro de estas, “las plagas constituyen la principal causa de pérdidas, lo cual repercute en un menor ingreso económico y en una disminución significativa de esta fuente alimenticia” (Páliz & Mendoza, 1999).

De acuerdo con (Paliwal, Granados, Lafitte, & Violic, 2001), “Algunas enfermedades son universales y ocurren en casi todos los ambientes en que se cultiva el maíz; estas incluyen los tizones, las royas y las manchas de las hojas y del tallo y la pudrición de la panoja”. Otras enfermedades en cambio, son específicas de la región donde se ubique el cultivo.

Se pueden clasificar a las enfermedades que afectan al maíz, de acuerdo al órgano dañado (Sillon, n.d.):



Figura 27. Clasificación de las principales enfermedades del maíz de acuerdo al momento de aparición en el cultivo y el órgano afectado

Fuente: (Sillon, n.d.)

Aunque son muchas las enfermedades fúngicas que afectan a los cultivos de maíz, este trabajo se centra en cuatro de las principales plagas que afectan a esta planta en nuestro país.

Curvularia lunata

Esta enfermedad se da en zonas cálidas y húmedas (Programa de Maíz del CIMMYT, 2004).

Sintomatología: “esta enfermedad es causada por hongos que producen pequeñas manchas cloróticas o necróticas con halo de color amarillo” (INIAP, n.d.). Las lesiones tienen un diámetro aproximado de 0.5 cm.




Figura 28. Microfotografías del hongo *Curvularia*: A-B: conidióforos y conidios; C.D.E.: disposición de los conidios en el conidióforo; F: conidios; G.H.: conidios germinando (C = 400x; los demás: 100x)

Fuente: (Malaguti & Subero, n.d.-b)




Figura 29. Hoja de maíz infectada por el hongo *Curvularia* en el campo
Fuente: (Malaguti & Subero, n.d.-b)

Ustilago maydis

Esta enfermedad se da en cualquier zona, sin embargo “puede ser más grave en climas húmedos y templados que en las tierras bajas tropicales con clima caluroso y húmedo” (Programa de Maíz del CIMMYT, 2004).

Sintomatología: las partes atacadas por el hongo son los tallos, las hojas y las mazorcas. “Unas agallas blancas cerradas muy conspicuas sustituyen a los granos individuales. Con el tiempo las agallas se rompen y liberan masas negras de esporas que infectarán las plantas de maíz del siguiente ciclo de cultivo” (Programa de Maíz del CIMMYT, 2004).



Figura 30. Mazorca infectada por el hongo *Ustilago maydis*
Fuente: (Programa de Maíz del CIMMYT, 2004)




Figura 31. Esporas del hongo *Ustilago maydis* a 400x
Fuente: (Levetin, n.d.)

Helminthosporium maydis

Esta enfermedad ataca a cultivos ubicados en zonas cálidas y húmedas.

Sintomatología: en un principio, las lesiones “son pequeñas y romboides. A medida que maduran se van alargando, pero las nervaduras adyacentes restringen su crecimiento y la forma final de la lesión es rectangular, de 2 a 3 cm de largo. Las lesiones pueden llegar a fusionarse y producir la quemadura completa de extensas áreas foliares” (Programa de Maíz del CIMMYT, 2004).



Figura 32. Hoja infectada por *Helminthosporium maydis*
Fuente: (Programa de Maíz del CIMMYT, 2004)




Figura 33. Microfotografías de *Helminthosporium maydis* (A y B: conidióforos. C y D: conidios (A.B.C. = 100x; D = 400 X). E: conidióforos y conidios
Adaptada de: (Malaguti & Subero, n.d.-a)

CAPÍTULO 3

DISEÑO Y DESARROLLO DEL SISTEMA

3.1. Introducción

En el presente capítulo se detalla el desarrollo del prototipo de un sistema basado en conocimiento (SBC). Los SBC permiten resolver problemas complejos y reales, por lo que son difíciles de desarrollar usando metodologías y técnicas clásicas de desarrollo.

Para el desarrollo del presente prototipo se ha creado una base de conocimiento y reglas de acuerdo a la experiencia y dominio del profesional técnico especialista en detección de hongos y plagas del maíz.

En el proceso de desarrollo de los SBC se inicia con las siguientes fases: el análisis del problema, modelado del conocimiento, desarrollo del prototipo, pruebas con casos, la fase de instalación y mantenimiento.

En la figura 33, se muestra una adaptación de las fases del desarrollo de los SBC, las fases de instalación y mantenimiento no se desarrollaron debido a que supera los alcances de desarrollo del presente proyecto.

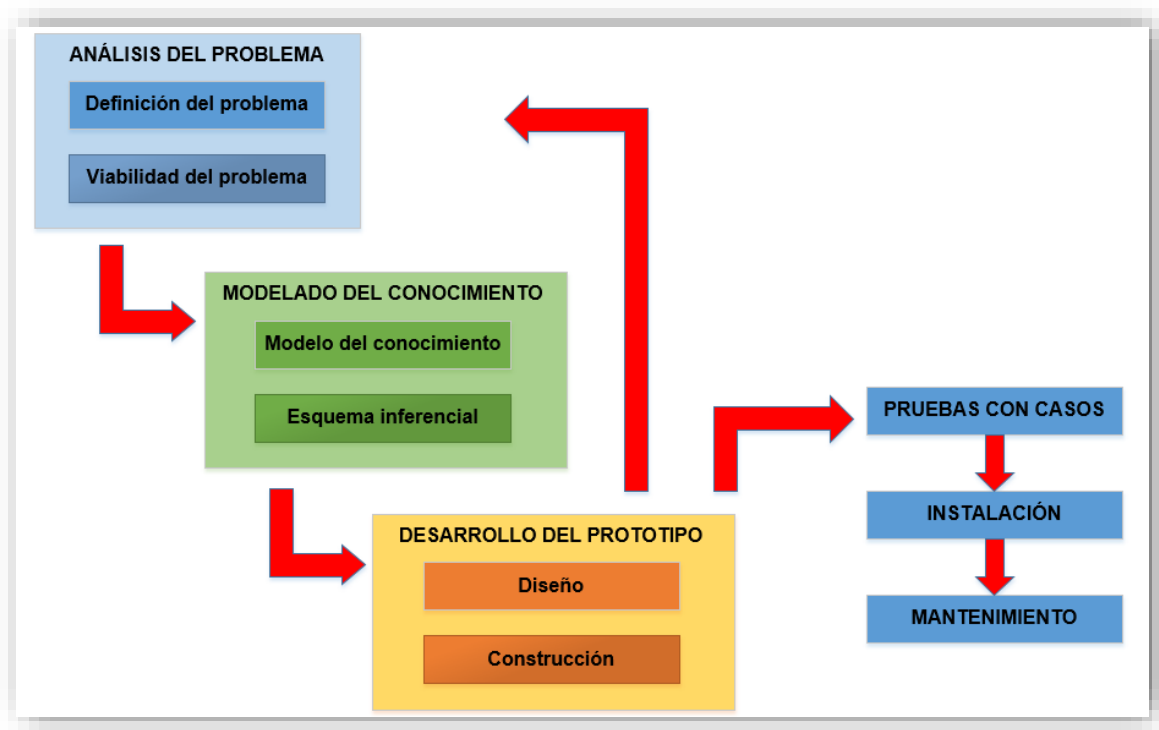


Figura 34. Fases de desarrollo de un Sistema Basado en Conocimiento (SBC)

3.2. Análisis del problema

3.2.1. Problema

Hoy en día, arriva al Laboratorio de Fitopatología una gran cantidad de muestras, especialmente de cultivos de maíz, que requieren análisis para la identificación de los patógenos presentes. Para llevar a cabo los análisis morfométricos, los expertos cuentan con un único microscopio dotado de un software apropiado, por lo que se demora la obtención de reportes diagnósticos.

El Laboratorio de Fitopatología dispone de cámaras, microscopios y computadores que no pueden ser utilizados para realizar mediciones morfométricas debido a que no cuentan con el software apropiado para dicho propósito.

La elaboración de los informes de análisis toma mucho tiempo ya que las mediciones de los microorganismos son realizadas de forma manual. Esos datos son procesados y comparados con información de papers para que los expertos lleguen a un diagnóstico del patógeno causante de la plaga.

3.2.2. Análisis de viabilidad

Viabilidad técnica	<ul style="list-style-type: none">• Para el desarrollo del sistema, Agrocalidad proporciona la logística y el equipamiento necesario como computadoras, microscopios, cámaras oculares digitales para microscopios, placas de microorganismos e información técnica.• Los estudiantes cuentan con computadoras con características que soportan las herramientas de desarrollo empleadas.
Viabilidad económica	<ul style="list-style-type: none">• No se incurre en un gasto mayor para el desarrollo del proyecto ya que las herramientas de desarrollo utilizadas son freeware.
Viabilidad operativa	<ul style="list-style-type: none">• El proyecto cuenta con personal calificado para su desarrollo.• Los estudiantes poseen las bases necesarias de desarrollo de software adquiridas durante su formación académica.• Se tiene el apoyo de la docente tutora del proyecto, quien cuenta con formación académica y experiencia en este tipo de proyectos.• Agrocalidad brinda el apoyo directo de su personal experto en análisis fitopatológico.
Conclusión	<ul style="list-style-type: none">• El proyecto es técnica, económica y operativamente viable debido a que se cuentan con todos los recursos necesarios para su desarrollo.

3.3. Solución

Desarrollar una aplicación que permita realizar el proceso de medición y registro de medidas morfométricas de los microorganismos presentes en las muestras analizadas, y que pueda ser utilizada conjuntamente con los varios equipos disponibles en el Laboratorio de Fitopatología.

Con base en el conocimiento y experiencia de los expertos del Laboratorio de Fitopatología, desarrollar una red neuronal artificial que realice el aprendizaje automático para reconocer patrones de tres de las plagas más comunes que afectan a los cultivos de maíz en nuestro país: *Curvularia lunata*, *Ustilago maydis*, *Stenocarpella macrospora* y *Helminthosporium maydis*.

3.4. Modelado del conocimiento

A continuación, se detalla la descripción de las tareas y de los elementos de conocimiento dentro del proceso en el que se implantará el SBC.

Tabla 5

Detalle de tareas realizadas por el experto

Tareas Realizadas por el experto
Preparar las muestras
Preparar el microscopio <ul style="list-style-type: none"> • Colocar la muestra • Seleccionar el lente de visualización • Seleccionar el sector a analizar
Realizar la microfotografía del sector seleccionado.
Guardar la microfotografía en la base de datos.
Seleccionar la microfotografía que se va a realizar la medición.
Procesar la imagen
Realizar la medición
Realiza la clasificación
Generar reportes

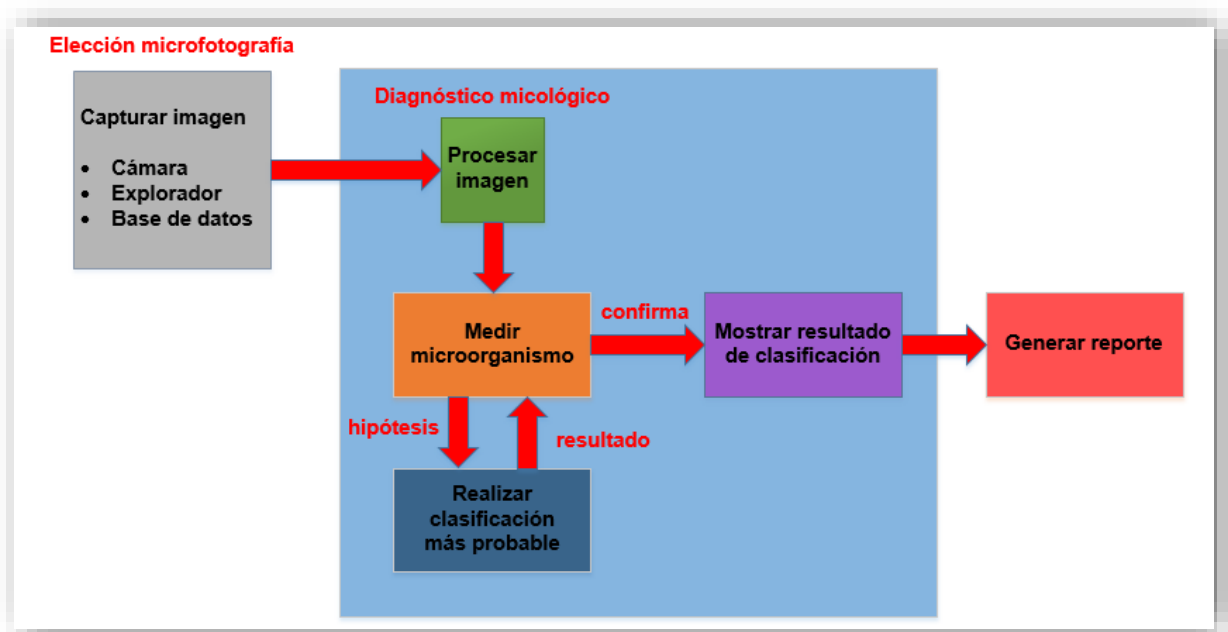


Figura 35. Mapa de tareas para llevar a cabo la clasificación de hongos

3.4.1. Esquema inferencial (reglas)

Modelo conceptual microorganismo

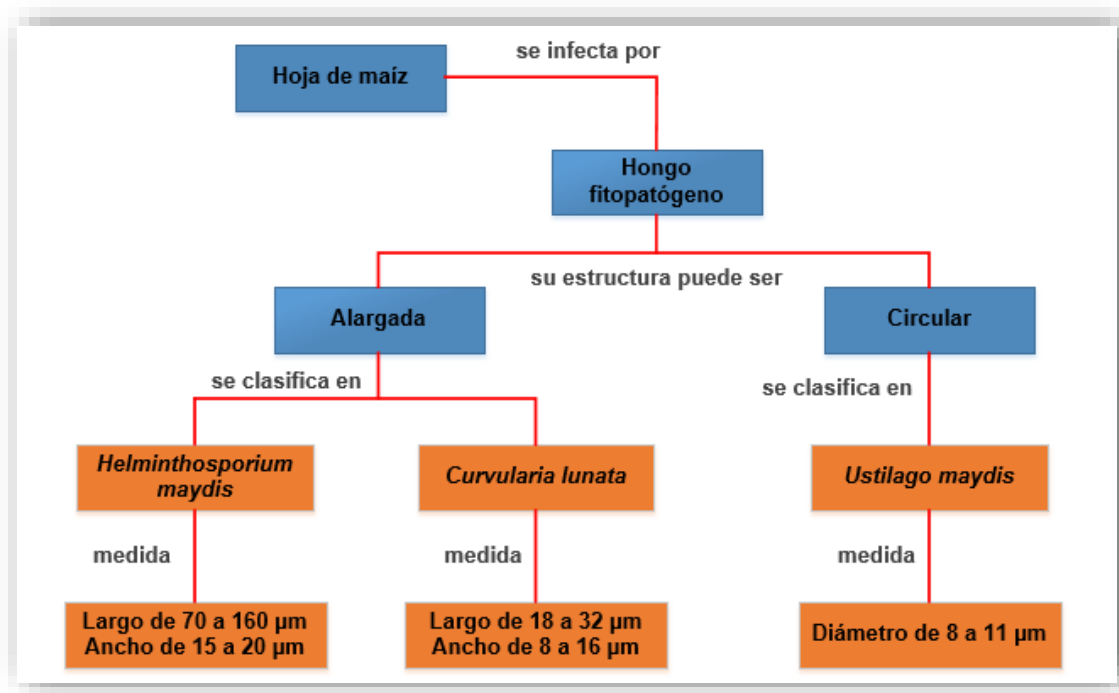


Figura 36. Modelo conceptual microorganismo

Reglas

A continuación, se detallan las reglas para estructurar el conocimiento del presente sistema experto.

