Educación
Secretaría de Educacion Pública

TECNOLÓGICO NACIONAL DE MÉXICO®
Instituto Tecnológico de Orizaba

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN I.- TESIS

TRABAJO PROFESIONAL

"SISTEMA INTELIGENTE PARA EVALUAR LA VULNERABILIDAD Y RIESGO EN EL SECTOR AGROPECUARIO ANTE LOS EFECTOS DEL CAMBIO CLIMÁTICO A TRAVÉS DE UN SISTEMA MULTIAGENTE Y TRATAMIENTO DE IMÁGENES SATELITALES"

QUE PARA OBTENER EL GRADO DE:

MAESTRO EN INGENIERÍA INDUSTRIAL

PRESENTA:

Ing. Adán Espinosa Carrillo

DIRECTOR DE TESIS:

Dr. Alberto Alfonso Aguilar Lasserre

CODIRECTOR DE TESIS:

Dra. Alina Evelyn Badillo Márquez

INSTITUTO TECNOLÓGICO DE ORIZABA ®

ORIZABA, VERACRUZ, MÉXICO. **SEPTIEMBRE 2025**

Educación
Secretaría de Educación Pública

TECNOLÓGICO NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 10/septiembre/2025
Dependencia: **División de Estudios de Posgrado e Investigación**
Asunto: **Autorización de Impresión**
OPCION: **I**

C. ESPINOSA CARRILLO ADAN
Candidato(a) a Grado de Maestro(a) en:
INGENIERÍA INDUSTRIAL
PRESENTE

De acuerdo con el reglamento de Titulación vigente de los Centros e Institutos Tecnológicos Federales del Tecnológico Nacional de México, de la Secretaría de Educación Pública, y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

"SISTEMA INTELIGENTE PARA EVALUAR LA VULNERABILIDAD Y RIESGO EN EL SECTOR AGROPECUARIO ANTE LOS EFECTOS DEL CAMBIO CLIMÁTICO A TRAVÉS DE UN SISTEMA MULTIAGENTE Y TRATAMIENTO DE IMÁGENES SATELITALES"

Comunico a usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

A T E N T A M E N T E
Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA - CULTURA®

OFELIA LANDETA ESCAMILLA
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN

Educación
Secretaría de Educación Pública
TECNOLÓGICO NACIONAL DE MÉXICO
INSTITUTO TECNOLÓGICO DE ORIZABA
DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OLE/jarh

OG-13-F06



2025 Año de La Mujer Indígena

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx

ESPACIO 100% LIBRE DE PLÁSTICO DE UN SOLO USO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba Veracruz, 20/junio/2025.
Asunto: Revisión de trabajo escrito

C. OFELIA LANDETA ESCAMILLA
JEFA DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.:

ESPINOSA CARRILLO ADAN

La cual lleva el título de:

SISTEMA INTELIGENTE PARA EVALUAR LA VULNERABILIDAD Y RIESGO EN EL SECTOR AGROPECUARIO ANTE LOS EFECTOS DEL CAMBIO CLIMÁTICO A TRAVÉS DE UN SISTEMA MULTIAGENTE Y TRATAMIENTO DE IMÁGENES SATELITALES

y concluyen que se acepta.

A T E N T A M E N T E
Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA - CULTURA®

PRESIDENTE:	DR. ALBERTO ALFONSO AGUILAR LASSERRE	FIRMA
SECRETARIO:	DRA. ALINA EVELYN BADILLO MÁRQUEZ	FIRMA
VOCAL:	MII CONSTANTINO GERARDO MORAS SANCHEZ	FIRMA
VOCAL SUP.:	DR. RAMIRO MEZA PALACIOS	FIRMA

TA-09-F18



2025 Año de La Mujer Indígena



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

LICENCIA DE USO OTORGADA POR Adan Espinosa Carrillo, de nacionalidad Mexicana mayor de edad, con domicilio ubicado en Calle la Gavia 106 Fraccionamiento las Haciendas, Orizaba Ver., en mi calidad de titular de los derechos patrimoniales y morales y autor de la tesis denominada "SISTEMA INTELIGENTE PARA EVALUAR LA VULNERABILIDAD Y RIESGO EN EL SECTOR AGROPECUARIO ANTE LOS EFECTOS DEL CAMBIO CLIMÁTICO A TRAVÉS DE UN SISTEMA MULTIAGENTE Y TRATAMIENTO DE IMÁGENES SATELITALES" en adelante **"LA OBRA"** quien para todos los fines del presente documento se denominará **"EL AUTOR Y/O EL TITULAR"**, a favor del Instituto Tecnológico de Orizaba del Tecnológico Nacional de México, la cual se regirá por las cláusulas siguientes:

PRIMERA -OBJETO: "EL AUTOR Y/O TITULAR", mediante el presente documento otorga al Instituto Tecnológico de Orizaba del Tecnológico Nacional de México, licencia de uso gratuita e indefinida respecto de **"LA OBRA"**, para almacenar, preservar, publicar, reproducir y/o divulgar la misma, con fines académicos, por cualquier medio en forma física y a través del repositorio institucional y del repositorio nacional, éste último consultable en la página: (https://www.repositorionacionalcti.mx/).

SEGUNDA - TERRITORIO: La presente licencia se otorga, de manera no exclusiva, sin limitación geográfica o territorial alguna, de manera gratuita e indefinida.

TERCERA -ALCANCE: La presente licencia contempla la autorización para formato uso de "LA OBRA" en cualquier formato o soporte material y se extiende a la utilización, de manera enunciativa más no limitativa a los siguientes medios: óptico, magnético, electrónico, virtual (red), mensaje de datos o similar conocido por conocerse.
en medio óptico, magnético, electrónico, en red, mensajes de datos o similar, conocido o por conocerse.

CUARTA - EXCLUSIVIDAD: La presente licencia de uso aquí establecida no implica exclusividad en favor del Instituto Tecnológico de Orizaba ; por lo tanto, **"EL AUTOR Y/O TITULAR"** conserva los derechos patrimoniales y morales de **"LA OBRA"**, objeto del presente documento.

QUINTA - CRÉDITOS: El Instituto Tecnológico de Orizaba y/o el Tecnológico Nacional de México reconoce que el "AUTOR Y/O TITULAR" es el único, primigenio y perpetuo titular de los derechos morales sobre "LA OBRA"; por lo tanto, siempre deberá otorgarle los créditos correspondientes por la autoría de la misma.

SEXTA - AUTORÍA: **"EL AUTOR Y/O TITULAR"** manifiesta ser el único titular de los derechos de autor que derivan de **"LA OBRA"** y declara que el material objeto del presente fue realizado por él, sin violentar o usurpar derechos de propiedad intelectual de terceros; por lo tanto, en caso de controversia sobre los mismos, se obliga a ser el único responsable.

Dado en la Ciudad de Orizaba, a los 17 días del mes de Septiembre de 2020.

"EL AUTOR Y/O TITULAR" **"EL INSTITUTO TECNOLÓGICO DE Orizaba"**

Adan Espinosa Carrillo



Dedicatorias:

A Dios, por ser mi guía y fortaleza en cada paso de este camino. En los momentos de incertidumbre me dio claridad, en las dificultades me dio resiliencia, y en las alegrías me permitió reconocer la grandeza de este logro como fruto de fe y perseverancia.

A mis padres, cuyo amor incondicional, sacrificio y ejemplo me han enseñado a no rendirme.

A mi hermana, que con su cariño y compañía se convirtió en un apoyo indispensable.

A mis amigos, que más que compañeros de vida se han convertido en familia. Gracias por estar a mi lado en los días difíciles, por darme momentos de alegría y diversión que hicieron más llevadero este camino. Su apoyo, su compañía y sus risas fueron bálsamo en los días de cansancio y motivación en los momentos de duda.

Este logro no es únicamente mío, sino también de cada uno de ustedes que me han acompañado en esta etapa. A ustedes dedico con todo mi corazón este trabajo, que representa no solo el esfuerzo académico, sino también el amor, el apoyo y la confianza de quienes siempre han creído en mí.

Agradecimientos:

Mi más profundo agradecimiento al Dr. Alberto Lasserre, director de tesis, por su orientación, paciencia y compromiso a lo largo de este proyecto. Su guía académica y humana fueron clave para transformar ideas.

A la Dra. Evelyn Badillo, codirectora de tesis, no solo por su acompañamiento académico y científico, sino también por la amistad sincera que surgió en este proceso. Su cercanía, empatía y motivación constante hicieron de este trayecto algo más humano y enriquecedor.

A todos mis profesores, quienes con su entrega y dedicación me brindaron las bases del conocimiento que hoy sostienen este logro. Cada clase, cada consejo y cada reto planteado a lo largo de mi formación fueron eslabones que me llevaron hasta aquí.

Al Tecnológico Nacional de México, Campus Orizaba, que me abrió sus puertas, me formó como profesionista y me permitió vivir experiencias que trascendieron lo académico para convertirse en aprendizajes de vida.

A (CONACyT), por la beca otorgada que hizo posible la realización de este proyecto.

Finalmente, agradezco a mi familia y a todas las personas que, de una u otra manera, estuvieron presentes en este trayecto. A quienes, con un consejo, una palabra de aliento o un gesto de apoyo me recordaron que los sueños se alcanzan con esfuerzo y con el respaldo de quienes nos quieren.

Este trabajo es el reflejo de una suma de esfuerzos, conocimientos y afectos. A todos, gracias por acompañarme en este camino y por ser parte de la historia que hoy culmina con este logro académico y personal.

Aunque hubo pausas y tropiezos, llegamos hasta aquí gracias a la fe y al apoyo de quienes caminaron conmigo.