- Si el promedio ancho está dentro del rango de 15 a 20 y si el promedio largo está dentro del rango de 70 a 160 entonces el microorganismo pertenece a la especie "*Helminthosporium maydis*".




Figura 37. Regla para la clasificación del microorganismo “Helminthosporium maydis”

- Si el promedio ancho está dentro del rango de 8 a 16 y si el promedio largo está dentro del rango de 18 a 32 entonces el microorganismo pertenece a la especie “*Curvularia lunata*”.




Figura 38. Regla para la clasificación del microorganismo “Curvularia lunata”

- Si el promedio ancho está dentro del rango de 8 a 11 y si el promedio largo es igual a 0 entonces el microorganismo pertenece a la especie “*Ustilago maydis*”.

```

IF (promedioAncho >= 8 && promedioAncho <= 11)
  IF(promedioLargo == 0)
    THEN microorganismo == "Ustilago Maydis"
  ELSE return
ELSE return

```

Variables (pointing to promedioAncho)
Condiciones (pointing to the IF conditions)
Conclusion (pointing to the THEN result)

Figura 39. Regla para la clasificación del microorganismo "Ustilago maydis"

3.4.2. Diagrama de arquitectura SBC

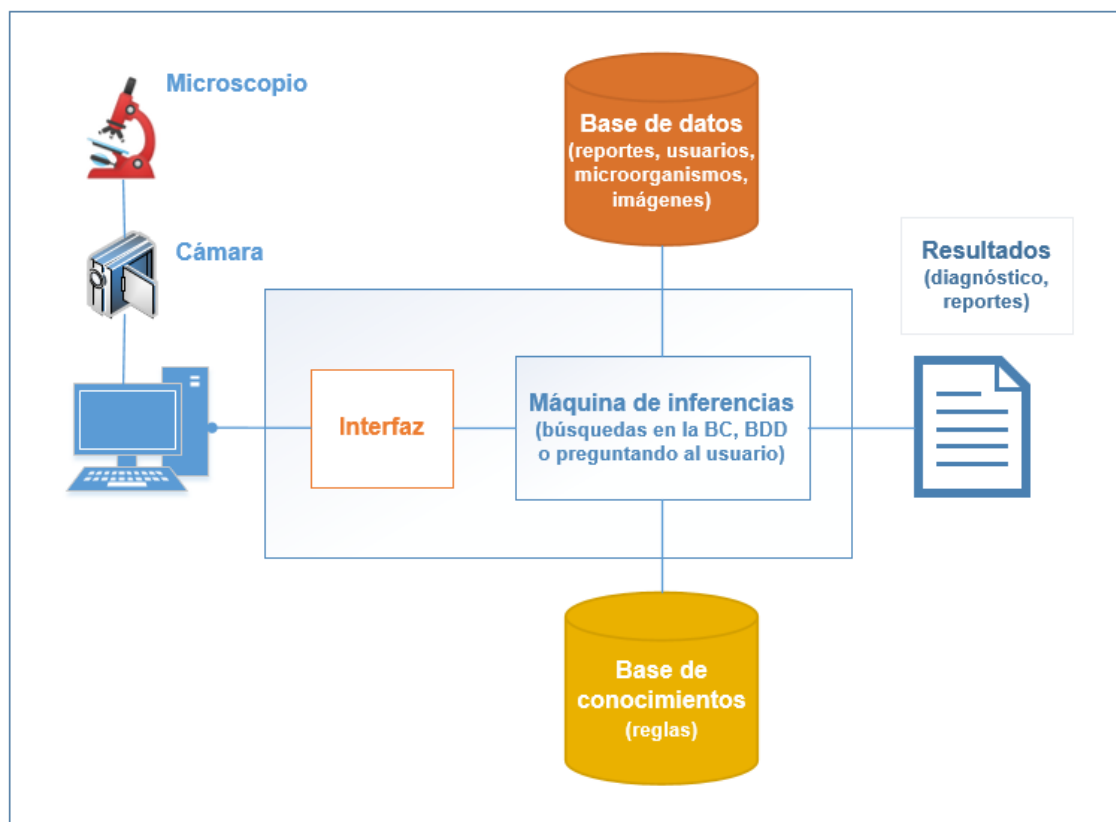


Figura 40. Diagrama de arquitectura del Sistema de Diagnóstico Micológico SDM

3.4.3. Creación de los clasificadores

Algoritmo Vecinos más cercanos

Para la creación del clasificador es importante definir la métrica de la distancia, que debe ser seleccionada según el problema a resolver, por lo cual para el presente problema se usó la métrica de nueve vecinos con el objetivo de realizar una clasificación más precisa como se muestra en la siguiente imagen.




Figura 41. Representación gráfica algoritmo Vecinos más cercanos con una métrica igual a 9

Algoritmo Random Forest

Para la creación del clasificador Random Forest se usaron los siguientes parámetros:

- Profundidad del árbol igual a 3
- Nivel igual a 2
- Número de nodos terminales igual a 6

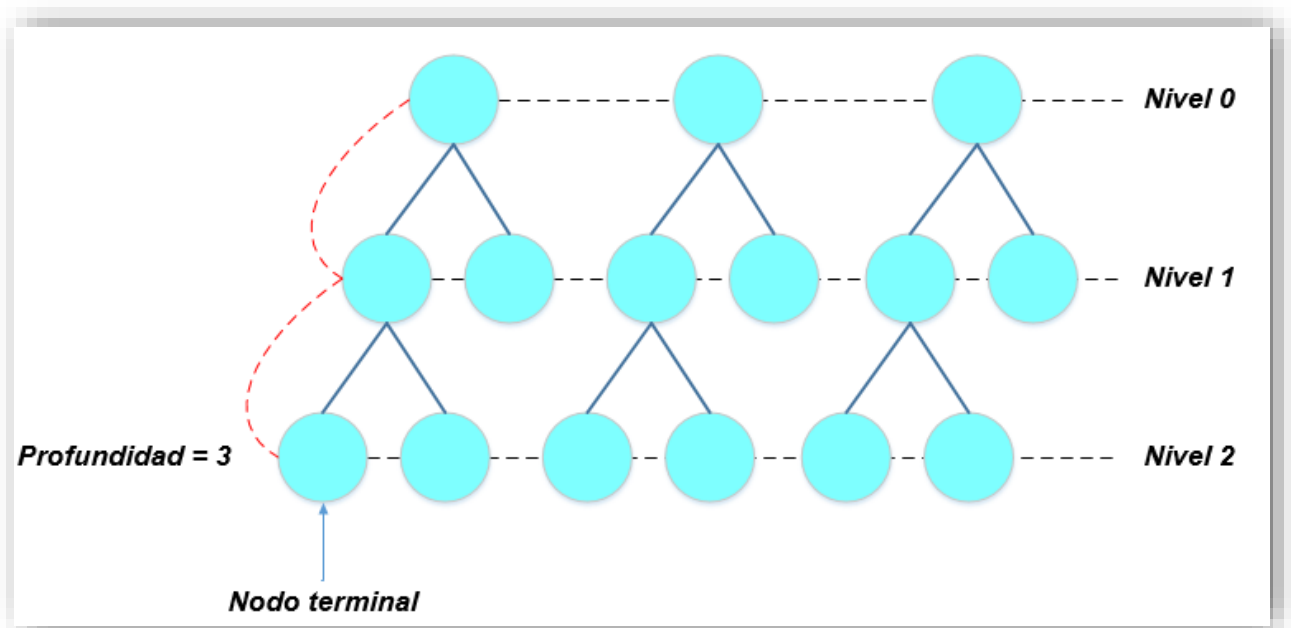


Figura 42. Estructura del clasificador Random Forest

3.4.4. Creación de Redes Neuronales

Creación Red Neuronal Perceptrón Simple

Fue implementada la Red Neuronal Perceptrón Simple, la misma que cuenta con la siguiente estructura como se observa en la imagen. Los valores de largo, ancho y diámetro del microorganismo se tomaron como entrada para la red.

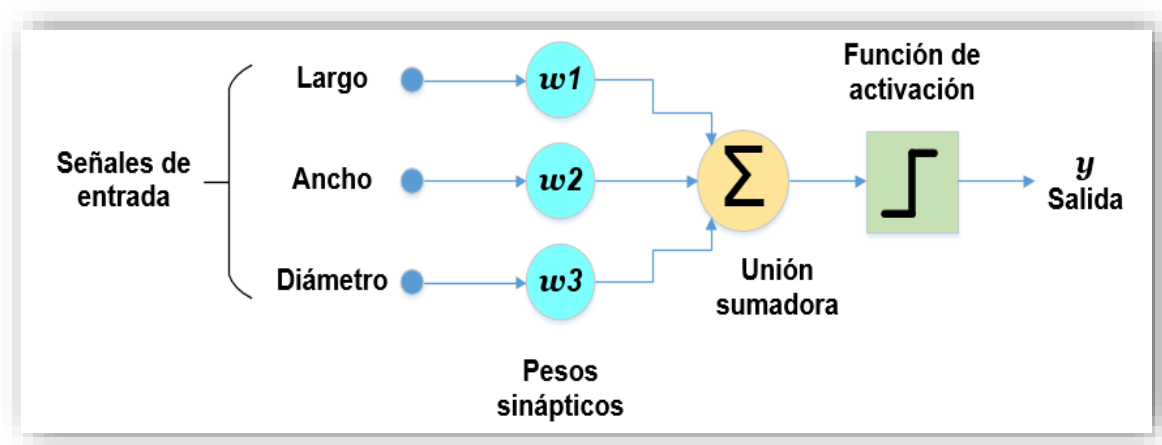


Figura 43. Estructura del Perceptrón Simple implementado

Creación Red Neuronal Convolutional

Fue implementada la Red Neuronal Convolutional, la misma que consta de una estructura, tal como se detalla:

- La entrada: es una imagen de 150x150 pixeles.
- Capa de convolución.
- Capa de pooling o reducción (Utilizando la función de maxpooling).
- Capa de convolución.
- Capa de pooling o reducción (Utilizando la función de maxpooling).
- Aplicación de la función softmax.
- 4 salidas, pertenecientes a las cuatro plagas de las hojas de la planta de maíz.




Figura 44. Estructura de la red neuronal convolutional

Fuente: (Jones, 2017)

3.5. Desarrollo del prototipo

3.5.1. Casos de uso y descripción

Casos de uso generales

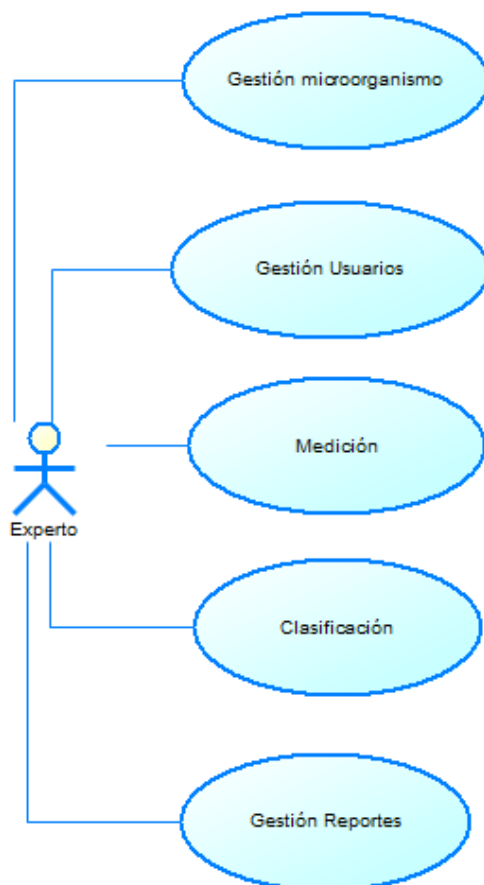


Figura 45. Diagrama general de casos de uso

Casos de uso «Gestión Usuarios»




Figura 46. Diagrama de casos de uso «Gestión Usuario»

Tabla 6

Descripción del caso de uso «Gestión usuario»

Nombre	GESTIÓN USUARIO	
Actor	Administrador	
Descripción	Describe el proceso para crear un nuevo usuario para el sistema	
Flujo Principal	Eventos Actor	Eventos Sistema
	<ul style="list-style-type: none"> • Presiona el menú de usuario. • Se debe seleccionar Gestionar perfil. • Se debe seleccionar Gestionar usuario. 	<ul style="list-style-type: none"> • Muestra el formulario de creación de perfil y usuario. • Muestra el formulario de perfil. • Muestra el formulario de gestión de usuario.
Alternativa	--	
Precondición	Ingresar con el perfil de Administrador.	
Postcondición	Se procede a la gestión tanto del perfil o usuario.	
Presunción	La Base de datos se encuentra disponible.	

Casos de uso «Gestión Perfil»

Tabla 7

Descripción del caso de uso «Consultar perfil»

Nombre	Consultar Perfil	
Actor	Administrador	
Descripción	Describe el proceso para consultar los perfiles del sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Presionar el menú de usuario. • Se debe seleccionar Gestionar perfil. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra el formulario de creación de perfil y usuario. • Muestra el formulario de perfil. • Muestra una tabla con todos los perfiles.
Alternativa	Ingresar nuevo perfil en el caso de que no existan perfiles asignados.	
Precondición	Ingresar con el perfil de Administrador.	
Postcondición	Se procede a la gestión tanto del perfil.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 8

Descripción del caso de uso «Crear perfil»

Nombre	Crear Perfil	
Actor	Administrador	
Descripción	Describe el proceso para crear un nuevo perfil para el sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Presiona el menú de usuario. • Presiona el botón Crear. • Ingresa los datos del perfil a crear. • Presiona el botón Guardar. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra el formulario de creación de perfil. • Habilita los campos para la creación. • Muestra la información ingresada en la tabla.
Alternativa	--	
Precondición	Ingresar con el perfil de Administrador.	
Postcondición	Se procede a la gestión tanto del perfil.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 9*Descripción del caso de uso «Editar perfil»*

Nombre	Editar Perfil	
Actor	Administrador	
Descripción	Describe el proceso para editar los perfiles del sistema	
Flujo Principal	Eventos Actor	Eventos Sistema
	<ul style="list-style-type: none"> • Se debe seleccionar el perfil a editar y presionar el botón Visualizar. • Presionar el botón Editar. • Editar los campos que se requieran. • Presionar el botón Guardar 	<ul style="list-style-type: none"> • Muestra los campos del formulario con la información del perfil seleccionado. • Editar los campos. • Guarda los cambios al perfil seleccionado.
Alternativa	Si no se ha seleccionado el perfil a editar el sistema mostrará un mensaje.	
Precondición	Seleccionar un perfil.	
Postcondición	Se reinicia el caso de uso.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 10*Descripción del caso de uso «Eliminar perfil»*

Nombre	Eliminar Perfil	
Actor	Administrador	
Descripción	Describe el proceso para eliminar los perfiles del sistema	
Flujo Principal	Eventos Actor	Eventos Sistema
	<ul style="list-style-type: none"> • Se debe seleccionar el perfil a eliminar y presionar el botón Visualizar. • Presionar el botón Eliminar. • Presiona Aceptar. 	<ul style="list-style-type: none"> • Muestra los campos del formulario con la información del perfil seleccionado. • Muestra un mensaje de confirmación. • Guarda los cambios y actualiza la tabla de perfiles.
Alternativa	Si no presiona Aceptar en el mensaje de confirmación para eliminar, se reinicia el caso de uso.	
Precondición	Seleccionar un perfil.	
Postcondición	Se reinicia el caso de uso.	
Presunción	La Base de datos se encuentra disponible.	

Gestión Usuario

Tabla 11

Descripción del caso de uso «Consultar usuario»

Nombre	Consultar Usuario	
Actor	Administrador	
Descripción	Describe el proceso para consultar los usuarios del sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Presionar el menú de usuario. • Se debe seleccionar Gestionar usuario. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra el formulario de creación de usuario. • Muestra el formulario de usuario. • Muestra una tabla con todos los usuarios.
Alternativa	Ingresar nuevo usuario en el caso de que no existan usuarios asignados.	
Precondición	Ingresar con el perfil de Administrador.	
Postcondición	Se procede a la gestión del usuario.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 12

Descripción del caso de uso «Crear usuario»

Nombre	Crear Usuario	
Actor	Administrador	
Descripción	Describe el proceso para crea un nuevo usuario para el sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Presiona el menú de usuario. • Presiona el botón crear. • Ingresa los datos del usuario a crear. • Presiona el botón Guardar. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra el formulario de creación de usuario. • Habilita los campos para la creación. • Muestra la información ingresada en la tabla.
Alternativa	--	
Precondición	Ingresar con el usuario de Administrador.	
Postcondición	Se procede a la gestión tanto del usuario.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 13*Descripción del caso de uso «Editar usuario»*

Nombre	Editar Usuario	
Actor	Administrador	
Descripción	Describe el proceso para editar los usuarios del sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Se debe seleccionar el usuario a editar y presionar el botón Visualizar. • Presionar el botón Editar. • Editar los campos que se requieran. • Presionar el botón Guardar 	Eventos Sistema <ul style="list-style-type: none"> • Muestra los campos del formulario con la información del usuario seleccionado. • Edita los campos. • Guarda los cambios al usuario seleccionado.
Alternativa	Si no se ha seleccionador el usuario a editar el sistema mostrara un mensaje.	
Precondición	Seleccionar un usuario.	
Postcondición	Se reinicia el caso de uso.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 14*Descripción del caso de uso «Eliminar usuario»*

Nombre	Eliminar Usuario	
Actor	Administrador	
Descripción	Describe el proceso para eliminar los usuarios del sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Se debe seleccionar el usuario a eliminar y presionar el botón Visualizar. • Presionar el botón de eliminar. • Presiona Aceptar. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra los campos del formulario con la información del usuario seleccionado. • Muestra un mensaje de confirmación. • Guarda los cambios y actualiza la tabla de usuarios.
Alternativa	Si no presiona Aceptar en el mensaje de confirmación para eliminar, se reinicia el caso de uso.	
Precondición	Seleccionar un usuario.	
Postcondición	Se reinicia el caso de uso.	
Presunción	La Base de datos se encuentra disponible.	

Casos de uso «Gestión Reportes»

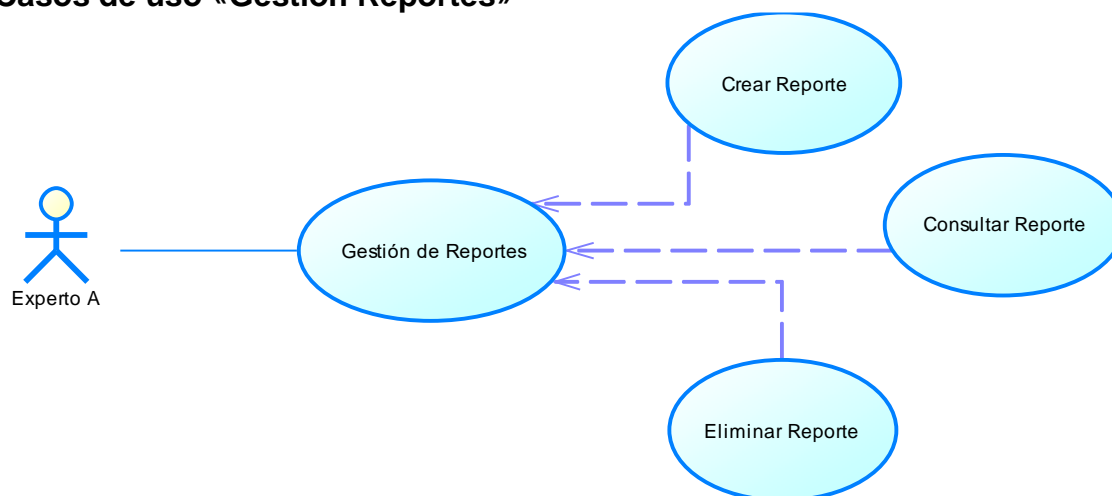


Figura 47. Diagrama de casos de uso «Gestión Reportes»

Reportes

Tabla 15

Descripción del caso de uso «Consultar reportes»

Nombre	Consultar reportes	
Actor	Experto	
Descripción	Describe el proceso para consultar los reportes del sistema	
Flujo Principal	Eventos Actor	Eventos Sistema
	<ul style="list-style-type: none"> • Presionar el menú de Reportes. • Selecciona si se desea buscar por nombre, fecha, o código de muestra. 	<ul style="list-style-type: none"> • Muestra el formulario de gestión de reportes. • Muestra los reportes según el tipo de búsqueda que se seleccionó.
Alternativa	Muestra un mensaje cuando no existan reportes en el tipo de búsqueda seleccionada.	
Precondición	Seleccionar el menú Reporte.	
Postcondición	Se procede a la gestión de reportes.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 16

Descripción del caso de uso «Eliminar reporte»

Nombre	Eliminar Reporte	
Actor	Experto	
Descripción	Describe el proceso para eliminar los reportes del sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Se debe realizar la búsqueda del reporte que se requiere eliminar. • Presionar el botón Eliminar. • Presionar Aceptar. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra los reportes buscados. • Muestra un mensaje de confirmación. • Guarda los cambios y actualiza la tabla de reportes.
Alternativa	Si no presiona Aceptar en el mensaje de confirmación para eliminar, se reinicia el caso de uso.	
Precondición	Seleccionar un usuario.	
Postcondición	Se reinicia el caso de uso.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 17

Descripción del caso de uso «Crear reporte»

Nombre	Crear Reporte	
Actor	Experto	
Descripción	Describe el proceso para crea un nuevo reporte para el sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Presionar el botón de reportes en la barra de herramientas. • Presionar el botón Adjuntar imagen. • Ingresar la información de la muestra. • Seleccionar la fuente. • Presionar Visualizar reporte. • Presionar Cerrar la visualización del reporte. • Presionar Guardar reporte. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra el formulario de creación de reportes. • Muestra el explorador de Windows para buscar la fotografía. • Procesa la información ingresada. • Calcula el promedio máximo y mínimo de la plaga. • Muestra el reporte en PDF. • Almacena en la base de datos.
Alternativa	--	
Precondición	Realizar la medición de los microorganismos.	
Postcondición	Se procede al diagnóstico del microorganismo.	
Presunción	La Base de datos se encuentra disponible.	

Casos de uso «Gestión Microorganismo»

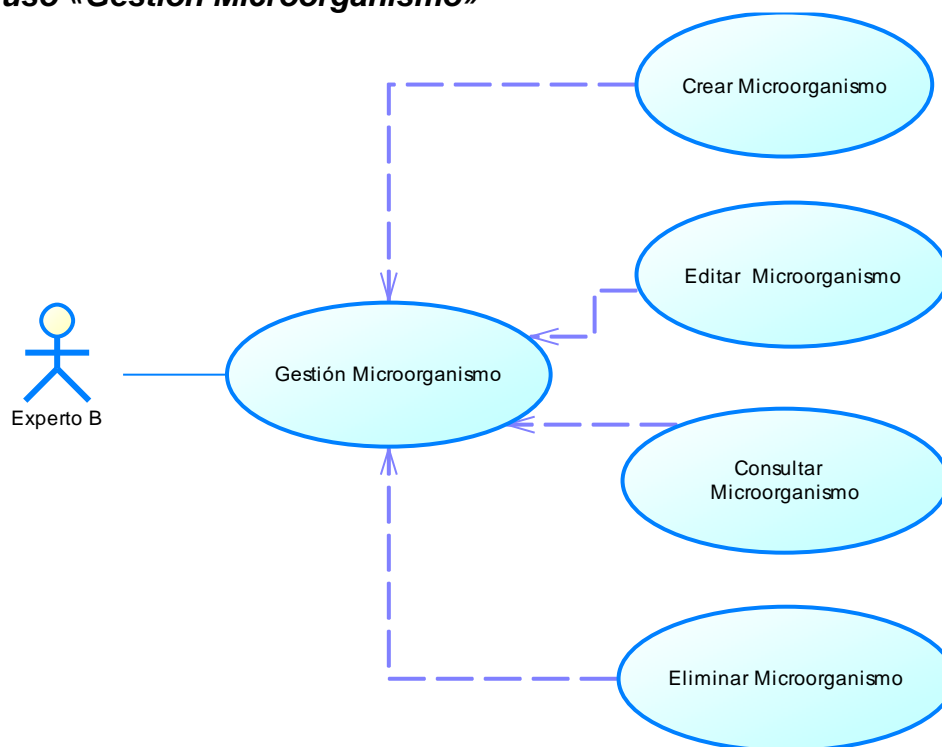


Figura 48. Diagrama de casos de uso «Gestión Microorganismo»

Tabla 18

Descripción del caso de uso «Consultar microorganismo»

Nombre	Consultar Microorganismo	
Actor	Experto	
Descripción	Describe el proceso para consultar los microorganismos del sistema	
Flujo Principal	Eventos Actor	Eventos Sistema
	<ul style="list-style-type: none"> • Presionar el menú de microorganismo. • Presionar Gestión de microorganismo. 	<ul style="list-style-type: none"> • Muestra el formulario de microorganismo. • Muestra una tabla con todos los microorganismos.
Alternativa	Ingresar nuevo microorganismo en el caso de que no existan microorganismos asignados.	
Precondición	Ingresar con el perfil de Administrador.	
Postcondición	Se procede a la gestión del microorganismo.	
Presunción	La Base de datos se encuentra disponible.	

Tabla 19

Descripción del caso de uso «Crear microorganismo»

Nombre		Crear Microorganismo	
Actor	Experto		
Descripción	Describe el proceso para crea un nuevo microorganismo para el sistema		
Flujo Principal	Eventos Actor		Eventos Sistema
	<ul style="list-style-type: none"> • Presiona el menú de microorganismo. • Presiona el botón Crear. • Ingresa los datos del microorganismo a crear. • Presiona el botón Guardar. 		<ul style="list-style-type: none"> • Muestra el formulario de creación de microorganismo. • Habilita los campos para la creación. • Muestra la información ingresada en la tabla.
Alternativa	--		
Precondición	Ingresar con el usuario de Administrador.		
Postcondición	Se procede a la gestión del microorganismo.		
Presunción	La Base de datos se encuentra disponible.		

Tabla 20

Descripción del caso de uso «Editar microorganismo»

Nombre		Editar Microorganismo	
Actor	Experto		
Descripción	Describe el proceso para editar los microorganismos del sistema		
Flujo Principal	Eventos Actor		Eventos Sistema
	<ul style="list-style-type: none"> • Se debe seleccionar el microorganismo a editar y presionar el botón Visualizar. • Presionar el botón Editar. • Editar los campos que se requieran. • Presionar el botón Guardar. 		<ul style="list-style-type: none"> • Muestra los campos del formulario con la información del microorganismo seleccionado. • Edita los campos. • Guarda los cambios al microorganismo seleccionado.
Alternativa	Si no se ha seleccionado el microorganismo a editar el sistema mostrará un mensaje.		
Precondición	Seleccionar un usuario.		
Postcondición	Se reinicia el caso de uso.		
Presunción	La Base de datos se encuentra disponible.		

Tabla 21

Descripción del caso de uso «Eliminar microorganismo»

Nombre	Eliminar Microorganismo	
Actor	Experto	
Descripción	Describe el proceso para eliminar los microorganismos del sistema	
Flujo Principal	Eventos Actor <ul style="list-style-type: none"> • Se debe seleccionar el microorganismo a eliminar y presionar el botón visualizar. • Presionar el botón de eliminar. • Presiona Aceptar. 	Eventos Sistema <ul style="list-style-type: none"> • Muestra los campos del formulario con la información del microorganismo seleccionado. • Muestra un mensaje de confirmación. • Guarda los cambios y actualiza la tabla de microorganismos.
Alternativa	Si no presiona Aceptar en el mensaje de confirmación para eliminar, se reinicia el caso de uso.	
Precondición	Seleccionar un microorganismo.	
Postcondición	Se reinicia el caso de uso.	
Presunción	La Base de datos se encuentra disponible.	