INDICE

Índice de tablas i

Índice de figuras ii

Abstract viii

Resumen ix

CAPITULO I. GENERALIDADES 1

1.1 Introducción 1

1.2 Planteamiento del problema 2

1.3 Justificación 4

1.4 Objetivos 5

1.4.1 Objetivo general 5

1.4.2 Objetivos específicos 5

1.5 Hipótesis 5

1.6 Estado del arte 6

1.7 Conclusión de capitulo 17

CAPÍTULO II. MARCO TEÓRICO 18

2.1 Cambio climático 18

2.1.1 Efectos del cambio climático 18

2.1.2 México ante el cambio climático 19

2.1.3 Desastres naturales 20

2.1.4 Procesos asociados con el cambio climático 22

2.1.5 Vulnerabilidad ante el cambio climático 23

2.1.6 Exposición y vulnerabilidad 23

2.2 Cambio climático y sus efectos en el Sector agropecuario en México 24

2.2.1 Efectos del cambio climático en la producción de Caña 26
2.3 Inteligencia artificial 29
2.3.1 Redes neuronales 29
2.3.2 Procesamiento digital de imágenes 31
2.3.3 Lógica difusa 32
2.3.4 Sistema basado en agentes 32
2.3.5 Dinámica de sistemas 33
2.4 Conclusión de capitulo 34
Capítulo III. Metodología 35
3.1 Diagnóstico 37
3.1.1 Factores causantes de desastres. 37
3.1.2 Características de los factores. 38
3.1.3 Clasificación de los indicadores de vulnerabilidad 39
3.1.4 Indicadores de sensibilidad 41
3.1.5 indicadores de vulnerabilidad y obtención de índice de vulnerabilidad 44
3.2 Desarrollo de modelo de vulnerabilidad, sistema multi-agente 45
3.2.1 Aplicación de dinámica de sistemas en Anylogic 46
3.2.1.1 Conceptualización 47
3.2.1.2 Implementación 51
3.2.1.3 formulación 53
3.3 Modelo agropecuario caso de estudio 55
3.3.1 Aplicación de tratamiento de imágenes satelitales. 57
3.3.1.1 Monitoreo 58
3.3.1.2 Recolección de imágenes 59
3.3.2 Entorno de trabajo 60

3.3.2.1 Librerías Python 61
3.3.3 Obtención de imágenes desde SMN 63
3.3.3.1 Definición del área de estudio 63
3.3.3.2 Estandarización de las imágenes 64
3.3.3.3 Programación de intervalos y almacenamiento 64
3.3.4 Algoritmo de extracción de parámetros climáticos a partir de colores 65
3.3.4.1 Segmentación cromática por umbrales HSV 66
3.3.4.2 Segmentación por cuadrantes y construcción del dataset global 68
3.3.4.3 Preparación, entrenamiento y evaluación de la red 69
3.3.5 Integración de parámetros cromáticos a un sistema difuso 70
3.3.5.1 Planteamiento y selección de variables modelo difuso pecuario-agrícola ... 71
3.3.5.2 Etiquetas lingüísticas y funciones de membresía 73
3.3.5.3 Principios físicos/ epidemiológicos (Veracruz) construcción de reglas de inferencia 74
3.4 Proyección de valor de la producción pecuaria a partir del modelo difuso 76
3.4.1 Datos y alcance 76
3.4.2 Base económica “proyección sin riesgo” 76
3.5 Modelo para la detección y evaluación de enfermedades en caña de azúcar 78
3.5.1 CNN para la clasificación de enfermedades en caña de azúcar 78
3.5.1.1 Preparación del conjunto de datos 78
3.5.1.2 Neutralización del fondo en las imágenes (Preprocesamiento) 79
3.5.1.3 Generación de lotes con aumentación de datos 79
3.5.1.4 Arquitectura del modelo y estrategia de transfer learning 82
3.5.1.5 Régimen de entrenamiento en dos etapas 84
3.5.1.6 Validación: curvas de entrenamiento, métricas y matriz de confusión 86

3.5.2 Sistema difuso para enfermedades de caña de azúcar 88
3.5.2.1 Sistema difuso por enfermedad (FIS-1) 88
3.5.2.2 Variable de salida FIS-1 90
3.5.2.3 Lógica y reglas difusas 91
3.5.2.4 Módulo difuso de rendimiento y calidad (FIS-2) 92
3.5.2.6 Implementación de los modelos difusos 94
3.6 Conclusiones del capítulo 94
CAPITULO IV RESULTADOS 96
4.1 Análisis de sensibilidad (Modelo multiagentes) 96
4.1.1 análisis de sensibilidad Recurso Hídrico 97
4.1.2 Análisis de sensibilidad Tierras agrícolas y pecuarias 99
4.1.3 Emisiones de gases de efecto invernadero 101
4.2 Resultados modelo de riesgo agropecuario 103
4.3 Resultados de modelo difuso riesgo agrícola y pecuario 106
4.3.1 Superficies difusas del sector pecuario 106
4.3.2 Proyecciones del valor de la producción pecuaria 110
4.3.2 Superficies difusas para el sector agrícola (Probabilidad de enfermedades en el cultivo de caña de azúcar) 114
4.3 Resultados modelo RNA-FIS 118
4.3.1 Resultados generales de las versiones RNA 118
4.4 Resultados del modelo de riesgo por enfermedad en caña de azúcar 129
4.4.1 Superficie de respuesta modelo difuso de riesgo 132
4.4.2 Resultados del modelo productivo de caña de azúcar 141
4.4.2.1 impacto de Yellow en la producción y calidad 141
4.4.2.2 Impacto de Red Rot en la producción y calidad 145

4.4.2.3 Impacto de Mosaic en la producción y calidad 148
4.4.2.4 Impacto de Rust (Roya) en el rendimiento y calidad 151
4.4.3 Jerarquización de enfermedades 153
4.5 Esquemas de adaptación 156
4.5.1 Esquemas de adaptación para el sector pecuario 157
4.5.1.2 Interfaz interactiva para sector pecuario 160
4.5.2 Esquemas de adaptación para el sector agrícola (cultivo de caña de azúcar) 162
4.5.2.1 Interfaz interactiva para sector agrícola (Cultivo de caña de azúcar) 165
4.5.3 impacto en las cadenas de suministro 169
4.6 Conclusión del capitulo 170
4.7 Discusión de resultados 171
CONCLUSIONES 173
Bibliografía 179

Índice de tablas

Tabla 1 Concentrado estado del arte (parte 1) 13
Tabla 2 Concentrado estado del arte (parte 2) 14
Tabla 3 Concentrado estado del arte (parte 3) 15
Tabla 4 Concentrado estado del arte (parte 4) 16
Tabla 5 Fuentes de información consultadas 38
Tabla 6 Indicadores de exposición 40
Tabla 7 Lista de variables y su relación con vulnerabilidad 43
Tabla 8 Tipos de agentes y sus funciones 46
Tabla 9 Variables indicadores de vulnerabilidad (A. E. Badillo, 2021) 48
Tabla 10 Variables indicadores de vulnerabilidad parte 2 (A. E. Badillo, 2021) 49
Tabla 11 formulación matemática para series de tiempo del modelo matemático 54
Tabla 12 Clasificación Geográfica 55
Tabla 13 Producción Agrícola y Pecuaria por región en Ton 55
Tabla 14 Interpretación cromática del Tope de nubes 60
Tabla 15 Rangos iniciales por color 68
Tabla 16 Definición del universo y etiquetas lingüísticas de las variables de entrada derivadas del Tope de Nubes (SMN) 73
Tabla 17 Definición del universo y etiquetas lingüísticas de las variables de Salida derivadas del Tope de Nubes (SMN) 74
Tabla 18 Generación de lotes con aumentación de datos 82
Tabla 19 Variables de entrada FIS-1 89
Tabla 20 Parámetros de las variables de entrada FIS-1 90
Tabla 21 Funciones de membresía para Risk 91
Tabla 22 Variables de entrada Fis-2 93
Tabla 23 Variables de salida Fis-2 93
Tabla 24 Resultados para los escenarios del recurso Hídrico 98
Tabla 25 Resultados para los escenarios de las tierras agropecuarias 100
Tabla 26 Resultados para los escenarios de gases de efecto invernadero 102
Tabla 27 Resultados de la simulación 103
Tabla 28 Métricas de evaluación por clase en la clasificación de colores Tope de Nubes. 105

Tabla 29 métricas de predicción V5 122
Tabla 30 Resumen de los modelos V1-V5 123
Tabla 31 características principales de la versión 7 125
Tabla 32 métricas de evaluación del modelo 127
Tabla 33 Sensibilidad del rendimiento (R) y ATR a variables climáticas y fitosanitarias en el modelo Yellow Leaf. 144
Tabla 34 Sensibilidad del rendimiento (R) y ATR en Red Rot 147
Tabla 35 Sensibilidad del rendimiento (R) y ATR a variables climáticas y fitosanitarias en el modelo Mosaic. 150
Tabla 36 Sensibilidad del rendimiento (R) y ATR a variables climáticas y fitosanitarias en el modelo Mosaic. 152
Tabla 37 Planes de acción por severidad para MOSAIC 164
Tabla 38 Planes de acción por severidad para RED ROT 165
Tabla 39 Planes de acción por severidad para YELLOW 165
Tabla 40 Planes de acción por severidad para RUST 165
Tabla 41 Relación entre impactos productivos, efectos logísticos y seguridad alimentaria 170

Índice de figuras

Figura 1 Efectos socioeconómicos del cambio climático (Iberdrola, 2024) 19
Figura 2 Modificaciones del promedio y extremos de las temperaturas con el cambio climático (López et al., 2022) 20
Figura 3 Conceptos centrales del Informe especial sobre la gestión de los riesgos de fenómenos meteorológicos extremos y desastres para mejorar la adaptación al cambio climático (Grupo Intergubernamental de Expertos sobre el Cambio Climático, 2012) 23
Figura 4 Anomalías de precipitaciones a nivel nacional 2022 (CONAGUA) 26
Figura 5 comparación de modelos acoplados (CMIP5) de los escenarios RCP2,6 y RCP8,5, correspondientes al período 2081-2100 28
Figura 6 Metodología general (A. E. Badillo, 2021) 36
Figura 7 Diagrama causal del modelo de vulnerabilidad 50
Figura 8 Rendimiento de tierras agrícolas 51