Casos de uso «Medición»




Figura 49. Diagrama de casos de uso «Medición»

Tabla 22

Descripción del caso de uso «Capturar imagen»

Nombre	Capturar Imagen	
Actor	Experto	
Descripción	Describe el proceso para cargar la imagen del microorganismo para la medición.	
Flujo principal	Eventos Actor	Eventos Sistema
	Cargar imagen desde el explorador <ul style="list-style-type: none"> • Presiona el botón del menú Captura. • Busca la foto y presiona Aceptar. 	<ul style="list-style-type: none"> • Muestra el explorador para buscar la foto a seleccionar. • Carga la foto al panel de captura.
	Cargar imagen desde la base de datos <ul style="list-style-type: none"> • Presiona el botón de cargar imagen de la barra de herramientas. • Selecciona la fecha. • Presiona en el botón Buscar. 	<ul style="list-style-type: none"> • Muestra el formulario de carga de imágenes. • Muestra el calendario del mes actual. • Muestra todas la imágenes almacenadas según la fecha.
	Capturar imagen desde la cámara <ul style="list-style-type: none"> • Presiona el botón de grabar. • Selecciona el objetivo con que se desea tomar la microfotografía y presiona el botón Capturar. 	<ul style="list-style-type: none"> • Muestra la cámara activada en el panel de medición. • Muestra la foto capturada en el panel de medición.
Alternativa	Cargar imagen desde el explorador	Si no se encuentra la foto en el explorador verificar que la extensión de la microfotografía sea .jpg.
	Cargar imagen desde la base de datos	Si no existen microfotografías en la fecha seleccionada, muestra un mensaje de no existen fotografías y se reinicia le caso de uso.
	Capturar imagen desde la cámara	Si no se encuentra conforme con la microfotografía se procede a activar nuevamente la cámara y se reinicia el caso de uso.
Precondición	Ingresar al sistema.	
Postcondición	Cargar imagen desde el explorador	Se procede a la edición.
	Cargar imagen desde la base de datos	Se procede a la edición.
	Capturar imagen desde la cámara	Guardar la imagen en la base de datos.
Presunción	La Base de datos se encuentra disponible.	

Tabla 23

Descripción del caso de uso «Medir»

Nombre	Medir	
Actor	Experto	
Descripción	Describe el proceso para la medición de los microorganismos de la imagen.	
Flujo principal	Eventos Actor	Eventos Sistema
	Medir Diámetros	
	<ul style="list-style-type: none"> • Presiona el botón del lente con el que se realizó la captura de la microfotografía. • Presiona el botón de Diámetros. • Realiza el número deseado de mediciones. • Clic derecho para terminar la medición. 	<ul style="list-style-type: none"> • Establece el factor de medición. • Deshabilita los botones de medición lineal y polilíneal. • Establece las medidas en una sola columna. • Almacena las medidas en la columna. • Habilita los botones de medición lineal y polilíneal.
	Medir Lineal	
<ul style="list-style-type: none"> • Presiona el botón del lente con el que se realizó la captura de la microfotografía. • Presiona el botón de lineal. • Realiza el número deseado de mediciones en par, primero largo y luego ancho de cada microorganismo. • Clic derecho para terminar la medición. 	<ul style="list-style-type: none"> • Establece factor de medición. • Deshabilita los botones de medición diámetros y polilíneal. • Establece las medidas en dos columnas, una para el ancho y la otra para el largo. • Almacena las medidas en la columna. • Habilita los botones de medición diámetro y polilíneal 	
Alternativa	Medir Polilíneal	
	<ul style="list-style-type: none"> • Presiona el botón del lente con el que se realizó la captura de la microfotografía. • Presiona el botón de polilíneal. • Realiza el número deseado de mediciones para el largo y termina con clic derecho. • Presiona nuevamente el botón de polilíneal y realiza la medición del ancho. Clic derecho para terminar. 	<ul style="list-style-type: none"> • Establece el factor de medición. • Deshabilita los botones de medición diámetros y polilíneal. • Establece las medidas en dos columnas, una para el ancho y la otra para el largo. • Almacena las medidas en la columna. • Habilita los botones de medición diámetro y lineal.
	Medir Diámetros	--
	Medir Lineal	--
	Medir Polilíneal	--
Precondición	Edición de foto.	
Postcondición	Medir Diámetros	Se procede a los reportes
	Medir Lineal	Se procede a los reportes
	Medir Polilíneal	Se procede a los reportes
Presunción	La Base de datos se encuentra disponible.	

Tabla 24

Descripción del caso de uso «Editar imagen»

Nombre	Editar Imagen	
Actor	Experto	
Descripción	Describe el proceso para la edición de la imagen.	
Flujo Principal	Eventos Actor	Eventos Sistema
	<ul style="list-style-type: none"> Selecciona el nivel de blanqueamiento de la imagen. 	<ul style="list-style-type: none"> Muestra la microfotografía con los cambios según el nivel de blanqueamiento seleccionado.
Alternativa	Si no presiona Aceptar en el mensaje de confirmación para eliminar, se reinicia el caso de uso.	
Precondición	Seleccionar un microorganismo.	
Postcondición	Se reinicia el caso de uso.	
Presunción	La Base de datos se encuentra disponible.	

Casos de uso «Clasificación»

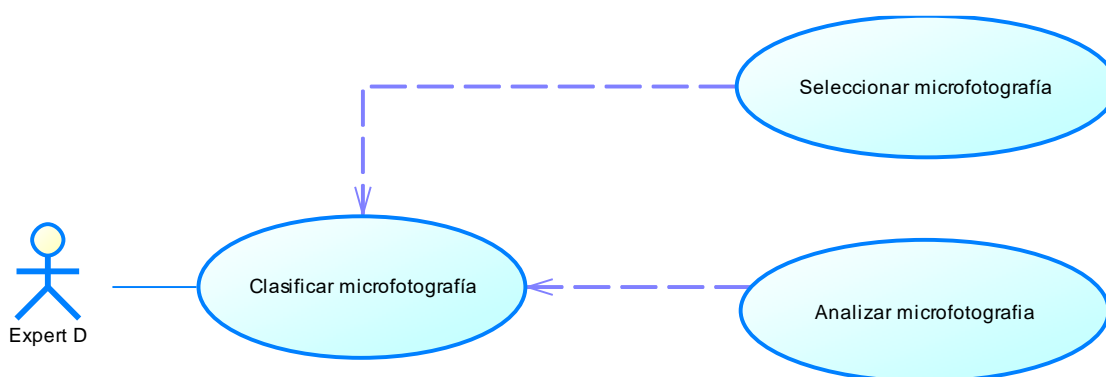


Figura 50. Diagrama de casos de uso «Clasificación»

Tabla 25

Descripción del caso de uso «Clasificación»

Nombre	Clasificar microfotografía	
Actor	Experto	
Descripción	Describe el proceso para la clasificación de la imagen del microorganismo.	
Flujo principal	Eventos Actor	Eventos Sistema
	Seleccionar microfotografía <ul style="list-style-type: none"> Seleccionar la microfotografía que se va a clasificar. 	<ul style="list-style-type: none"> Muestra el explorador para buscar la foto a seleccionar. Carga la foto al panel de clasificación.
	Analizar la microfotografía <ul style="list-style-type: none"> Selecciona la fotografía. 	<ul style="list-style-type: none"> Carga la foto a la red neuronal.
	Capturar imagen desde la cámara <ul style="list-style-type: none"> Presiona Clasificar 	<ul style="list-style-type: none"> Muestra el resultado de la clasificación.
Precondición	Realizar los reportes.	
Presunción	La Base de datos se encuentra disponible.	

3.5.2. Diagramas de secuencia

3.5.2.1. Gestión de usuarios




Figura 51. Diagrama de secuencia «Gestión de Usuarios»

3.5.2.2. Gestión de microorganismos




Figura 52. Diagrama de secuencia «Gestión de microorganismos»

3.5.2.3. Gestión de reportes




Figura 53. Diagrama de secuencia «Gestión de reportes»

3.5.2.4. Realizar medición




Figura 54. Diagrama de secuencia «Realizar medición»

3.5.2.5. Generar reporte




Figura 55. Diagrama de secuencia «generar reporte»

3.5.2.6. Clasificar microfotografía




Figura 56. Diagrama de secuencia «Clasificar microfotografía»

3.5.3. Diagrama de clases




Figura 57. Diagrama de clases

3.5.4. Diagrama de base de datos «labfitopatologia»




Figura 58. Modelo de la base de datos «labfitopatologia»

3.5.5. Mapa de pantallas

A continuación, se presentan como el experto puede navegar por las diferentes pantallas del sistema:




Figura 59. Navegabilidad de interfaces

3.5.6. Interfaces

3.5.6.1. Ventana de inicio de sesión



Figura 60. Ventana de inicio de sesión

3.5.6.2. Ventana principal




Figura 61. Ventana principal

3.5.6.3. Ventana de carga de imágenes

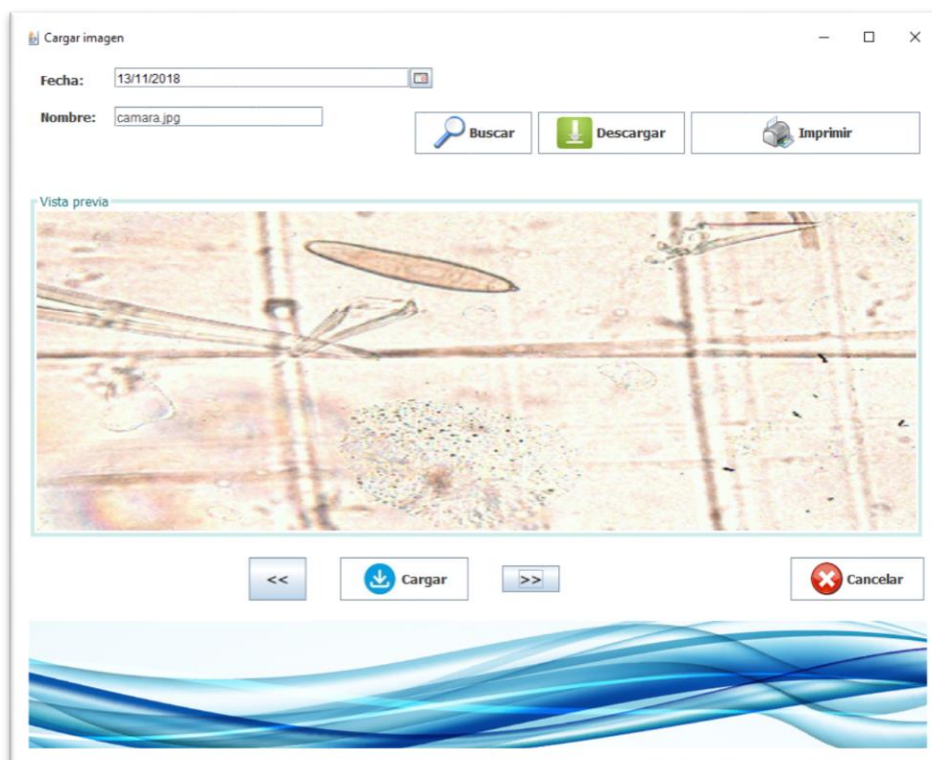


Figura 62. Ventana de carga de imágenes

3.5.6.4. Ventana de reportes

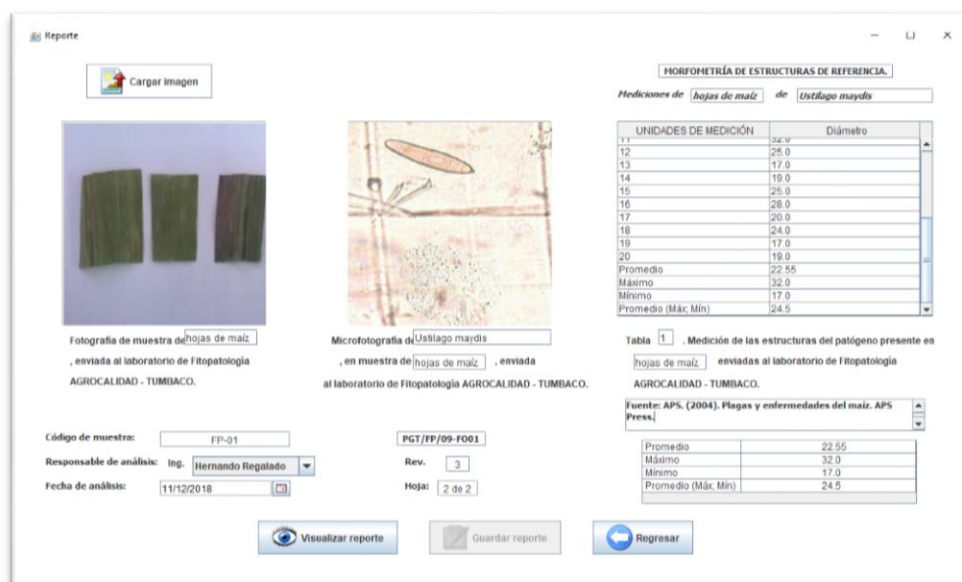


Figura 63. Ventana de reportes

3.5.6.5. Ventana de previsualización de reportes



Figura 64. Ventana de previsualización de reportes

3.5.6.6. Ventana de almacenamiento de reportes

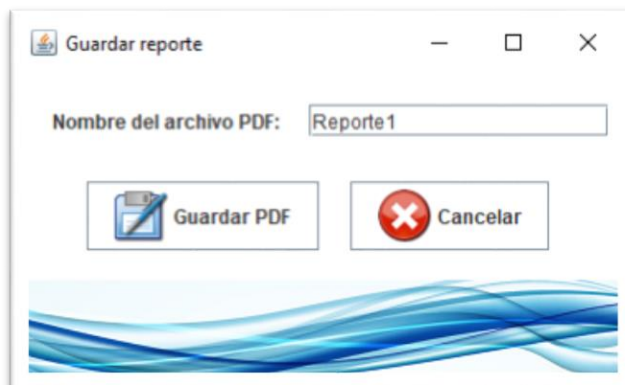


Figura 65. Ventana de almacenamiento de reportes

3.5.6.7. Ventana de gestión de reportes

Gestión de reportes

Buscar reporte por:

Nombre:

Código de muestra:

Fecha:

Buscar

Id reporte	Nombre	Código de muestra	Fecha	Archivo
4	Reporte1	FP-3	2018-11-30	
5	Reporte4	FP-4	2018-11-30	
6	Hoja de maíz	FP-03	2018-11-30	

Eliminar reporte

Figura 66. Ventana de gestión de reportes

3.5.6.8. Ventana de gestión de usuarios

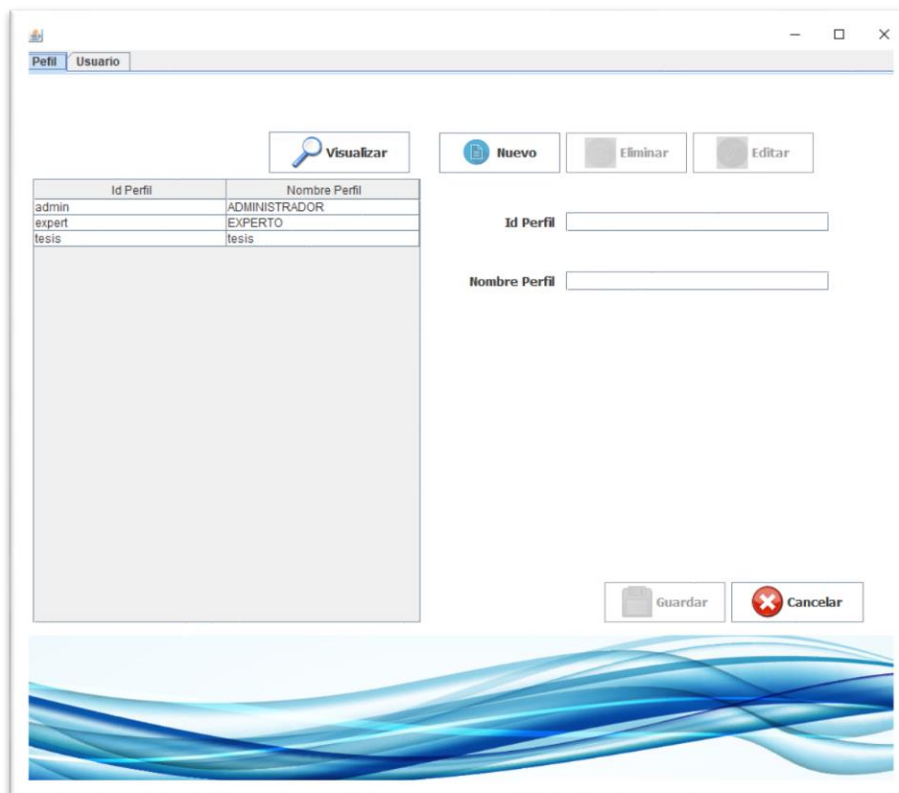


Figura 67. Ventana de gestión de usuarios

3.5.6.9. Ventana de gestión de microorganismos

Id Micro	Nombre	Max Largo	Min Largo	Max Ancho	Min Ancho	Observaciones
	Curvularia lunata	0.0	0.0	0.0	0.0	
	Ustilago maydis	0.0	0.0	0.0	0.0	
	Stenocarpella mac.	0.0	0.0	0.0	0.0	
	Helminthosporium	0.0	0.0	0.0	0.0	

Figura 68. Ventana de gestión de microorganismos

3.5.7. Aplicación de Técnicas de Visión Artificial

3.5.7.1. Procesamiento de las imágenes

Como parte del procesamiento de la imagen, se utilizó la técnica de histogramas, misma que permitió modificar las características de la microfotografía como el contraste y el brillo.

3.5.7.2. Histograma de una imagen a color

En el caso de las imágenes a color, el histograma indicó la frecuencia con la que aparecían los diferentes niveles de cada canal RGB (Rojo, Verde y Azul), como se observa en la figura 68.




Figura 69. Histograma de imagen a color

3.5.7.3. Ecuación de histogramas

Al ecualizar los histogramas, se aplicó el filtro de balanceo de blanco o de equilibrio del color. El histograma se modifica cuando el valor de cada canal es multiplicado por un factor independiente. Si el factor tiende a cero, la imagen original adquiere tonos más oscuros. Por el contrario, si el factor es mayor que uno, la imagen original adquiere tonos más claros.

A continuación, se muestra el histograma multiplicado por el factor con un valor de 0.50, dando como resultado que el valor del tono de todos los puntos de la imagen se desplace hacia tonos más oscuros. Entonces el nivel de intensidad de los píxeles se acercó a 0 (negro), dando lugar a una imagen oscurecida.





Figura 70. Histograma aplicado un factor de 0.50

A continuación, se muestra el histograma multiplicado por el factor con un valor de 2.08, dando como resultado que el valor del tono de todos los puntos de la imagen se desplace hacia tonos más claros. Entonces el nivel de intensidad de los pixeles se acercó a 255 (blanco), dando lugar a una imagen aclarada.





Figura 71. Histograma aplicado un factor de 2.08

3.5.8. Entrenamiento de los Clasificadores implementados

3.5.8.1. Entrenamiento aplicando el clasificador Vecinos más cercanos

Al aplicar el algoritmo del Vecino más cercano se obtuvieron los siguientes resultados que se describen a continuación:

a. Análisis de data

El análisis se realizó con Python utilizando las librerías matplotlib, pandas, numpy y utilizando el clasificador KNeighborsClassifier. El análisis de la data se trabajó con 200 mediciones, 50 medidas tanto de largo, ancho y diámetro del microorganismo por cada especie.

A continuación, se muestra como se estructuró la data para el análisis y aplicación del algoritmo.

	nombreEt	Nombre	Largo	Ancho	Diametro
0	1	Curvularia lunata	21.70	8.24	0.0
1	1	Curvularia lunata	23.35	8.51	0.0
2	1	Curvularia lunata	29.94	8.51	0.0
3	1	Curvularia lunata	29.94	8.51	0.0
4	1	Curvularia lunata	25.82	9.61	0.0

Figura 72. Estructura de una parte de la data

En la figura 73 se muestra gráficamente a cada una de las especies de los microorganismos o plagas de la planta de maíz, clasificadas según sus medidas de largo y ancho. En el caso de *Ustilago maydis* se colocaron las medidas del diámetro debido a que su forma es circular.

Además, se puede observar con color verde al microorganismo *Helminthosporium maydis*, con azul al microorganismo *Stenorcapella macrospora*, con rojo al microorganismo *Curvularia lunata* y con rosado al microorganismo *Ustilago maydis*.

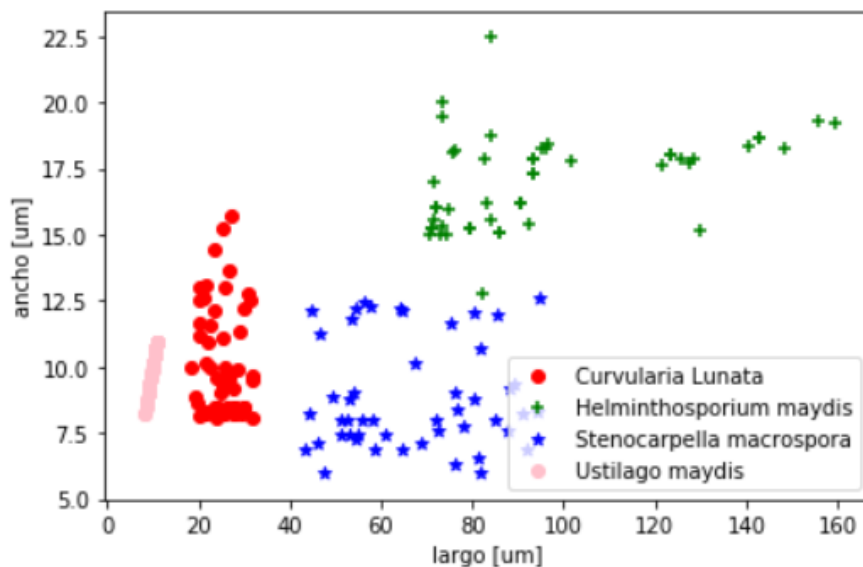


Figura 73. Gráfica de los microorganismos de la planta de maíz

b. Aplicación del algoritmo

El algoritmo fue calculado para los nueve vecinos más cercanos, y se obtuvo el 98 % de precisión. A continuación, se muestra la gráfica del porcentaje de clasificación versus el número de vecinos más cercanos, en donde se puede observar con azul a la validación que alcanza el 100 % de exactitud y con naranja al entrenamiento que alcanzó el 98 % de exactitud.




Figura 74. Gráfica de exactitud de clasificación aplicando el algoritmo de vecinos más cercanos

3.5.8.2. Entrenamiento aplicando el clasificador Random Forest

Al aplicar el algoritmo del bosque Aleatorio se obtuvieron los siguientes resultados que se describen a continuación:

a. Análisis de data

El análisis de la data se trabajó con 200 mediciones, 50 medidas tanto de largo, ancho y diámetro del microorganismo por cada especie.

A continuación, se muestra como se estructuró la data en un archivo .csv, para el análisis y aplicación del algoritmo:

```

Curvularia lunata,27.82,9.22,0
Curvularia lunata,31.78,9.54,0
Curvularia lunata,21.58,13.1,0
Curvularia lunata,21.2,12.64,0
Helminthosporium maydis,70.05,15.93,0
Helminthosporium maydis,73.35,19.5,0
Helminthosporium maydis,71.42,17.03,0
Helminthosporium maydis,82.69,17.85,0
Helminthosporium maydis,84,22.5,0
Helminthosporium maydis,92.3,15.38,0
Helminthosporium maydis,93.13,17.85,0
Helminthosporium maydis,125.82,17.85,0
Helminthosporium maydis,74.83,15.93,0
Helminthosporium maydis,73.35,20,0
Helminthosporium maydis,85.71,15.1,0
Helminthosporium maydis,93.13,17.3,0
Helminthosporium maydis,90.65,16.2,0
Helminthosporium maydis,72.25,16.02,0
Helminthosporium maydis,79.34,15.23,0

```

Figura 75. Parte de la data con la que se entrenó el clasificador Random Forest

b. Aplicación del algoritmo

Al aplicar el algoritmo de clasificación de Random forest se obtuvo un porcentaje de exactitud de 99 %.




Figura 76. Porcentaje exactitud de Random Forest

3.5.9. Entrenamiento de las redes neuronales implementadas

3.5.9.1. Entrenamiento Perceptrón Simple

Para el entrenamiento del Perceptrón Simple se ocupó como data el archivo .csv de mediciones donde se encuentran 150 mediciones pertenecientes a los microorganismos, 50 medidas tanto de largo, ancho y diámetro del microorganismo por cada especie.

```

Helminthosporium maydis,82.69,17.85,0
Helminthosporium maydis,84,22.5,0
Helminthosporium maydis,92.3,15.38,0
Helminthosporium maydis,93.13,17.85,0
Helminthosporium maydis,125.82,17.85,0
Helminthosporium maydis,74.83,15.93,0
Helminthosporium maydis,73.35,20,0
Helminthosporium maydis,85.71,15.1,0
Helminthosporium maydis,93.13,17.3,0
Helminthosporium maydis,90.65,16.2,0
Helminthosporium maydis,72.25,16.02,0
Helminthosporium maydis,79.34,15.23,0

```

Figura 77. Parte de la data con la que se entrenó el Perceptrón Simple

El entrenamiento para el perceptrón se realizó con tres entradas que representan el largo, ancho y diámetro de las medidas de cada microorganismo, se realizó para 10 épocas. En la siguiente imagen se visualiza la gráfica del entrenamiento del perceptrón, donde se puede observar que sufrió sobreaprendizaje.

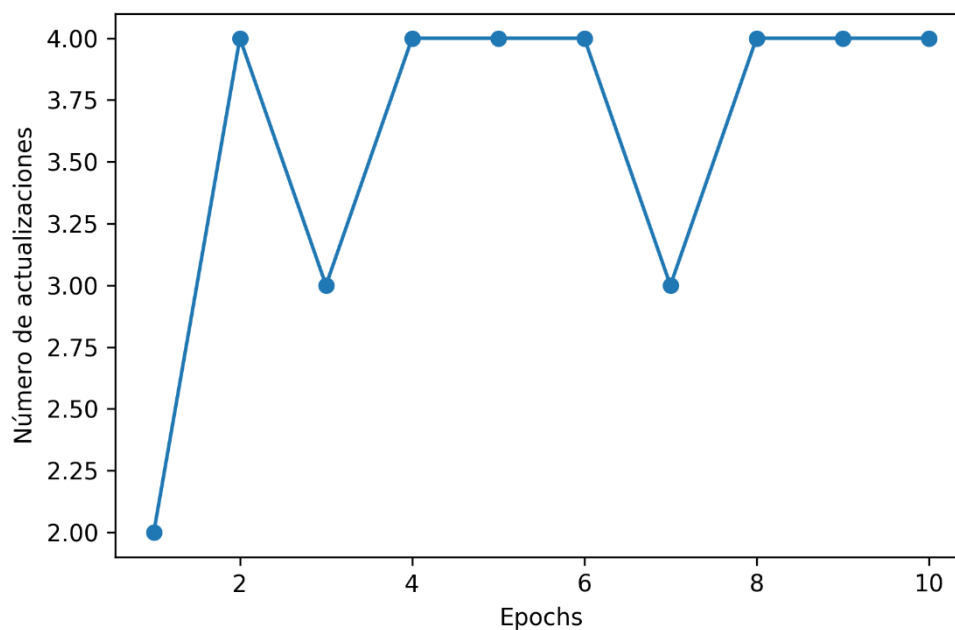


Figura 78. Entrenamiento Perceptrón Simple

El sobreaprendizaje se produce debido a la poca data con la que se le entrenó al perceptrón, por lo cual la clasificación obtuvo poca precisión como se muestra en el

interior del círculo rojo de la imagen.




Figura 79. Error en la Clasificación usando el Perceptrón Simple.

Durante el entrenamiento del perceptrón simple, en la fase de entrenamiento y validación, en la época 10 se obtuvieron valores de error de clasificación (loss) superiores al 60 %.