Figura 9 Eficiencia de los recursos hídricos para el sector agropecuario 52
Figura 10 Diagrama de flujo Vulnerabilidad climática 53
Figura 11 Valor de la producción de caña de azúcar (A. E. Badillo, 2021) 56
Figura 12 Indicador de autosuficiencia alimentaria de México (D. Badillo, 2025) 56
Figura 13 Metodología para la aplicación del procesamiento digital de imágenes 58
Figura 14 Diagrama de fujo construcción base de datos SMN 61
Figura 15 librerías para la recopilación de imágenes en tiempo real 63
Figura 16 Base de datos tope de nubes de SMN 65
Figura 17 Imágenes cargadas y descomprimidas obtenidas del SMN 66
Figura 18 Segmentación cromática RGB a HSV 67
Figura 19 Paleta por clase derivada de los rangos HSV 68
Figura 20 Segmentación por cuadrante y color predominante 69
Figura 21 Distribución de indicadores derivados del color 69
Figura 22 Interfaz de definición de variables modelo de riesgo agrícola y pecuario derivada de Tope de nubes SMN 72
Figura 23 Funciones de pertenencia de las variables de entrada del sistema difuso 75
Figura 24 Aumentación en base de datos con clases desbalanceadas 81
Figura 25 Ejemplo de reglas difusas en la interfaz de MATLAB 92
Figura 26 Proyecciones de temperaturas ante el cambio climático 97
Figura 27 Escenarios para la eficiencia del recurso hídrico 98
Figura 28 Disponibilidad de agua y su relación con la Vulnerabilidad del recurso hídrico 99
Figura 29 Escenarios de las tierras agrícolas y pecuarias 100
Figura 30 Vulnerabilidad y rendimiento de las tierras agropecuarias 101
Figura 31 Escenarios para las emisiones de gases de efecto invernadero 102
Figura 32 Curvas de pérdida y exactitud durante el entrenamiento y validación de la red neuronal convolucional aplicada al Tope de Nubes 104
Figura 33 Matriz de confusión normalizada de la clasificación de colores Tope de Nubes. 106
Figura 34 Superficie difusa de riesgo pecuario (LSHR) en función de amplitud térmica y velocidad del viento 107

Figura 35 Superficie difusa de riesgo pecuario (LSHR) en función de Amplitud Térmica y Humedad 109
Figura 36 Superficie difusa de riesgo pecuario (LSHR) en función de Humedad y viento 110
Figura 37 Veracruz: Valor de la producción pecuaria (miles de pesos), observado y proyecciones cortas (lineal y SES, 2011–2024). 111
Figura 38 Valor pecuario por especie 111
Figura 39 Proyecciones del valor de la producción sin Riesgo hasta 2030 112
Figura 40 Calculo de riesgo y ajuste de valor de producción pecuaria en diferentes escenarios 112
Figura 41 Proyección del valor de la producción pecuaria 2011–2030 con ajuste por riesgo sanitario-climático 113
Figura 42 Superficie difusa de probabilidad de enfermedades en caña de azúcar (SCDP) en función de humedad y viento 115
Figura 43 Superficie difusa de probabilidad de enfermedades en caña de azúcar (SCDP) en función de humedad y amplitud térmica 116
Figura 44 Superficie difusa de probabilidad de enfermedades en caña de azúcar (SCDP) en función de amplitud térmica y viento 117
Figura 45 Matriz de confusión, RNA sin generadores de datos 119
Figura 46Curva de entrenamiento/ Validación RNA generadores y aumento de datos 120
Figura 47Matriz de confusión RNA generadores y aumento de datos 120
Figura 48 Curvas de entrenamiento y validación versión 3 121
Figura 49 Curvas de entrenamiento y validación versión 4 121
Figura 50 Curva de entrenamiento, validación y perdida versión 5 MobileNetV2 121
Figura 51 Matriz de confusión V5 122
Figura 52 Curvas de entrenamiento y validación V6, desajuste en la optimización 124
Figura 53 Curvas función perdida 124
Figura 54 Matriz de confusión versión 6 124
Figura 55 Curvas de entrenamiento y validación V7 126
Figura 56 Curva función de perdida V7 126
Figura 57 Matriz de confusión versión 7 128
Figura 58 Matriz de confusión normalizada 128

Figura 59 Predicciones del modelo de clasificación entrenado 129
Figura 60 Superficie de respuesta para Red Rot en caña de azúcar, considerando la interacción entre la edad del cultivo (AGE) y la variable P 132
Figura 61 Superficie de respuesta del modelo difuso (RISK) en función de VIG y P 133
Figura 62 Superficie de respuesta del modelo difuso (RISK) en función de NKI y P 133
Figura 63 Superficie de respuesta del modelo difuso (RISK) en función de SM y P 134
Figura 64 Superficie del modelo RISK respecto a las variables SM y AGE 135
Figura 65 Superficie del modelo RISK con respecto a las variables AGE y VIG 135
Figura 66 Superficie del modelo RISK con respecto a las variables NKI y VIG 136
Figura 67 Figura 66 Superficie del modelo RISK con respecto a las variables VIG y LWH 137
Figura 68 Superficie de respuesta del modelo difuso (Mosaic): edad del cultivo (AGE) vs. vigor (VIG) 138
Figura 69 Superficie de respuesta del modelo difuso (Mosaic): edad del cultivo (AGE) vs. balance K/N (NKI) 138
Figura 70 Superficie de respuesta del modelo difuso (Mosaic): vigor (VIG) vs. balance K/N (NKI) 139
Figura 71 Superficie de respuesta del modelo difuso (Mosaic): fósforo (P) vs. vigor (VIG) 139
Figura 72 Superficie de respuesta (Yellow leaf): relación (KMg) vs. balance (NKI)..... 140
Figura 73 Superficie de respuesta (Yellow leaf): relación K/Mg vs. vigor del cultivo (VIG). 141
Figura 74 Superficie de respuesta del rendimiento de caña de azúcar (t/ha) en función de la severidad de Yellow Leaf y la humedad relativa (%) 142
Figura 75 Superficie de respuesta del ATR (kg/t) en función de la severidad de Yellow Leaf y la amplitud térmica (°C) 143
Figura 76 Rendimiento y ATR de caña de azúcar bajo distintos niveles de severidad de Yellow Leaf (condiciones fijas). 143
Figura 77 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en el modelo Yellow Leaf 144

Figura 78 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en el modelo Yellow Leaf 145
Figura 79 Superficie de respuesta del rendimiento de caña de azúcar (t/ha) en función de la severidad de Red Rot y la humedad relativa (%) 145
Figura 80 Superficie de respuesta del ATR (kg/t) en función de la severidad de Red Rot y la amplitud térmica (°C). 146
Figura 81Rendimiento (t/ha) y ATR (kg/t) en función de la severidad de Red Rot bajo condiciones fijas. 146
Figura 82 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en Red Rot. 147
Figura 83 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en Red Rot. 148
Figura 84 Superficie de respuesta del ATR (kg/t) en función de la severidad de Mosaic y la amplitud térmica (°C) 149
Figura 85 Superficie de respuesta del ATR (kg/t) en función de la severidad de Mosaic y la edad del cultivo (meses) 149
Figura 86 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en Mosaic 150
Figura 87 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en Mosaic. 151
Figura 88 Superficie de respuesta del rendimiento (t/ha) en función de la severidad de Rust y la humedad relativa (%). 152
Figura 89 Superficie de respuesta del ATR (kg/t) en función de la severidad de Rust y la amplitud térmica (°C) 152
Figura 90 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en Rust. 153
Figura 91 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en Rust 153
Figura 92 Comparativo del daño por severidad en rendimiento (ΔR, t/ha) y calidad (ΔATR, kg/t) por enfermedad. 154
Figura 93 Panorama del daño por severidad: ΔR (t/ha) vs ΔATR (kg/t) por enfermedad . 155
Figura 94 Ranking comparativo: Rendimiento + ATR (normalizados por máximo) e índice compuesto (0.6R + 0.4A) 156

Figura 95 Esquema integral de adaptación para el sector pecuario 159
Figura 96 Panel escenarios rápidos y selección de especie 160
Figura 97 Ajuste de parámetros 161
Figura 98 Recomendaciones según parámetros 161
Figura 99 Esquema integral de adaptación para el cultivo de caña de azúcar 164
Figura 100 Selección de enfermedad y parámetros iniciales 166
Figura 101Parámetros de riesgo y condiciones edafoclimáticas 167
Figura 102 Estimaciones de rendimiento, calidad y azúcar 168
Figura 103Acciones específicas de manejo para enfermedades 169

Abstract

Climate change has profoundly transformed ecosystems, directly impacting agriculture and livestock—key pillars of food security and rural economies. In Mexico, particularly in Veracruz, agro-livestock vulnerability is driven by climatic variability, water scarcity, and the recurrence of extreme events, compromising crop yields and livestock product quality.

This research develops an integrated agro-climatic vulnerability and risk model that combines intelligent agents, fuzzy logic, satellite image processing, and convolutional neural networks. The approach generates impact scenarios to estimate the probability of sugarcane diseases and sanitary risk in the livestock sector. Results show high crop sensitivity to variations in temperature, humidity, and wind, while livestock faces risks associated with thermal and hydric stress. Finally, adaptation schemes are proposed to strengthen sectoral resilience to climate change, providing a practical decision-support tool for policy and production management.

In summary, the findings suggest that the analysis of agro-livestock vulnerability requires interdisciplinary approaches that integrate biophysical, socioeconomic, and technological dimensions. This perspective not only addresses the productive level but also extends to agro-food logistics, by anticipating disruptions in supply and distribution, and by linking productive vulnerability with food security and the efficiency of supply chains.

Keywords: climate change; agro-livestock vulnerability; sugarcane diseases; fuzzy logic; convolutional neural networks; satellite imagery; agent-based modeling; Risk management.

Resumen

El cambio climático ha generado transformaciones profundas en los ecosistemas, afectando de manera directa la agricultura y la ganadería, sectores que sostienen la seguridad alimentaria y la economía rural. En México, y particularmente en Veracruz, la vulnerabilidad agropecuaria se relaciona con la variabilidad climática, la escasez de agua y la recurrencia de fenómenos extremos, lo que compromete tanto el rendimiento de los cultivos como la calidad de la producción pecuaria. La presente investigación desarrolla un modelo integral de vulnerabilidad y riesgo agropecuario, combinando agentes inteligentes, lógica difusa, procesamiento digital de imágenes satelitales y redes neuronales convolucionales. Con este enfoque se generan escenarios de impacto para estimar la probabilidad de enfermedades en caña de azúcar y el riesgo sanitario del sector pecuario. Los resultados evidencian que los cultivos son altamente sensibles a variaciones de temperatura, humedad y viento, mientras que la ganadería enfrenta riesgos asociados al estrés térmico e hídrico. Finalmente, se proponen esquemas de adaptación que fortalecen la resiliencia del sector agropecuario frente a los efectos del cambio climático, aportando una herramienta práctica para la toma de decisiones en políticas y gestión productiva.

En conjunto, los hallazgos permiten concluir que el análisis de la vulnerabilidad agropecuaria exige enfoques interdisciplinarios que articulen lo biofísico, lo socioeconómico y lo tecnológico. Esta visión no solo incide en el nivel productivo, sino que también alcanza la logística agroalimentaria, al anticipar disrupciones en el abasto y la distribución, y al vincular la vulnerabilidad productiva con la seguridad alimentaria y la eficiencia de las cadenas de suministro.

Palabras clave: cambio climático; vulnerabilidad agropecuaria; enfermedades de la caña de azúcar; lógica difusa; redes neuronales convolucionales; imágenes satelitales; modelo basado en agentes; gestión de riesgo.

CAPITULO I. GENERALIDADES

1.1 Introducción

En México, el sector agropecuario forma parte importante en la economía del país, las actividades de producción se relacionan directamente con la agricultura, ganadería, explotación forestal y pesca, representando hasta el 4% del producto interno bruto mexicano, con un valor aproximado de 900 millones de pesos. Además, de los 24 millones de hectáreas dedicadas al sector de la agricultura, cerca de 109 mil hectáreas están dedicadas a la ganadería, siendo así la agricultura la actividad más importante del sector agropecuario seguido de la cría y explotación de animales. (Gutierrez, 2022)

Sin embargo, el principal causante de la diminución de la superficie agrícola y el valor comercial de la tierra en México y el mundo es el cambio climático, de acuerdo con la FAO cada territorio o estado en México tendrá una disminución de valor debido a los factores climáticos(“FAO Publications Catalogue, 2023). El cambio climático se manifiesta como una realidad que no podemos negar, teniendo un impacto significativo en nuestro entorno y, por consecuencia, en nuestras vidas. Ante el cambio climático se tiene un panorama inquietante, aumentos de temperatura, eventos climáticos extremos y desastres naturales que van en aumento. Es decir, la vulnerabilidad de la agricultura y la ganadería está estrechamente relacionada con factores climáticos, además de factores económicos y sociales.

La agricultura emite alrededor de una cuarta parte de los gases de efecto invernadero(FAO, 2019). El cambio climático se está manifestando en gran manera en diversos ecosistemas, los océanos han aumentado su temperatura y acidez, representando una amenaza para la población de peces. Las sequias son más prolongadas y severas poniendo en riesgo el suministro de agua dulce para los cultivos y la crianza animal.

Se producen fenómenos meteorológicos extremos que dañan las infraestructuras, arrasan las cosechas y erosionan los recursos naturales. (Organizacion de las Naciones Unidas para la Alimentacion y la Agricultura, 2019)

Las emisiones de gases de efecto invernadero correspondiente al sector agropecuario equivalen al 17-32% de las emisiones a escala mundial, y al 12% de las emisiones a nivel nacional. La mayor parte de las emisiones son generadas por estiércol de los animales y

por el uso de fertilizantes en los suelos agrícolas. (Santillán, 2016)

Dicho esto, se aborda la vulnerabilidad agropecuaria ante los efectos de cambio climático mediante un modelo basado en agentes, analizando escenarios de impactos son generados a consecuencia de sequías, y emisiones de GEI debido a la producción agrícola, ganadera y ocurrencia de incendios de incendios.

Esta investigación permite estimar la vulnerabilidad, de acuerdo con el análisis de la disponibilidad de recursos, que se ven afectados principalmente por los efectos del cambio climático, estos efectos se ven resumidos en los cambios drásticos en loa aumentos de temperatura, lo cual ocasiona menor disponibilidad de tierras e incluso provoca incendios forestales erosionando dicho recurso, además se contempla la disminución de precipitación poniendo en riesgo la disponibilidad del recurso hídrico, asimismo, el principal objetivo es ayudar en el proceso de toma de decisiones para maximizar el rendimiento de la cadena de suministro del sector agropecuario en la zona de estudio mediante la generación de planes de trabajo que conduzcan al desarrollo de acciones de adaptación y/o mitigación para hacer frente al cambio climático

1.2 Planteamiento del problema

La escasez de agua se ha convertido en un desafío global debido a la expansión poblacional y el crecimiento urbano, junto con la creciente demanda de agua para la agricultura, la industria y el consumo humano, lo que agrava aún más la situación. Las consecuencias del cambio climático, como las sequías prolongadas y más frecuentes, intensifican esta crisis hídrica, afectando diversas regiones del mundo. En las últimas décadas, se han registrado cambios ambientales notables debido al impacto climático. Entre estos cambios, se observa una disminución de las lluvias, un incremento en las temperaturas y una mayor recurrencia e intensidad de las sequías. Estos fenómenos han generado efectos negativos en múltiples sectores, como la producción agrícola, la gestión de los recursos hídricos, la preservación de la biodiversidad y la salud humana.

La disminución de precipitaciones y el incremento de las temperaturas están interrelacionados, ya que el calentamiento global intensifica el ciclo hidrológico, llevando a sequías más prolongadas y severas en algunas regiones mientras que otras pueden experimentar inundaciones. Estos cambios no solo afectan el medio ambiente,

sino también la economía y la estabilidad social a nivel mundial. Además, se espera que el cambio climático aumente el riesgo de sequías y desertificación en muchas regiones, particularmente aquellas con un rápido crecimiento demográfico, grupos vulnerables y desafíos de seguridad alimentaria.(Yann Kerblat & Melody Hill Kokoszka, 2024)

México ha sufrido de manera considerable el impacto del cambio climático. La disminución de precipitación, así como el aumento de las temperaturas han sido causantes de sequías severas que afectan a varias regiones del país, principalmente la zona norte y centro. Estas condiciones extremas perjudican la producción agrícola, poniendo en riesgo la seguridad alimentaria, además de reducir la disponibilidad de agua. Por otro lado, los ecosistemas también se ven amenazados debido a estos cambios. Las sequías recurrentes también tienen implicaciones económicas y sociales, acentuando la pobreza y provocando desplazamientos de la población en busca de mejores condiciones de vida.(CENAPRED, 2018)

Veracruz, aunque cuenta con climas tropicales, además de su rica biodiversidad, en los últimos años en el territorio se han experimentado cambios climáticos adversos, el 2024 se ha considerado como el año más seco desde 1981 con temperaturas arriba de los 30° Centígrados, incluso en las zonas que poseen las temperaturas templadas del estado. (Diario de Xalapa, 2024)

Estos cambios han conducido a sequías que afectan tanto a la agricultura como a los recursos hídricos de la región. La agricultura, una de las principales actividades económicas, ha sufrido pérdidas significativas por la escasez de agua y el impacto del calor extremo en los cultivos. Además, la disminución de las precipitaciones ha afectado los cuerpos de agua, reduciendo la disponibilidad de agua potable para las comunidades locales y afectando negativamente los ecosistemas.

1.3 Justificación

El impacto del cambio climático en el mundo ha cobrado mayor relevancia en las últimas tres décadas, evidenciando su influencia en distintos sectores y regiones. En el 2013, el Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC), afirma que el calentamiento en el sistema climático es inequívoco y que se están observando cambios que no tienen precedentes. Las variaciones en el clima, especialmente en los patrones de lluvia y el incremento de las temperaturas, representan una amenaza directa para la disponibilidad de agua. Esta situación afecta de manera más severa a las poblaciones vulnerables en los países en desarrollo, donde el acceso a recursos hídricos ya es limitado.