Figura 80. Porcentaje de error del Perceptrón Simple

3.5.9.2. Entrenamiento Red Neuronal Convolucional

De las imágenes, se utilizó para el entrenamiento 200 microfotografías, 66 por cada clase y para la validación 120 microfotografías, 40 para cada clase. Además, se entrenó a la red con 10 épocas de 500 pasos para cada época.

```

Epoch 1/10
500/500 [=====] - 528s 1s/step - loss: 0.3846 - acc: 0.8735 - val_loss: 0.0383 - val_acc: 0.9773
Epoch 2/10
500/500 [=====] - 522s 1s/step - loss: 0.0529 - acc: 0.9843 - val_loss: 0.0515 - val_acc: 0.9773
Epoch 3/10
500/500 [=====] - 516s 1s/step - loss: 0.0198 - acc: 0.9943 - val_loss: 0.0971 - val_acc: 0.9773
Epoch 4/10
500/500 [=====] - 531s 1s/step - loss: 0.0020 - acc: 0.9999 - val_loss: 0.0968 - val_acc: 0.9773
Epoch 5/10
500/500 [=====] - 544s 1s/step - loss: 0.0059 - acc: 0.9983 - val_loss: 0.0427 - val_acc: 0.9773
Epoch 6/10
500/500 [=====] - 536s 1s/step - loss: 8.7028e-04 - acc: 0.9999 - val_loss: 0.1343 - val_acc: 0.9773
Epoch 7/10
500/500 [=====] - 533s 1s/step - loss: 0.0666 - acc: 0.9827 - val_loss: 0.1304 - val_acc: 0.9773
Epoch 8/10
500/500 [=====] - 541s 1s/step - loss: 0.0334 - acc: 0.9908 - val_loss: 0.1847 - val_acc: 0.9545
Epoch 9/10
500/500 [=====] - 566s 1s/step - loss: 0.0096 - acc: 0.9975 - val_loss: 0.2379 - val_acc: 0.9773
Epoch 10/10
500/500 [=====] - 564s 1s/step - loss: 0.0018 - acc: 0.9997 - val_loss: 0.1719 - val_acc: 0.9773

```

Figura 81. Descripción del porcentaje de precisión en el entrenamiento durante el entrenamiento

En la siguiente figura, se muestra la gráfica de la precisión que alcanza el algoritmo versus las épocas durante el entrenamiento. En azul se muestra los resultados obtenidos de las imágenes del entrenamiento y en naranja los resultados de las imágenes de la validación. Se puede observar que después de 10 épocas se obtuvieron valores de 99 % de precisión en el entrenamiento y 98 %, en la validación.




Figura 82. Gráfica de la precisión de la predicción en cada época

En la figura siguiente se muestra la gráfica del error que obtuvo el algoritmo versus las épocas durante el entrenamiento. De igual forma que en la figura anterior, se muestran en azul los valores obtenidos para las imágenes de entrenamiento y en naranja los valores obtenidos para las imágenes de validación. El entrenamiento de la red en ambos casos en la época 10 obtiene valores de error de clasificación (loss) inferiores al 20 %.




Figura 83. Gráfica del porcentaje de error que se obtuvo durante el entrenamiento de la red neuronal convolucional

3.6. Instalación

Debido al alcance definido en el proyecto, solo se instaló el prototipo en el Laboratorio de Fitopatología, ya que el SBC requiere seguir probando con casos, con el objetivo de recolectar más microfotografías para que el entrenamiento de la red neuronal logre mejorar el porcentaje de certeza en cuanto a la clasificación del microorganismo.

3.7. Mantenimiento

En el alcance del presente trabajo no se ha planteado la fase de mantenimiento ya que se requiere continuar con el proceso de recolección y prueba de casos. Se podrá actualizar y dar mantenimiento cuando el laboratorio de Fitopatología de AGROCALIDAD

disponga de una mayor cantidad de microfotografías (al menos 2000 microfotografías por cada tipo de microorganismo) esto con el fin de que la red neuronal continúe realizando entrenamiento y aprendizaje para lograr un diagnóstico más preciso.

CAPÍTULO 4

VALIDACIÓN Y RESULTADOS

En este capítulo mostramos los resultados obtenidos con cada una de las redes neuronales implementadas, así como la comparación entre los resultados obtenidos y los tiempos entre la aplicación y el procedimiento manual.

4.1. Resultados de los Clasificadores Implementados

4.1.1. Clasificador Vecinos más cercanos

A continuación, se muestra un ejemplo de la prueba del algoritmo de clasificación de los vecinos más cercanos, se ingresó la medida de largo igual a 84.24, la medida de ancho igual a 17.84 y la medida de diámetro igual a 0. Se obtuvo la clasificación de *Helminthosporium maydis* con un 98 % de precisión.

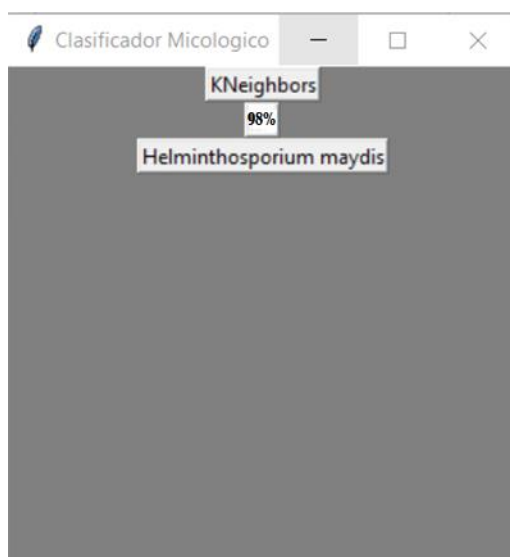


Figura 84. Clasificador aplicando el algoritmo de Vecinos más cercanos

4.1.2. Clasificador Random Forest

Al aplicar el algoritmo de clasificación de Random forest se obtuvo un porcentaje de exactitud de 99 %. A continuación, se muestra un ejemplo de los resultados de aplicar el algoritmo con los siguientes datos: largo igual a 92.3, ancho igual a 15.38 y diámetro igual a 0.




Figura 85. Clasificador aplicando el algoritmo Random forest

4.1.3. Comparación Clasificadores

La mayor precisión para los dos clasificadores se produjo cuando el tamaño de la muestra de entrenamiento se encontraba equilibrada en cantidad respecto a cada microorganismo. A continuación, se muestran los resultados máximos de precisión de los clasificadores, donde K-Nearest Neighbours obtuvo el 98 % y Random Forest obtuvo un 99 %.




Figura 86. Porcentaje de presión de la clasificación

En base a los resultados obtenidos en el entrenamiento de los algoritmos de clasificación se escogió el clasificador **Random Forest** ya que obtuvo el mayor porcentaje de éxito al clasificar el microorganismo.

Por lo tanto, este algoritmo fue implementado en el módulo de **Morfometría** con el objetivo de realizar la clasificación automática a partir de las medidas del microorganismo, obtenidas durante la medición.

4.2. Resultados de las Redes Neuronales implementadas

Como se concluyó en el apartado 3.6.9 del capítulo tres, la escasa cantidad de data con la que se contó para el entrenamiento del perceptrón simple, ocasionó un sobreaprendizaje. El error no descendió a un nivel mínimo aceptable que justifique la utilización de esta red, por lo que se la descartó en la fase de pruebas.

4.2.1. Red Neuronal Convolutacional

A continuación, se detalla las pruebas realizadas utilizando la Red Neuronal Convolutacional.

Para las pruebas se utilizaron las fotografías previamente procesadas. En la figura

87 se observa parte de las muestras de la base de datos de imágenes con las que se realizaron las pruebas de validación de la red neuronal convolucional.





Figura 87. Parte de la muestra con las que se realizó las pruebas y validaciones de la red convolucional.

Al analizar los resultados obtenidos por microorganismo se observa que se obtuvo el mismo porcentaje de éxito en las clases *Helminthosporium maydis* y *Ustilago maydis*, a diferencia de *Curvularia lunata* en la que se obtuvo un porcentaje menor de éxito debido a que este microorganismo tiene una estructura más compleja a diferencia de los otros dos microorganismos.

Tabla 26*Porcentaje de éxito en la clasificación*

Microorganismo	Éxito
<i>Helmitosporium maydis</i>	96 %
<i>Ustilago maydis</i>	97 %
<i>Curvularia lunata</i>	98 %

La figura 88 muestra el porcentaje de éxito en la predicción de cada microorganismo en una muestra de 50 pruebas por especie, donde se alcanzó un 96 % de precisión para el microorganismo *Helminthosporium maydis*, un 97 % para el microorganismo *Curvularia lunata* y un 98 % para *Ustilago maydis*.

**Figura 88.** Porcentaje de éxito en la clasificación por microorganismo

De los resultados de éxito por especie, se calculó el promedio de éxito total de predicción de la red neuronal, donde se obtuvo un 98 % de éxito en la clasificación del microorganismo, como se muestra en la figura 89.




Figura 89. Porcentaje de éxito en la clasificación total de los microorganismos

4.2.2. Comparación entre Redes Neuronales

Al realizar la comparación de los resultados entre las redes neuronales, se encontró que el Perceptrón Simple obtuvo un 40 % de éxito en la clasificación y que la red neuronal convolucional obtuvo un 98 % de éxito en la clasificación, como se muestra en la siguiente imagen.




Figura 90. Comparativa de porcentajes de éxito en la clasificación entre las redes neuronales

Con base en los resultados del porcentaje de éxito de clasificación y debido a que la Red Neuronal Convolutacional hace uso de las características propias de la imagen, y no de las mediciones del microorganismo, se seleccionó la **Red Neuronal Convolutacional** para ser implementada en el módulo de **Diagnóstico**.

4.2.3. Comparativa entre Red Neuronal Convolutacional y procedimiento actual

A continuación, se muestran los resultados al comparar la predicción usando la red neuronal convolutacional versus el procedimiento actual que se lleva a cabo en el Laboratorio de Fitopatología.




Figura 91. Comparativa del tiempo de clasificación entre la red neuronal y el procedimiento manual

La figura 91, muestra en azul los tiempos que se demora el sistema SDM, en el proceso de realizar la clasificación, donde se demora 3:18 minutos en obtener la imagen y 1:30 minutos en realizar la clasificación, con un total de 5:08 minutos versus en color naranja el tiempo en que se realiza la clasificación actualmente en el laboratorio, donde se demora 3:18 minutos en obtener la imagen y 25:33 minutos en realizar la clasificación con un total de 28:51 minutos. Claramente se puede observar que la aplicación de la red neuronal para el diagnóstico ahorra 22:23 minutos en el proceso de clasificación.

4.3. Resultados del módulo de Morfometría

Para verificar la validez y la confiabilidad de los datos entregados por el Sistema de Diagnóstico Micológico (SDM), se procedió a realizar el procedimiento de mediciones y generación de reportes del microorganismo *Ustilago maydis*, tanto en el software cellSens de Olympus, como en el sistema desarrollado SDM.

4.3.1. Procedimiento de morfometría en el cellSens

El experto seleccionó una placa preparada con el microorganismo *Ustilago maydis* y la colocó en el microscopio Olympus BX43. Luego, abrió la aplicación cellSens y activó la cámara, para seleccionar un campo visual idóneo, que contenga microorganismos representativos:




Figura 92. Microscopio BX43 y software cellSens

Una vez elegido el campo visual, realizó un blanqueamiento del fondo de la imagen, para destacar las conidias. Luego, presionó el botón “Arbitrary line” para medir diámetros, y procedió a tomar las medidas de 20 microorganismos:




Figura 93. Fotografía realizada durante el proceso de mediciones realizadas con cellSens

Cuando las mediciones fueron completadas, se procedió a generar el archivo de Excel que contenía los 20 datos recién registrados:

	A	B	C	D	E	F	G	H
1	Type	Name	Point X	Point Y	Length (µm)	Angle	Area	Perimeter
2	Arbitrary Line				10.99			
3	Arbitrary Line				9.81			
4	Arbitrary Line				10.05			
5	Arbitrary Line				8.95			
6	Arbitrary Line				10.13			
7	Arbitrary Line				10.50			
8	Arbitrary Line				8.96			
9	Arbitrary Line				8.70			
10	Arbitrary Line				9.52			
11	Arbitrary Line				10.00			
12	Arbitrary Line				10.99			
13	Arbitrary Line				10.02			
14	Arbitrary Line				9.71			
15	Arbitrary Line				10.40			
16	Arbitrary Line				9.51			
17	Arbitrary Line				9.76			
18	Arbitrary Line				10.05			
19	Arbitrary Line				8.70			
20	Arbitrary Line				10.76			
21	Arbitrary Line				9.78			

Figura 94. Hoja electrónica exportada por cellSens

Los datos de la hoja electrónica exportada por cellSens se copiaron a una plantilla preparada de Excel, con fórmulas para que se realicen los cálculos correspondientes a este microorganismo.

El dato más importante del informe de análisis es la desviación estándar, pues le permite al experto corroborar que las mediciones fueron realizadas correctamente, cuando este valor no sobrepasa a 1.

Para realizar ese cálculo, la plantilla de Excel usa la siguiente fórmula:

$$= DESVEST(promedio1;promedio2)$$

Donde:

- *promedio1*: media aritmética de las 20 mediciones realizadas con cellSens
- *promedio2*: media aritmética entre los valores máximo y mínimo posibles para *Ustilago maydis* (diámetro máximo = 11 μm ; diámetro mínimo = 8 μm (White, 2004)).

En las mediciones realizadas con cellSens, *promedio1* fue de **9.86 μm** y la desviación estándar fue de **0.257740422**.

Se adjuntaron la fotografía y la microfotografía, y se llenaron los campos con la información requerida, para obtener así el informe de análisis:



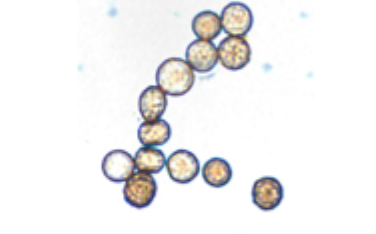
A	B	C	D	E	F	G	H																																																		
1	 AGROCALIDAD AGENCIA ECUATORIANA DE ASESORAMIENTO DE LA CALIDAD DEL AGRO	LABORATORIO DE FITOPATOLOGIA V. e Interconcha Km. 14x y Eloy Alfaro, Granja del MAGAP, Tumbaco - Quito T: 066 - 82-2922-882/2922-886/2922-885				PGT/FP/09-FO01																																																			
2		INFORME DE ANÁLISIS				Rev. 3 Hoja 2 de 2																																																			
3		Código de muestra de Laboratorio: FP-16-8533																																																							
4																																																									
5	Fotografía de muestra de frasco de maiz, enviada al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.		Microfotografía de Botrytis dothidea sp., en muestra de frasco de maiz, enviada al Laboratorio de Fitopatología AGROCALIDAD - TUMBACO.																																																						
32	MORFOMETRÍA DE ESTRUCTURAS MICELIALES DE REFERENCIA <i>Mediciones de unidades de Botrytis dothidea</i>																																																								
33	UNIDADES DE MEDICIÓN																																																								
34	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="width: 80%;">UNIDADES DE MEDICIÓN</th> <th style="width: 20%;">Medición</th> </tr> </thead> <tbody> <tr><td>1</td><td>18.53</td></tr> <tr><td>2</td><td>3.81</td></tr> <tr><td>3</td><td>18.85</td></tr> <tr><td>4</td><td>8.35</td></tr> <tr><td>5</td><td>18.19</td></tr> <tr><td>6</td><td>18.58</td></tr> <tr><td>7</td><td>8.36</td></tr> <tr><td>8</td><td>8.78</td></tr> <tr><td>9</td><td>3.52</td></tr> <tr><td>10</td><td>18.88</td></tr> <tr><td>11</td><td>18.53</td></tr> <tr><td>12</td><td>18.82</td></tr> <tr><td>13</td><td>3.74</td></tr> <tr><td>14</td><td>18.48</td></tr> <tr><td>15</td><td>3.51</td></tr> <tr><td>16</td><td>3.76</td></tr> <tr><td>17</td><td>18.85</td></tr> <tr><td>18</td><td>8.78</td></tr> <tr><td>19</td><td>18.76</td></tr> <tr><td>20</td><td>3.78</td></tr> <tr><td colspan="2" style="text-align: center;">Promedio</td></tr> <tr><td colspan="2" style="text-align: center;">Mediana</td></tr> <tr><td colspan="2" style="text-align: center;">Modo</td></tr> <tr><td colspan="2" style="text-align: center;">Promedio (MSQ) H. 0.1</td></tr> </tbody> </table>							UNIDADES DE MEDICIÓN	Medición	1	18.53	2	3.81	3	18.85	4	8.35	5	18.19	6	18.58	7	8.36	8	8.78	9	3.52	10	18.88	11	18.53	12	18.82	13	3.74	14	18.48	15	3.51	16	3.76	17	18.85	18	8.78	19	18.76	20	3.78	Promedio		Mediana		Modo		Promedio (MSQ) H. 0.1	
UNIDADES DE MEDICIÓN	Medición																																																								
1	18.53																																																								
2	3.81																																																								
3	18.85																																																								
4	8.35																																																								
5	18.19																																																								
6	18.58																																																								
7	8.36																																																								
8	8.78																																																								
9	3.52																																																								
10	18.88																																																								
11	18.53																																																								
12	18.82																																																								
13	3.74																																																								
14	18.48																																																								
15	3.51																																																								
16	3.76																																																								
17	18.85																																																								
18	8.78																																																								
19	18.76																																																								
20	3.78																																																								
Promedio																																																									
Mediana																																																									
Modo																																																									
Promedio (MSQ) H. 0.1																																																									
35	Tabla 4. Medición de las estructuras del patógeno presente en frasco de maiz enviada al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.																																																								
36	Fuente: White, D. [2004]. <i>Compendium of Cereals Diseases. The American Phytopathological Society. MSB.</i>																																																								
37	Responsable de Medición: <u>Ing. Hernando Regalado</u>																																																								
38	Fecha de Medición: <u>Junero, 18 de enero de 2019</u>																																																								
70	<table border="1" style="width: 100%; border-collapse: collapse;"> <tbody> <tr> <td style="width: 80%;">Promedio</td> <td style="width: 20%; text-align: center;">3.58</td> </tr> <tr> <td>Mediana</td> <td style="text-align: center;">11.88</td> </tr> <tr> <td>Modo</td> <td style="text-align: center;">8.88</td> </tr> </tbody> </table>							Promedio	3.58	Mediana	11.88	Modo	8.88																																												
Promedio	3.58																																																								
Mediana	11.88																																																								
Modo	8.88																																																								

Figura 95. Reporte en Excel elaborado por el experto

4.3.2. Procedimiento de morfometría realizado con el prototipo del sistema desarrollado

El experto colocó la misma placa portaobjetos en otro microscopio acoplado a la cámara MEM1300:




Figura 96. Sistema SDM

A continuación, ejecutó la aplicación SDM e ingresó con su nombre de usuario y contraseña. Activó la cámara y procedió a ubicarse en el mismo campo óptico en que se realizaron las mediciones anteriores. Luego, capturó la microfotografía y la almacenó en la base de datos. Posteriormente, usó el control manual deslizante para blanquear el fondo de la microfotografía y destacar las conidias, y procedió a realizar las mediciones de los mismos 20 microorganismos de la primera prueba, presionando el botón “Diámetros”:




Figura 97. Mediciones morfométricas realizadas en SDM

Cuando se completaron las mediciones, se procedió a presionar el botón “Generar reporte”. El clasificador del sistema SDM mostró un cuadro de diálogo con el mensaje de que se trataba del microorganismo “*Ustilago maydis*”:




Figura 98. Cuadro de diálogo del clasificador

Para realizar el cálculo de la desviación estándar en la aplicación SDM, se utiliza la siguiente fórmula:

$$\sigma = \sqrt{\sigma^2} = \frac{(prom1 - \frac{prom1 + prom2}{2})^2 + (prom2 - \frac{prom1 + prom2}{2})^2}{n - 1}$$

Donde:

- σ : desviación estándar de la muestra
- σ^2 : varianza
- $prom1$: media aritmética de las 20 mediciones realizadas con SDM


- *prom2*: media aritmética entre los valores máximo y mínimo posibles para *Ustilago maydis* (diámetro máximo = 11 μm ; diámetro mínimo = 8 μm (White, 2004))
- n: número de mediciones

En las mediciones realizadas con SDM, *prom1* fue de **9.87 μm** y la desviación estándar fue de **0.258447529**.

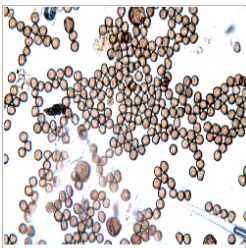
El experto presionó el botón “Aceptar” y procedió a llenar los campos a incluirse en el informe de análisis y a adjuntar la fotografía de la muestra:

Reporte

Cargar imagen



Fotografía de muestra de frutos de maíz, enviada al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.



Microfotografía de Ustilago maydis, en muestra de frutos de maíz, enviada al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.

MORFOMETRÍA DE ESTRUCTURAS DE REFERENCIA.

Mediciones de *conidias* de *Ustilago maydis*

UNIDADES DE MEDICIÓN	Diámetro
1	10,99
2	9,81
3	10,05
4	8,95
5	10,13
6	10,50
7	8,96
8	8,70
9	9,52
10	10,00
11	10,99
12	10,02
13	9,71
14	10,40

Tabla 1 Medición de las estructuras del patógeno presente en frutos de maíz enviadas al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.

Fuente: White, D. (2004). Compendium of Corn Diseases. The American Phytopathological Society, USA.

Promedio	9.50
Máximo	11.00
Mínimo	8.00
Desviación estándar	0.257740722

Código de muestra: FP-16-0539 PGT/FP/09-F001

Fecha de análisis: 16/01/2019 Rev. 3

Hoja: 2 de 2

Visualizar reporte Guardar reporte Regresar

Figura 99. Elaboración del informe de análisis en SDM

Por último, el experto presionó el botón “Visualizar reporte”, con lo que se desplegó una ventana con el reporte del informe de análisis en formato PDF:

JasperViewer


AGROCALIDAD
CORPORACIÓN VENEZOLANA DE INVESTIGACIÓN AGROPECUARIA

LABORATORIO DE FITOPATOLOGÍA
Via Intercomunal Km. 145 y Elby Adams,
Caracas del MAMP, Venezuela - Guatopo

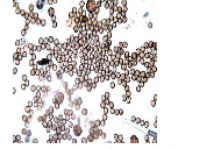
PGT/FP/09-F001
Rev. 3

INFORME DE ANÁLISIS
Hoja 2 de 2

Código de muestra de laboratorio: FP-16-0539



Fotografía de muestra de frutos de maíz, enviada al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.



Microfotografía de Ustilago maydis, en muestra de frutos de maíz, enviada al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.

MORFOMETRÍA DE ESTRUCTURAS DE REFERENCIA.

Mediciones de unidades de Ustilago maydis

UNIDADES DE MEDICIÓN	Diámetro
1	7,97
2	9,34
3	7,42
4	9,62
5	9,62
6	10,44
7	7,97
8	10,16
9	9,34
10	8,79
11	8,24
12	7,97
13	8,79
14	8,52
15	8,52
16	9,34
17	8,34
18	9,62
19	8,24
20	9,07
Promedio	8,91
Máximo	10,44
Mínimo	7,42
Promedio (Max. Min)	8,93

Tabla 1. Fotografía de muestra de frutos de maíz enviadas al laboratorio de Fitopatología AGROCALIDAD - TUMBACO.

Fuente: White, D. (2014). *Compendium of Corn Diseases*. The American Phytopathological Society, USA.

Fecha de Análisis: miércoles, 16 de enero de 2019

Responsable de Análisis: Ing. Homando Rogalado

Figura 100. Reporte en PDF generado por SDM

4.3.3. Comparativa de los resultados obtenidos entre cellSens y SDM

Las mediciones morfométricas obtenidas con cada sistema, así como los valores calculados con las mismas, se muestran a continuación:

Tabla 27

Datos del microorganismo Ustilago maydis obtenidos con cellSens y SDM

Unidades de medición	Software cellSens	Sistema SDM
1	10.99	10.89
2	9.81	9.95
3	10.05	10.62
4	8.95	9.01
5	10.13	10.26
6	10.50	10.57
7	8.96	9.01
8	8.70	8.70
9	9.52	9.64
10	10.00	10.26
11	10.99	10.87
12	10.02	10.19
13	9.71	9.64
14	10.40	10.26
15	9.51	9.01
16	9.76	9.64
17	10.05	10.26
18	8.70	8.70
19	10.76	10.57
20	9.78	9.64
Promedio	9.86	9.87
Máximo	10.99	10.87
Mínimo	8.70	8.70
Promedio (Máx; Mín)	9.85	9.79
Desviación estándar	0.257740422	0.258447529

Con base en las mediciones morfométricas realizadas a los microorganismos, se determinó que la media aritmética de los 20 diámetros realizados con cellSens fue de 9.86 μm , mientras que la media aritmética de las medidas obtenidas con el Sistema de Diagnóstico Micológico fue de 9.87 μm , lo que da una diferencia de 0.01 μm entre ambos promedios como se muestra en la figura 101.




Figura 101. Datos del microorganismo Ustilago maydis obtenidos con cellSens y SDM

La desviación estándar calculada con los datos obtenidos a través del software cellSens se ubicó en 0.257740422, mientras que la obtenida con el cálculo de los datos obtenidos mediante el sistema SDM fue de 0.258447529, por lo que la diferencia entre las dos medidas de dispersión es de 0.000707. Al ubicarse ambos valores por debajo de la unidad, se garantiza que las mediciones son confiables.




Figura 102. Comparativa desviación estándar entre CellSens y SDM

Como se puede observar en la figura 93, las mediciones realizadas tanto en cellSens como en SDM no se salen del intervalo de medidas permitidas para *Ustilago maydis*.

4.3.4. Comparación de tiempos en el módulo de Morfometría

En la siguiente tabla se presentan los tiempos registrados por el experto en cada una de las fases del análisis morfométrico, empleando ambos sistemas:

Tabla 28

Comparación de tiempos del análisis morfométrico entre cellSens y SDM

Fase	Tiempo en cellSens	Tiempo en SDM
Preparación/captura de imagen	03:18	03:57
Medición de microorganismos	05:18	05:01
Elaboración del informe de análisis	20:05	02:11
Total	28:41	11:09




Figura 103. Comparación de tiempos del análisis morfométrico entre cellSens y SDM

Como se puede observar en la tabla y en el gráfico precedentes, las fases de preparación/captura de imagen y de medición de microorganismos tienen una duración bastante similar en su realización, tanto el software cellSens como en el sistema SDM.

Donde destaca notablemente el sistema SDM es en el proceso de clasificación, ya que luego de realizar la medición, sin necesidad de crear el reporte el sistema ya clasifica el microorganismo entre las tres plagas.

Además, la elaboración del informe de análisis representa un ahorro de tiempo cercano a los 17 minutos por informe.

CAPÍTULO 5

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

El sistema SDM incluye dos módulos, el primero es el Módulo de Morfometría, dicho módulo permite analizar la muestra, identificar los microorganismos a partir de la obtención de medidas morfométricas de cada uno. Permite visualizar y generar el reporte del análisis. El segundo módulo consiste en el diagnóstico automático, incluye la implementación de la Red Neuronal Convolutiva. En este módulo se visualiza el resultado de la predicción e identificación de las tres plagas que han sido entrenadas en dicha red.

Para identificar la red que mejores resultados nos daba, han sido implementados varios tipos de redes neuronales, se ha realizado el procesamiento, entrenamiento y la comparación de los resultados. En el proceso de entrenamiento realizado con la Red Neuronal Convolutiva alcanzó el 98 % de certeza en la predicción, estos resultados han permitido comprobar que la Red Neuronal Convolutiva es válida para realizar detección de características en imágenes.

Actualmente el laboratorio de Fitopatología de AGROCALIDAD realiza el proceso de las mediciones en las microfotografías de forma manual, nuestro SDM genera los resultados de diagnóstico en cada módulo, es decir, a partir de las características propias de la imagen (Módulo de Diagnóstico), y de las mediciones del microorganismo (Módulo de Morfometría).

Se ha podido comprobar que la Red Neuronal Convolutiva es válida para realizar el reconocimiento de plagas del maíz a partir de una microfotografía, y que aquello que antes solo podía realizar el experto ahora lo puede hacer la máquina, mediante una clasificación automatizada.

Se ha comprobado la hipótesis planteada en el presente proyecto, ya que cuando se realizaron las pruebas se obtuvo resultados interesantes respecto al ahorro de tiempo por cada módulo y proceso que se ejecutó. Durante el proceso de diagnóstico el experto ahorra un total de 22:23 minutos y en el proceso de morfometría ahorra 17 minutos. Con lo que la herramienta tecnológica propuesta demuestra su validez y beneficio para el usuario.

Para la comprobación de la validez de los informes de análisis generados por el Sistema de Diagnóstico Micológico SDM, se realizó el cálculo estadístico de la desviación estándar, donde se obtuvieron valores menores que la unidad, lo que garantiza confiabilidad en el proceso de medición.

Se ha cumplido el objetivo principal de este trabajo, crear una Red Neuronal Artificial para el aprendizaje y el reconocimiento de patrones en tres plagas del maíz.