Las variaciones en el clima, junto con eventos meteorológicos extremos y los cambios previstos en las condiciones globales, ejercen una gran influencia sobre la producción agrícola y ganadera. Este impacto se observa tanto a nivel local, regional como nacional, comprometiendo la seguridad alimentaria, el equilibrio ambiental y la estabilidad económica de las comunidades rurales. El cambio climático afecta la productividad agrícola de manera directa e indirecta, provocando modificaciones en los patrones de lluvia, periodos de sequía e inundaciones, además de alterar la distribución geográfica de plagas y enfermedades. Las grandes cantidades de CO_2 absorbidas por los océanos causan acidificación, influyendo en la salud de los océanos y en aquellos cuyos medios de vida y nutrición dependen de ellos. (FAO, 2023)

La cadena de suministro agrícola a nivel mundial desempeña un papel crucial en la emisión de gases de efecto invernadero, siendo responsable de aproximadamente un tercio del total, solo superado por el sector energético. Además, representa la mayor fuente de emisiones de metano y contribuye significativamente a la pérdida de biodiversidad. Si no se implementan soluciones efectivas, la reducción en el rendimiento de los cultivos especialmente en las zonas más afectadas por la inseguridad alimentaria podría llevar a un aumento de la pobreza en diversas comunidades. En zonas donde los recursos hídricos ya son limitados, el cambio climático causará cada vez más impactos adversos en la producción agrícola debido a la disminución de los suministros de agua, el aumento de fenómenos meteorológicos extremos.(Banco Mundial, 2022)

Ante este escenario, el análisis de vulnerabilidad y riesgo climático se ha convertido en una herramienta clave para orientar decisiones en el sector agropecuario. A través de estos estudios, es posible identificar y comprender de manera integral los desafíos y oportunidades que el cambio climático plantea para la agricultura y la ganadería. Además, este enfoque permite adoptar estrategias informadas de adaptación, fortaleciendo la resiliencia de los sistemas productivos y reduciendo su vulnerabilidad frente a las variaciones climáticas.

1.4 Objetivos

1.4.1 Objetivo general

Desarrollar un modelo de vulnerabilidad y riesgo agropecuario mediante la creación de escenarios de impacto provocados por el cambio climático para proponer esquemas de adaptación.

1.4.2 Objetivos específicos

- Desarrollo de indicadores de vulnerabilidad basados en la recolección de información para alimentar un modelo de vulnerabilidad de un sistema de multi agentes basado en técnicas de inteligencia artificial y así establecer una escala de referencia de vulnerabilidad.
- Validar el modelo de vulnerabilidad en base a la dinámica histórica del riesgo para proyectar mediante tendencias los índices de vulnerabilidad aplicado en un caso de estudio.
- Desarrollar un agente reactivo capaz de obtener escenarios alternativos de vulnerabilidad mediante análisis multicriterio para el apoyo a la toma de decisión
- Desarrollar un modelo de procesamiento digital de imágenes para detectar áreas de interés que pudieran poner en riesgo el sector agropecuario.

1.5 Hipótesis

El desarrollo de un modelo de vulnerabilidad y riesgo agropecuario basado en técnicas de inteligencia artificial a través de escenarios de impacto causados por el cambio climático permitirá la obtención de esquemas de trabajo y adaptabilidad.

1.6 Estado del arte

1. Cambio Climático

El cambio climático debe abordarse desde un enfoque multidisciplinario que integre factores ambientales, económicos y sociales, permitiendo una comprensión más profunda de sus implicaciones. Este análisis resulta fundamental, ya que su impacto se extiende a múltiples dimensiones de la vida humana y compromete la estabilidad de los ecosistemas (Díaz Cordero, 2012). El artículo destaca los efectos profundos en las sociedades humanas, especialmente en las comunidades más vulnerables. La autora denota la importancia de políticas públicas efectivas y la cooperación internacional para mitigar los efectos y adaptarse a los cambios inevitables.

Dentro de contribuciones significativas se encuentra el análisis de riesgo y vulnerabilidad relacionados con el cambio climático, se destaca la importancia de conocer las regiones y comunidades más expuestas a estos efectos para implementar medidas de adaptación efectivas. Este enfoque es clave para optimizar la planificación y administración de recursos en entornos caracterizados por la incertidumbre climática.

2. Panorama agropecuario ante cambio climático

(Mora et al., 2010) El impacto del cambio climático en el sector agropecuario de Costa Rica se analiza en una perspectiva de largo plazo, considerando su efecto hasta el año 2100. Este estudio abarca tanto la producción pecuaria como agrícola, incluyendo algunos de los cultivos más relevantes para la economía del país. Se destaca que las variaciones en el clima y su influencia en la producción podrían generar una reconfiguración de los cultivos, modificando el uso del suelo. Por ello, también se examinan las posibles repercusiones sobre el valor de la tierra. Además, se observa que los efectos adversos del cambio climático ya están afectando al sector agropecuario y, si no se implementan mejoras en las condiciones de producción, estas consecuencias podrían intensificarse en el futuro. El análisis realizado sugiere que es probable que se haya superado la temperatura óptima para alcanzar los mayores niveles de producción. Asimismo, los registros de precipitaciones recientes muestran valores inferiores a los necesarios para garantizar la máxima productividad. De esta manera, el cambio climático

ya podría estar generando impactos negativos en la actividad agropecuaria en su conjunto.

3. Vulnerabilidad y riesgo agrícola

(Monterroso Rivas Alejandro Ismael et al., 2007) Realiza una evaluación exhaustiva de cómo el cambio climático afecta la agricultura en la región de Veracruz y sugiere estrategias para mitigar dichos impactos. El estudio emplea metodologías del IPCC para evaluar la vulnerabilidad y el riesgo, proporcionando un marco científico sólido internacionalmente, donde se permite una evaluación sistemática y comparativa de los riesgos climáticos. Este estudio aborda diversas dimensiones del impacto del cambio climático, analizando variaciones en la temperatura, la precipitación y la ocurrencia de eventos extremos como huracanes y sequías. Se establecen distintos niveles de aptitud para el cultivo de maíz y café, considerando factores como temperatura, precipitación y altitud. Para ello, se aplicaron tasas de cambio derivadas de modelos climáticos desarrollados en Norteamérica, el Reino Unido y Alemania, con proyecciones para los años 2020 y 2050. Los rangos de aptitud quedaron clasificados en las siguientes categorías: Apto, Moderadamente Apto, Marginalmente Apto y No Apto. Los escenarios proyectados indican una reducción en la precipitación de entre un 10% y un 20% en comparación con los valores actuales, mientras que la temperatura se espera que aumente progresivamente, desde 1°C en 2020 hasta alcanzar 4°C para el 2050

4. Adaptación al cambio Climático

(Altieri Miguel A & Nicholls Clara, 2018) Proponen la agroecología como una solución integral al cambio climático, argumentando que las prácticas agroecológicas no solo mejoran la sostenibilidad y la productividad de los sistemas agrícolas, sino que también aumentan su resiliencia ante eventos climáticos extremos. La agroecología se presenta como una alternativa viable y necesaria frente a la agricultura industrial, que es insostenible y contribuye significativamente al cambio climático. El artículo distingue entre adaptación y transformación en el contexto de la agricultura. La adaptación se refiere a ajustes incrementales que permiten a los sistemas agrícolas existentes enfrentar los cambios climáticos. Por otro lado, la transformación implica cambios más profundos y estructurales que reconfiguran los sistemas agrícolas hacia una mayor sostenibilidad y

adaptabilidad. Además, se sostienen que, si bien la adaptación es necesaria, no es suficiente por sí sola para abordar las raíces del problema climático; la transformación de los sistemas agrícolas es esencial.

5. Cambio climático y la vulnerabilidad agrícola

(Gunter Fischer et al., 2002) Aborda los impactos del cambio climático en la agricultura y examina la vulnerabilidad del sector agrícola ante estos cambios. El estudio, realizado por el Centro Internacional de Información sobre Ciencias de la Tierra (IIASA), se centra en varios aspectos claves, modelos y escenarios climáticos, el impacto en la productividad agrícola y la vulnerabilidad regional, Además, se destaca la relevancia de la colaboración internacional para enfrentar los desafíos que el cambio climático representa a nivel global y garantizar la seguridad alimentaria

6. Indicadores de vulnerabilidad agrícola para el cambio climático

(Simone Neset Tina et al., 2019) Examina la selección y aplicación de indicadores para evaluar la vulnerabilidad de la agricultura sueca frente al cambio climático. Se aborda la vulnerabilidad agrícola desde múltiples dimensiones, exposición, sensibilidad y capacidad de adaptación. Lo que proporciona una visión completa de los factores que repercuten directamente en la vulnerabilidad agrícola.

7. Ciclo hidrológico ante el cambio climático

El clima y el ciclo hidrológico están interconectados, por lo que el aumento de la temperatura y los cambios en los patrones de precipitación previstos en los escenarios climáticos más probables tendrán un impacto significativo en la disponibilidad de agua a nivel global, con efectos particularmente relevantes en México. Se espera un incremento en la intensidad de las lluvias y la frecuencia de eventos extremos, lo que aumentará la vulnerabilidad de diversas cuencas en el sureste del país, una región que ya enfrenta problemas recurrentes de inundaciones. Para lidiar con estos y otros efectos del cambio climático en el territorio mexicano, se requiere de mejores modelos basados en escenarios de cambio climático, y diseñar y priorizar acciones de adaptación en las regiones hidrológicas más vulnerables. (Martínez-Austria & Patiño, 2012).

8. Inteligencia artificial ante el cambio climático

(Snow Jackie, 2019) La inteligencia artificial ha emergido como una herramienta en la constante mitigación del cambio climático, donde se deben aportar soluciones innovadoras y eficaces en varios sectores. En este artículo se denota el impacto potencial de la IA en la mitigación de los efectos climáticos a través de la predicción, el monitoreo y la optimización de recursos. La implementación de diferentes técnicas de inteligencia artificial permite procesar grandes volúmenes de datos que provienen de satélites y registros meteorológicos con lo que se puede predecir patrones climáticos futuros y monitorear emisiones en tiempo real. La capacidad de análisis avanzado mejora significativamente la anticipación y la respuesta a eventos climáticos extremos, facilitando la implementación de medidas preventivas y de mitigación. Además, se hace notar que, en la agricultura de precisión, impulsada por inteligencia artificial, permite optimizar el uso de los recursos, tales como el agua y los fertilizantes, haciendo que se reduzca la necesidad de pesticidas y aumentando así la productividad agrícola, enfrentando los desafíos de cambio climático y dando seguridad alimentaria.

i. Redes neuronales artificiales (RNA)

(Cervantes Osornio Rocio & Arteaga Ramírez Ramón, 2010) Realizan una comparación de metodologías convencionales con modelos de RNA para estimar presión real de vapor de agua, radiación global diaria y evapotranspiración de referencia, para estimar por medio de redes neuronales artificiales la cantidad de agua requerida para compensar la pérdida por evapotranspiración del cultivo se define como necesidades hídricas del cultivo, en donde se tiene que los agentes meteorológicos que afectan a la ET_0 (Perdidas por evapotranspiración) son las variables temperatura, radiación global, humedad relativa y velocidad del viento, donde la ET_0 se calcula a partir de estos parámetros. En este estudio se ha evidenciado que las redes neuronales artificiales constituyen una herramienta altamente efectiva para la estimación y predicción de diversas variables clave, como la presión real de vapor de agua, la radiación global y la evapotranspiración de referencia.

ii. Modelos basados en agentes

(Jiménez, 2020) Asegura que el uso eficiente del agua es fundamental para la sostenibilidad de la agricultura y la seguridad alimentaria, al reducir la vulnerabilidad en la producción de cultivos, causada por la escasez o el desperdicio del recurso. La investigación propone un sistema de gestión de riego inteligente mediante un modelo basado en agentes (MBA), diseñado para mejorar la distribución del recurso hídrico en el Distrito de Riego de Colombia. La solución integra un agente ciber-físico capaz de calcular y dosificar volúmenes de agua óptimos según parámetros agronómicos, junto con un MBA que coordina la asignación del recurso mediante funciones de utilidad. Estas funciones consideran tanto el estado fisiológico de los cultivos como variables socioambientales entre los agentes involucrados en la zona de estudio

iii. Inteligencia artificial y detección de incendios

Dentro de las afecciones que podría causar los periodos prolongados de sequía y los aumentos de temperatura son los incendios forestales con mayor frecuencia e intensidad, la ocurrencia de estos eventos pone en jaque a las autoridades porque su ocurrencia principalmente es en tiempos de estiaje, los incendios forestales son causante de perdida de vegetación además de erosión de suelo y emisión de gases de efecto invernadero. (Valle, 2016) En su trabajo propone el uso de tratamiento digital de imágenes mediante el desarrollo de una aplicación especializada que previene y genera alertas tempranas de focos ígneos. El sistema permite enviar notificaciones a dispositivos remotos, incluyendo una imagen digital con la ubicación y el momento exacto del incendio, alertando sobre la presencia de fuego y humo forestal, reduciendo la necesidad de un monitoreo físico constante

iv. Tratamiento digital de imágenes

(Andrade, 2009) Aborda la incertidumbre como un componente clave dentro de la Teoría Social del Riesgo aplicada a fenómenos como inundaciones y sequías, destacando su influencia en la configuración territorial del riesgo asociado a estos eventos. La limitada disponibilidad de información en la región resalta la necesidad de recurrir a fuentes alternativas y el uso de indicadores para obtener datos relevantes. Además, se señala que

los enfoques tradicionales de la ciencia no siempre ofrecen soluciones adecuadas para gestionar el territorio cuando las comunidades enfrentan emergencias constantes. En este contexto, se examina la aplicación de herramientas como la Teledetección y los Sistemas de Información Geográfica para gestionar la incertidumbre y fortalecer el control de la vulnerabilidad social frente a estos eventos climáticos, enfatizando su papel fundamental en el desarrollo regional.

v. Estrés Hídrico y procesamiento de imágenes

(ZHAO et al., 2012) Estudia el estrés hídrico en plantas desde un enfoque innovador utilizando el procesamiento de imágenes basadas en 3D, para capturar detalles precisos de la morfología de las plantas. Estas imágenes permiten una observación detallada de la estructura y cambios en las plantas que pueden ser indicadores de estrés hídrico. Se emplea el procesamiento de imágenes para analizar las características estructurales y morfológicas de las plantas. Esto incluye la identificación de cambios en el volumen, la forma y la textura de las hojas y tallos. La reconstrucción tridimensional de las plantas a partir de imágenes permite un análisis más detallado y preciso de la estructura de la planta en comparación con las imágenes 2D tradicionales. Las características cuantificables derivadas de las imágenes 3D, como la densidad foliar y el área de superficie, se analizan para detectar signos de estrés hídrico. Se utilizan algoritmos de aprendizaje automático para clasificar y predecir el estado de estrés hídrico de las plantas basándose en los datos obtenidos de las imágenes 3D. Estos algoritmos pueden identificar patrones y correlaciones que no son fácilmente visibles al ojo humano.

vi. Imágenes Hiper espectrales y estrés hídrico

(Mohd et al., 2019) Usa imágenes hiper espectrales para detectar el estrés hídrico y la recuperación en plantas de maíz dentro de una plataforma de fenotipado de alto rendimiento, con el objetivo principal de desarrollar y validar un método de análisis de imágenes para la detección temprana del estrés hídrico y la recuperación en plantas de maíz mejorando la selección de genotipos tolerantes a la sequía y analizar las funciones de genes relacionados con la respuesta al estrés hídrico, utilizando cámaras hiper espectrales de corto alcance para capturar imágenes detalladas de las plantas de maíz, abarcando un amplio rango de longitudes de onda, en lugar de usar índices de vegetación

convencionales, el método se centra en la selección de bandas espectrales con alta información discriminativa que son sensibles a los cambios fisiológicos causados por el estrés hídrico. El método propuesto permite detectar respuestas al estrés hídrico en una etapa temprana, antes de que los síntomas sean visibles a simple vista.

vii. Modelo de Vulnerabilidad basado en Multi agentes

(A. E. Badillo, 2021) Presenta un modelo basado en agentes inteligentes mediante la valoración dinámica del riesgo agrícola para estimar la vulnerabilidad de la caña de azúcar del sector agrícola en el estado de Veracruz, este modelo permite plantear diferentes escenarios determinando el impacto que tienen la interacción de las variables. Además, en su trabajo realiza la combinación de técnicas de inteligencia artificial como tratamiento digital de imágenes y lógica difusa.

En las tablas 1-4 se muestra un concentrado de manera resumida de cada uno de los artículos consultados para la construcción del estado del arte.

Tabla 1 Concentrado estado del arte (parte 1)

Artículo	Autor(es)	Año	Aportación
El Cambio Climático	Gerarda Díaz Cordero	2012	• Concienciación sobre los efectos del cambio climático, análisis de los impactos del cambio climático al medio ambiente. • Propuestas de mitigación y adaptación, propone estrategias para reducir los efectos del cambio climático y la adaptación a sus impactos • Educación y divulgación científica, divulgación científica como herramienta para combatir el cambio climático
Costa Rica: Efectos del cambio climático sobre la agricultura	Mora, Jorge Ordaz, Juan Luis Ramírez, Diana Serna Hidalgo, Braulio	2010	• Análisis de las afecciones de cultivos como el café, banana, y caña de azúcar por cambio climático • Estrategias de adaptación para agricultores ante las nuevas condiciones climáticas
Vulnerabilidad y Riesgo en Agricultura por cambio climático en la Región Centro del Estado de Veracruz, México	Monterroso Rivas Alejandro Ismael Conde Álvarez Ana Cecilia Gómez Díaz Jesús David López García José	2007	• Modelo de evaluación de vulnerabilidad y riesgo agrícola en el centro de Veracruz por cambio climático • Impactos en cultivos y sistemas de producción en maíz, caña de azúcar y cítricos.

Tabla 2 Concentrado estado del arte (parte 2)

Artículo	Autor(es)	Año	Aportación
Agroecología y cambio climático: ¿adaptación o transformación?	Altieri Miguel A Nicholls Clara	2018	• Propone la agroecología como solución integral ante el cambio climático reduciendo la vulnerabilidad de los sistemas agrícolas mejorando la productividad y la seguridad alimentaria al reducir la dependencia de insumos químicos y los combustibles fósiles
Climate Change and Agricultural Vulnerability	G¨unther Fischer Mahendra Shah Harrij van Velthuizen	2002	• Análisis de la vulnerabilidad de los cultivos, la productividad, disponibilidad de agua y la incidencia de plagas y enfermedades como efecto del cambio climático así mismo estudia la estabilidad de los ecosistemas agrícolas • Desarrollo de un modelo de proyecciones para prever los impactos del cambio climático en la agricultura, considerando emisiones de GEI, temperatura, precipitación y eventos extremos
Evaluation of indicators for agricultural vulnerability to climate change: The case of Swedish agriculture	Simone Neset Tina Wiréhn Lotten Opach Tomasz Glaas Erik Ola Linnér Björn	2019	• Sugiere la integración de aspectos cualitativos y cuantitativos en la evaluación de vulnerabilidad, promoviendo un enfoque más holístico y flexible.
Efectos del cambio climático en la disponibilidad de agua en México	Martínez-Austria Polioptro F.	2012	• Pronósticos de temperatura y precipitación • Impactos en cuencas hidrológicas que dependen de deshielos • Predicción del Incremento en la frecuencia de las sequias

Tabla 3 Concentrado estado del arte (parte 3)