El SDM desarrollado para el laboratorio de Fitopatología de la Agencia de Regulación y Control Fito y Zoosanitario – AGROCALIDAD es una herramienta de mucha utilidad, porque permite optimizar el proceso de generación de certificados de calidad en el maíz en base a los resultados del análisis automático de las microfotografías de tres plagas de maíz. Además, SDM permite verificar los resultados mediante el módulo de morfometría.

5.2. Recomendaciones

Para la captura de microfotografías y la realización de las mediciones morfométricas es recomendable contar con cámaras digitales para microscopio con una resolución de 5.0 megapíxeles (2592x1944 píxeles) o superior, de modo que las imágenes tengan una buena calidad y los microorganismos no aparezcan distorsionados.

Se recomienda almacenar una gran cantidad de microfotografías en la base que ha sido creada, con el objetivo de disponer de un corpus para entrenamiento y aprendizaje automático con el número de imágenes óptimo (5000 imágenes por cada tipo

de plaga) con el fin de incrementar los porcentajes de certeza en los resultados del aprendizaje de la red neuronal convolucional.

Se recomienda que la Agencia de Regulación y Control Fito y Zoosanitario – Agrocalidad implemente más proyectos que hagan uso de redes neuronales convolucionales para el diagnóstico a través de microfotografías, en los demás laboratorios de referencia nacional de Tumbaco como el Laboratorio de Entomología y el Laboratorio de Nematología, así como también en los laboratorios de diagnóstico rápido y en laboratorios de provincias.

REFERENCIAS BIBLIOGRÁFICAS

- Adams, R. (2017). 10 ejemplos poderosos de inteligencia artificial en uso hoy en día. Retrieved October 16, 2018, from <https://www.forbes.com/sites/robertadams/2017/01/10/10-powerful-examples-of-artificial-intelligence-in-use-today/>
- Agencia de Servicios a la Comercialización y Desarrollo de Mercados Agropecuarios. (2018). ¿Conoces el origen del maíz? Retrieved October 16, 2018, from <https://www.gob.mx/aserca/es/articulos/conoces-el-origen-del-maiz?idiom=es>
- Agrocalidad. (2018). La Agencia | Agrocalidad. Retrieved October 15, 2018, from <http://www.agrocalidad.gob.ec/la-institucion/>
- Álvarez, L. (1994). *Fundamentos de inteligencia artificial*. EDITUM.
- Álvarez, M. (2014). *Análisis, diseño e implementación de un sistema de control de ingreso de vehículos basado en visión artificial y reconocimiento de placas en el parqueadero de la Universidad Politécnica Salesiana - Sede Cuenca*. Cuenca. Retrieved from <https://dspace.ups.edu.ec/bitstream/123456789/7060/1/UPS-CT003790.pdf>
- Ames, T. (1997). *Enfermedades Fungosas y Bacterianas de Raíces y Tubérculos Andinos*. Lima: Centro Internacional de la Papa. Retrieved from http://cipotato.org/wp-content/uploads/publication_files/books/002438.pdf
- Arenas, G., Canessa, L., Castro, C., & Peinado, O. (1987). Inteligencia artificial y Sistemas expertos. *Icesi*, 277. Retrieved from www.um.edu.ar/ojs-new/index.php/RUM/article/download/171/193
- Arenaza, É. (2012). Inteligencia Artificial. Retrieved January 21, 2019, from <http://edgar726.blogspot.com/>

- Avinash, N. (2018). Entendiendo los clasificadores de bosques aleatorios en Python. Retrieved from <https://www.datacamp.com/community/tutorials/random-forests-classifier-python>
- Baak, J. P. A., & Oort, J. (1983). *A Manual of Morphometry in Diagnostic Pathology*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-74823-3>
- Bellman, R. (1978). *An introduction to artificial intelligence : can computers think?* Boyd & Fraser Pub. Co.
- Bembibre, C. (2011). *Importancia del Maíz*. Retrieved from <https://www.importancia.org/maiz.php>
- Bendemra, H. (2018). Construye tu primer clasificador de Deep Learning con TensorFlow: Ejemplo de razas de perros. Retrieved October 15, 2018, from <https://medium.com/datos-y-ciencia/construye-tu-primer-clasificador-de-deep-learning-con-tensorflow-ejemplo-de-razas-de-perros-ed218bb4df89>
- Benítez, J. (2012). *Hongos patógenos en la selva*. Retrieved from https://www.uned.ac.cr/ecen/images/catedras/01-12_Benitez.pdf
- BiBing. (2018). Perceptron multicapa. Retrieved from <http://bibing.us.es/proyectos/abreproy/12166/fichero/Volumen+1+-+Memoria+descriptiva+del+proyecto%252F3+-+Perceptron+multicapa.pdf>
- Bolonia, C. (2018). ¿Cuáles son las partes de una neurona? | La Reserva. Retrieved October 16, 2018, from http://www.lareserva.com/home/Cuales_son_las_partes_de_una_neurona
- Calvo, D. (2017). Red neuronal Convolutiva CNN - Diego Calvo. Retrieved October 15, 2018, from <http://www.diegocalvo.es/red-neuronal-convolutiva-cnn/>
- Cantero, A., & Martínez, E. (2016). Visión por computadora: identificación, clasificación

- y seguimiento de objetos. *FPUNE Scientific*, (10). Retrieved from <http://www.une.edu.py:83/fpunescientific/index.php/fpunescientific/article/view/137>
- Diez, R. P., Gómez, A. G., & de Abajo Martínez, N. (2001). *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*. Universidad de Oviedo.
- DIVISADERO, A. T. & A. (2017). Analítica Web. Retrieved from <https://www.analiticaweb.es/algorithmo-knn-modelado-datos/>
- Durán, J. (2017). *Redes Neuronales Convolucionales en R Reconocimiento de caracteres escritos a mano Redes Neuronales Convolucionales en R Reconocimiento de caracteres escritos a mano Redes Neuronales Convolucionales en R*. Retrieved from <http://bibing.us.es/proyectos/abreproy/91338/fichero/TFG+Jaime+Durán+Suárez.pdf>
- Escolano, F., Cazorla, M. A., Alfonso, M. I., Colomina, O., & Lozano, M. (2003). *Inteligencia artificial: modelos, técnicas y áreas de aplicación* (Thomson). Spain.
- Fernández, F. (2002). *Arquitectura artificial o manierismo por computadora: experimentación con nuevos medios para la realización de proyectos arquitectónicos*.
- Flores, H., Santana, S., Castillo, A., & Domínguez, P. (2017). *Recomendaciones para la producción de grano y forraje de maíz bajo riego en Durango*. Durango: INIFAP. Retrieved from https://www.researchgate.net/publication/322924153_recomendaciones_para_la_pr oduccion_de_grano_y_forraje_de_maiz_bajo_riego_en_durango
- García, M. (2015). *Diseño de prototipo de recogida automatizada de bolos mediante brazo robótico y visión artificial*. Universidad de Oviedo. Retrieved from <http://digibuo.uniovi.es/dspace/bitstream/10651/29906/1/Memoria TFM.pdf>

Gerven, M. Van, & Bohte, S. (2018). *Artificial Neural Networks as Models of Neural Information Processing*. <https://doi.org/10.3389/978-2-88945-401-3>

González, L. (1985). *Introducción a la Fitopatología*. San José: IICA.

GrupoUS. (2018). Conceptos básicos. Retrieved October 16, 2018, from <http://grupo.us.es/gtocom/pid/pid10/RedesNeuronales.htm#arquitecturaredes>

Hong, K. (2018). scikit-learn : Random Decision Forests Classification - 2018. Retrieved January 14, 2019, from https://www.bogotobogo.com/python/scikit-learn/scikit_machine_learning_Random_Decision_Forests_Ensemble_Learning_Classification.php

Ibiblio. (2018). Artificiales.

INIAP. (n.d.). Curvularia. Retrieved from http://sinagap.agricultura.gob.ec/infoproductor/maiz/images/manejo_cultivo/curvularia.pdf

Jaramillo, N. (2011). Morfometría geométrica : principios teóricos y métodos de empleo. *ResearchGate*, (September).

Jones, T. (2017). Arquitecturas de aprendizaje profundo. Retrieved January 22, 2019, from <https://www.ibm.com/developerworks/ssa/library/cc-machine-learning-deep-learning-architectures/index.html>

Larranaga, P. (2018). Regularized Model learning in EDAs for continuous and multi-objective optimization.

Lastres, L., & Soza, F. (2009). *Manual Sanidad Vegetal*. Retrieved from https://www.se.gob.hn/media/files/media/Modulo_7_Manual_Sanidad_Vegetal..pdf

Levetin, E. (n.d.). Ustilago maydis - Fungalspores. Retrieved October 16, 2018, from <https://sites.google.com/site/fungalspores/welcome-to-the-fungal-spore-photo->

site/basidiomycete-spores/ustilago-maydis

Loncomilla, P. (2018). *Deep learning: Redes convolucionales*. Retrieved from <https://ccc.inaoep.mx/~pgomez/deep/presentations/2016Loncomilla.pdf>

Malaguti, G., & Subero, L. (n.d.-a). El tizón de las hojas del maíz causado *Helminthosporium maydis* en Venezuela. Retrieved from [http://www.sian.inia.gob.ve/revistas_ci/Agronomia Tropical/at2104/arti/malaguti_g.htm](http://www.sian.inia.gob.ve/revistas_ci/AgronomiaTropical/at2104/arti/malaguti_g.htm)

Malaguti, G., & Subero, L. (n.d.-b). Manchas foliares del maíz causados *Curvularia* en Venezuela. Retrieved from [http://sian.inia.gob.ve/revistas_ci/Agronomia Tropical/at2102/arti/malaguti_g.htm](http://sian.inia.gob.ve/revistas_ci/AgronomiaTropical/at2102/arti/malaguti_g.htm)

Maté, J. L., & Pazos, J. (1988). *Ingeniería del conocimiento. Diseño y construcción de sistemas expertos*. (SEPA, Ed.). Córdoba.

MAYA S.L. (2017). El maíz, origen anatomía y usos. Retrieved October 16, 2018, from <https://www.mayasl.com/maiz-origen-anatomia-usos/>

Moro, E. (2006). Introducción a la patología diagnóstica cuantitativa y sus aplicaciones. Retrieved from <http://conganat.cs.urjc.es>

Norvig, P., & Russell, S. (2013). *Inteligencia artificial. Elsevier Brasil*. (Vol. 1). <https://doi.org/M-26913-2004>

Padilla, A. (2012). *Sistema experto para la interpretación mamográfica*. Universidad Nacional Autónoma de México. Retrieved from <http://www.ptolomeo.unam.mx:8080/xmlui/handle/132.248.52.100/920>

Paliwal, R., Granados, G., Lafitte, H., & Violic, A. (2001). El maíz en los trópicos: mejoramiento y producción. Retrieved from <http://www.fao.org/docrep/003/x7650s/x7650s10.htm>

- Páliz, V., & Mendoza, J. (1999). Plagas del maíz (*Zea mays*) en el Litoral ecuatoriano, sus características y control. Retrieved from <http://repositorio.iniap.gob.ec/handle/41000/1616>
- Pawar, M. P., Turkar, D. V., & Patil, P. P. (2016). Cucumber Disease Detection using Artificial Neural Network. *International Conference on Inventive Computation Technologies (ICICT)*, 391–395. <https://doi.org/10.1109/INVENTIVE.2016.7830151>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(Oct), 2825–2830. Retrieved from <http://jmlr.csail.mit.edu/papers/v12/pedregosa11a.html>
- Pertusa, J. (2003). *Técnicas de análisis de imagen: aplicaciones en biología*. Valencia: Universitat de València. Retrieved from <https://www.casadellibro.com/libro-tecnicas-de-analisis-de-imagen-aplicaciones-en-biologia/9788437056678/918401>
- Proaño, R., Saguay, C., Jácome, S., & Sandoval, F. (2017). *Sistemas basados en conocimiento como herramienta de ayuda en la auditoría de sistemas de información*.
- Programa de Maíz del CIMMYT. (2004). *Enfermedades del maíz: una guía para su identificación en el campo* (4th ed.). México: CIMMYT. Retrieved from www.cimmyt.org
- Quintanar, T. (2007). *Sistemas expertos y sus aplicaciones*. Pachuca de Soto. Retrieved from [https://www.uaeh.edu.mx/docencia/Tesis/icbi/licenciatura/documentos/Sistemas expertos y sus aplicaciones.pdf](https://www.uaeh.edu.mx/docencia/Tesis/icbi/licenciatura/documentos/Sistemas%20expertos%20y%20sus%20aplicaciones.pdf)
- Quintero, C., Merchán, F., Cornejo, A., & Galán, J. S. (2018). Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo. *KnE Engineering*, 3(1), 585.

<https://doi.org/10.18502/keg.v3i1.1462>

- Ramírez, J. (1999). *Marco teórico de los sistemas expertos y su utilización como herramientas de negocio*. Universidad Autónoma de Nuevo León.
- Scott, C., Calyton, J., & Gibson, E. (1991). *A practical guide to knowledge acquisition*. Addison-Wesley.
- Serratos, J. (2009). *El origen y la diversidad del maíz en el continente americano*.
- Shah, M. (1997). *Fundamentals of computer vision*. *Fundamentals of Computer Vision*. Orlando: University of Central Florida. <https://doi.org/10.1017/9781316882641>
- Sillon, M. (n.d.). *Las principales enfermedades fúngicas del cultivo de maíz*. Retrieved from [http://horizonteadigital.com/investigacion/ha54/Principales enfermedades fungicas maiz.pdf](http://horizonteadigital.com/investigacion/ha54/Principales%20enfermedades%20fungicas%20maiz.pdf)
- Standar 153-1985. (2018). *Norma para el maíz*.
- Toro, V., Manriquez, G., & Suazo, I. (2010). Morfometría Geométrica y el Estudio de las Formas Biológicas: De la Morfología Descriptiva a la Morfología Cuantitativa. *International Journal of Morphology*, 28(4), 977–990. <https://doi.org/10.4067/S0717-95022010000400001>
- Unipython. (2018). Machine Learning Nearest Neighbour (vecinos mas cercanos). Retrieved January 14, 2019, from <https://unipython.com/machine-learningnearest-neighbour-vecinos-mas-cercanos/>
- White, D. (2004). *Plagas y enfermedades del maíz*. Madrid: The American Phytopathological Society.
- Winston, P. (1994). *Inteligencia Artificial*.pdf.
- Yang, M.-H., Kriegman, D. J., & Ahuja, N. (2002). *Detecting Faces in Images: A Survey*. Retrieved from <https://vision.cornell.edu/se3/wp->

content/uploads/2014/09/pami02.pdf

ANEXOS

ANEXO 1: Cronograma del proyecto