Artículo	Autor(es)	Año	Aportación
La inteligencia artificial podría ayudar a combatir el cambio climático	Snow Jackie	2019	• Análisis de volúmenes grandes de datos obtenidos de manera satelital con ayuda de inteligencia artificial • Reducción de emisiones y eficiencia energética • Monitoreo y mitigación de impactos ambientales
Redes neuronales artificiales para estimar y predecir variables climatológicas relacionadas con la evapotranspiración de referencia	Cervantes Osornio Rocio Arteaga Ramírez Ramón	2010	• Modelo de redes neuronales artificiales para estimar presión real de vapor de agua, radiación global diaria y evapotranspiración de referencia, con el objetivo de optimizar la gestión de la humedad en los cultivos
Modelo Basado en Agentes Inteligentes como Soporte a la Gestión del Riego en Cultivos Agrícolas	Jiménez López Andrés Fernando	2020	• Modelo para la optimización de uso del agua de riego • Reducción de costos por usos de agua, mejorando la productividad y asegurando el suministro de recurso hídrico en momentos críticos del cultivo
Sistema electrónico de alerta temprana de Incendios Forestales mediante Procesamiento Digital de imágenes para la empresa municipal del cuerpo de bomberos Ambato	Valle, David	2016	• Desarrollo de un sistema de alarma temprana por medio de envíos de correo electrónico al realizar procesamiento digital de imágenes que permite respuesta de manera eficiente y rápida por cuerpo de bomberos

Tabla 4 Concentrado estado del arte (parte 4)

Artículo	Autor(es)	Año	Aportación
Aplicación de la TD en la obtención de datos para mitigar la incertidumbre en el riesgo hídrico	Andrade, Isabel	2009	• Monitoreo de recursos hídricos de manera automatizada por procesamiento digital de imágenes, incluyendo cuerpos de agua, niveles de agua subterránea, y la extensión de áreas afectadas por sequías o inundaciones • Modelo de predicción de eventos extremos por teledetección
Identify Plant Drought Stress by 3D-Based Image	ZHAO Yan-dong SUN Yu-rui CAI Xiang LIU He Schulze, Peter	2012	• Análisis de características tridimensionales de las plantas como la forma y estructura y el cambio de estas ante la sequía • Identificación de biomarcadores de estrés como el contenido de agua, la fluorescencia de la clorofila u otros indicadores bioquímicos
Analysis of hyperspectral images for detection of drought stress and recovery in maize plants in a high-throughput phenotyping platform	Mohd, Shahrimie Mertens, Stien Dhondt, Stijn Inzé, Dirk Wuyts, Nathalie Scheunders, Paul	2019	• Explora cómo la detección temprana del estrés por sequía en plantas de maíz a través de imágenes hiperespectrales podría informar prácticas de manejo agronómico, como la selección de variedades de cultivos resistentes a la sequía o la programación de riegos más eficientes
Evaluación de vulnerabilidad y riesgo agrícola ante el cambio climático a través de un sistema multi-agentes	Badillo Alina Evelyn	2021	• Modelo de vulnerabilidad y riesgo agrícola ante el cambio climático basado en multi agentes • Desarrollo de modelo de lógica difusa • Modelo de redes neuronales convolucionales

1.7 Conclusión de capitulo

El análisis que se presenta en este capítulo evidencia la estrecha relación entre el cambio climático y la vulnerabilidad del sector agropecuario, particularmente en México y en regiones sensibles como Veracruz. Se expone que el incremento de temperaturas, la reducción en la disponibilidad hídrica y la frecuencia de fenómenos meteorológicos extremos constituyen amenazas directas para la agricultura y la ganadería, impactando tanto la seguridad alimentaria como la estabilidad social y económica de las comunidades rurales.

Asimismo, el sector agropecuario resulta afectado por el cambio climático y, simultáneamente, aporta una parte significativa de las emisiones de gases de efecto invernadero. Este panorama demanda estrategias de mitigación y adaptación con un enfoque integral, que combinen gestión de recursos, sostenibilidad productiva y reducción de riesgos.

La revisión del estado del arte permite identificar diversas metodologías y aproximaciones, desde el uso de indicadores y modelos climáticos, hasta la aplicación de inteligencia artificial, procesamiento digital de imágenes y modelos basados en agentes, que fortalecen el marco conceptual y técnico de la investigación. Estas herramientas ofrecen la posibilidad de anticipar impactos, optimizar recursos y generar escenarios alternativos que apoyen la toma de decisiones.

En general, en el Capítulo I establecen los fundamentos teóricos, contextuales y metodológicos que sustentan esta investigación, dejando claro que el estudio de la vulnerabilidad agropecuaria frente al cambio climático requiere de un enfoque integral

CAPÍTULO II. MARCO TEÓRICO

2.1 Cambio climático

Según las Naciones Unidas (UN) “el cambio climático se refiere a los cambios a largo plazo de las temperaturas y los patrones climáticos. Estos cambios pueden ser naturales, debido a variaciones en la actividad solar o erupciones volcánicas grandes”. Pero desde el siglo XIX, las actividades humanas han sido el principal motor del cambio climático. Las consecuencias del cambio climático incluyen ahora, entre otras, sequías intensas, escasez de agua, incendios graves, aumento del nivel del mar, inundaciones, deshielo de los polos, tormentas catastróficas y disminución de la biodiversidad. (Naciones unidas , 2023)

El clima no es un valor fijo, sino un fenómeno caracterizado por su variabilidad en distintos períodos de tiempo, definido por elementos como la temperatura, las precipitaciones y los vientos. Su evolución está influenciada por factores externos, entre ellos la latitud geográfica, la altitud, la proximidad al mar, la orientación del relieve terrestre respecto al sol, la dirección del viento y las corrientes oceánicas. Estos elementos, y sus variaciones a lo largo del tiempo, provocan cambios en las condiciones climáticas, afectando parámetros fundamentales como la temperatura, la presión atmosférica, los vientos, la humedad y las precipitaciones. Dependiendo de la dinámica con la que ocurren, estos cambios pueden seguir patrones sistemáticos o manifestarse de manera más caótica. (Useros Fernández, 2013)

2.1.1 Efectos del cambio climático

El cambio climático es un fenómeno que se ha venido observando durante décadas, algunos cambios como sequias, incendios forestales y lluvias extremas están ocurriendo incluso más rápido de lo previsto. Las proyecciones indican que las sequías en el suroeste y las olas de calor (periodos prolongados de temperaturas anormalmente alta) se volverán más intensos, mientras que las olas de frío serán menos severas y frecuentes. Además, se prevé que todas las estaciones seguirán experimentando un aumento en las temperaturas. Si las emisiones de gases de efecto invernadero continúan al ritmo actual, hacia finales de este siglo podríamos presenciar

eventos de calor extremo cada año, fenómenos que antes ocurrían solo una vez cada dos décadas. (NASA, 2024)

La actividad humana sin duda contribuye al aumento de la problemática con actividades básicas para su existencia como la ganadería y la agricultura, y esto representa efectos en niveles también socioeconómicos, como costos de adaptación, desplazamiento de población, disminución en la productividad agrícola, además del empeoramiento del acceso al recurso hídrico. (figura 1)



Figura 1 Efectos socioeconómicos del cambio climático (Iberdrola, 2024)

2.1.2 México ante el cambio climático

Las condiciones socioeconómicas como la pobreza y las desigualdades, la fragilidad de los ecosistemas naturales y las características geográficas y climáticas de nuestro país, hacen que México sea sumamente vulnerable al cambio climático. En los últimos 50 años, las temperaturas promedio del país han registrado un aumento de aproximadamente 0.85°C por encima de la norma climatológica, en línea con el incremento global reportado por el Grupo Intergubernamental de Expertos sobre el Cambio Climático. Las temperaturas mínimas y máximas presentan una tendencia

hacia un incremento de noches cálidas y una disminución de noches frías en todo el país. Se proyecta que entre 2015 y 2039, la temperatura media anual del país aumente entre 1.5°C y 2°C, con un mayor impacto en las regiones del norte.(INEEC, 2021)

En la figura 2 se observa el cambio de temperaturas, en donde se tiene un desplazamiento hacia temperaturas más cálidas, lo que modifica los promedios y los extremos de las temperaturas según el instituto nacional de ecología y cambio climático.

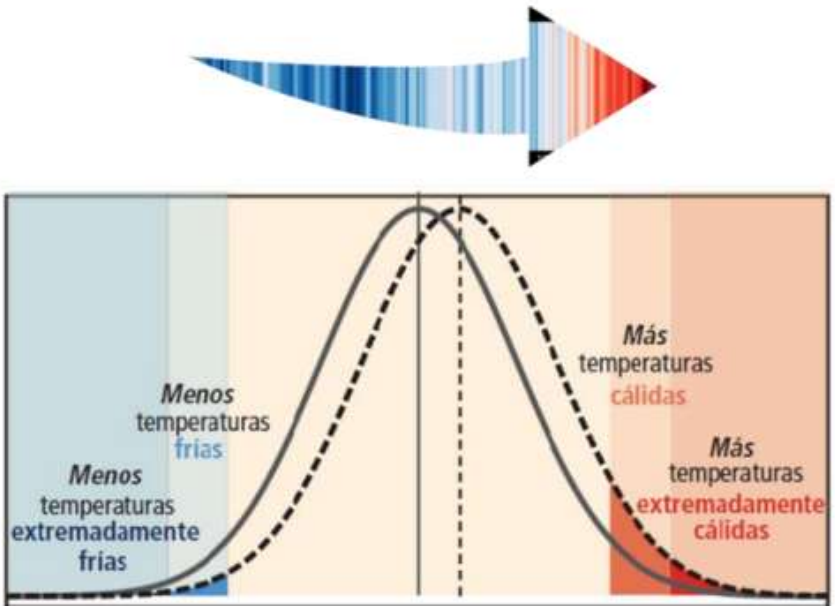


Figura 2 Modificaciones del promedio y extremos de las temperaturas con el cambio climático (López et al., 2022)

2.1.3 Desastres naturales

De acuerdo con (Guha , Vos, & Below, 2011) La ocurrencia de eventos hidrometeorológicos extremos, como inundaciones o sequías, ha aumentado de forma acelerada en los últimos decenios. A nivel mundial, entre 1990 y 2005, estos fenómenos ocasionaron más de cuatro mil desastres. En México, entre 1990 y 2010, se registraron 37 desastres relacionados con inundaciones, lo que resultó en la pérdida

de más de 1 600 vidas, afectando a casi dos millones de personas y generando daños materiales que superaron los cuatro mil millones de dólares.

Define también “desastre” como “una situación o evento que desborda la capacidad local, requiriendo una solicitud a nivel nacional o internacional de ayuda externa; un imprevisto y a menudo repentino acontecimiento que causa grandes daños, destrucción y sufrimiento humano”. Lo clasifica en 5 principales grupos:

- Geofísicos
- Meteorológicos
- Hidrológicos
- Climatológico
- Biológicos

El clima es el resultado de una compleja interacción entre diversos elementos y factores, por lo que cualquier modificación puede alterar el equilibrio del sistema. Para adaptarnos a los cambios climáticos es esencial comprender cómo están evolucionando las condiciones a nivel global, regional y local. En la actualidad, ya se han identificado numerosos impactos que seguirán manifestándose en el futuro, entre ellos el aumento de la temperatura promedio global tanto en los océanos como en la superficie terrestre, la elevación del nivel del mar a nivel mundial y la acidificación de los océanos, afectando los ecosistemas marinos. También se ha observado un incremento en la temperatura superficial de los océanos, lo que repercute en la vida marina y altera la abundancia de algas, plancton y peces, modificando los equilibrios ecológicos.

Además, los patrones de precipitación han cambiado, dando lugar a inundaciones recurrentes, mientras que la frecuencia e intensidad de huracanes, especialmente en el Atlántico Norte, ha aumentado. Las sequías son cada vez más prolongadas, afectando la disponibilidad de agua, y el número de días y noches cálidas sigue incrementándose, con olas de calor más frecuentes en regiones como Europa, Asia y Australia. A consecuencia de estos cambios, la disponibilidad de agua para consumo

humano, agrícola e hidroeléctrico ha disminuido, y la productividad agrícola se ha visto afectada, comprometiendo la seguridad alimentaria.

Asimismo, el deshielo progresivo en Groenlandia y la Antártida, junto con la reducción de los glaciares a nivel mundial, evidencia el impacto del cambio climático en los ecosistemas polares. La pérdida de biodiversidad es otra de sus consecuencias, ya que altera la composición de los ecosistemas y modifica los ciclos biológicos y la distribución de flora y fauna. En este contexto, el riesgo de incendios forestales ha aumentado debido a condiciones más secas, y los vectores de enfermedades infecciosas han cambiado, afectando ciertas regiones. En Europa, el incremento de temperaturas extremas ha derivado en un aumento de la mortalidad.(Instituto Nacional de Ecología y Cambio Climático, 2018)

2.1.4 Procesos asociados con el cambio climático

De acuerdo con (Office of the United Nations Disaster Relief Coordinator, 1980) existen conceptos fundamentales para comprender la ocurrencia de desastres naturales. La "amenaza natural" se refiere a la “probabilidad de que ocurra un fenómeno natural potencialmente dañino en un área determinada dentro de un periodo específico”. La "vulnerabilidad" se define como “el grado de pérdida que puede experimentar un elemento o conjunto de elementos en riesgo debido a la ocurrencia de dicho fenómeno”, con una magnitud expresada en una escala de 0 a 1 (desde ningún daño hasta una pérdida total).

Por otro lado, los "elementos de riesgo" comprenden todas aquellas personas, construcciones, obras de ingeniería civil, actividades económicas, servicios públicos e infraestructura que se encuentran expuestos a peligros en una región específica. El "riesgo específico" se calcula como el grado esperado de pérdidas derivadas de un fenómeno natural particular, resultante de la interacción entre la amenaza y la vulnerabilidad. Finalmente, el concepto de "riesgo" representa la cantidad estimada de vidas perdidas, personas heridas, daños materiales y la interrupción de actividades económicas provocadas por un desastre natural, siendo el producto del riesgo específico y los elementos expuestos al peligro.

2.1.5 Vulnerabilidad ante el cambio climático

La magnitud y el impacto de los fenómenos climáticos extremos no dependen únicamente de su intensidad, sino también de la exposición de las comunidades y su grado de vulnerabilidad. Los efectos adversos alcanzan la categoría de desastre cuando generan daños a gran escala y provocan alteraciones significativas en el funcionamiento normal de sociedades y comunidades. Estos eventos, junto con la exposición y la vulnerabilidad, están condicionados por diversos factores, entre ellos el cambio climático antropogénico, la variabilidad natural del clima y el desarrollo socioeconómico, los cuales influyen en la forma en que las poblaciones enfrentan y responden a estos riesgos ambientales. (Figura 3)

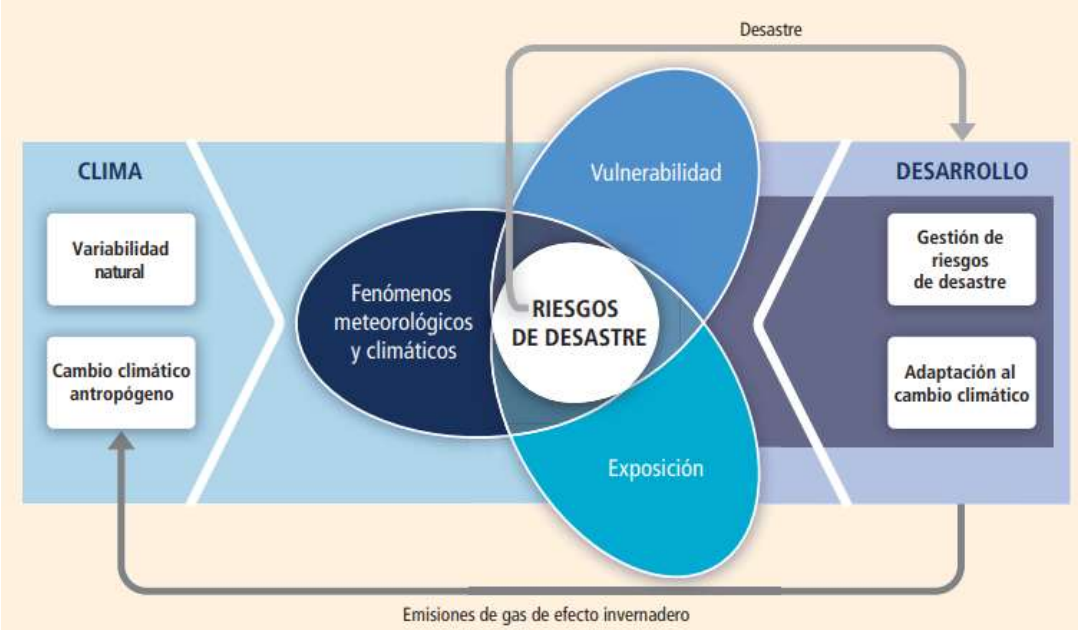


Figura 3 Conceptos centrales del Informe especial sobre la gestión de los riesgos de fenómenos meteorológicos extremos y desastres para mejorar la adaptación al cambio climático (Grupo Intergubernamental de Expertos sobre el Cambio Climático, 2012)

2.1.6 Exposición y vulnerabilidad

Los efectos de los fenómenos climáticos extremos y la posibilidad de desastres son el resultado tanto de la intensidad de estos eventos como de la exposición y vulnerabilidad de los sistemas humanos y naturales. Las variaciones observadas en estos fenómenos reflejan la influencia del cambio climático provocado por la actividad humana, además de la propia variabilidad natural del clima. Asimismo, los

cambios en la exposición y la vulnerabilidad están determinados por una combinación de factores climáticos y no climáticos, lo que subraya la complejidad de los desafíos que enfrentan las comunidades en la gestión del riesgo y la adaptación.(Grupo Intergubernamental de Expertos sobre el Cambio Climático, 2012)

La exposición y la vulnerabilidad son condiciones dinámicas que cambian con el tiempo y en función del espacio, influenciadas por factores económicos, sociales, geográficos, demográficos, culturales, institucionales, de gobernanza y ambientales. Las diferencias en los niveles de riqueza y educación, así como la discapacidad, el estado de salud, el género, la edad, la clase social y otros aspectos socioculturales, determinan distintos grados de exposición y vulnerabilidad entre individuos y comunidades. Estas desigualdades moldean la capacidad de respuesta y adaptación frente a los riesgos, destacando la importancia de abordar la vulnerabilidad desde una perspectiva integral.

2.2 Cambio climático y sus efectos en el Sector agropecuario en México

México, se encuentra en una zona geográfica, con condiciones climáticas y orográficas e hidrológicas que lo hacen más vulnerable a los efectos provocados por el cambio climático.(Secretaría de Agricultura y Desarrollo Rural, 2015)

Diversos modelos desarrollados que permiten generar escenarios ante el cambio climático proyectan que en México se pueden presentar un aumento hasta de 4° centígrados de temperatura para la zona fronteriza con estados unidos en donde se ha presentado puntos críticos de sequía desde el 2022, para el resto del país se puede proyectar un aumento de temperatura desde 2.5° C hasta 3.5° C. En cuanto a precipitaciones se espera una disminución de un 5 y 10%. (Instituto Nacional de Ecología y Cambio Climático, 2018)

De acuerdo con estos modelos, México se encuentra frente a escenarios de riesgo, para diferentes sectores como la agricultura, recurso hídrico, tormentas y clima severos. Estos impactos pueden ser impactos bajos, medios o altos.

Donde se muestra un impacto importante del cambio climático es en el recurso hídrico, la mayoría del país se volverá mas seca y estos periodos de sequía serán más frecuentes, particularmente en el norte del país y zonas urbanas.

Según (Graciela Magrin, 2007) El cambio climático, afecta directamente el rendimiento de los cultivos, esto al depender de las condiciones climáticas como cantidad de lluvia y temperaturas para su correcto desarrollo, además se propicia la perdida de ganado, así como destrucción de siembras. Las variaciones extremas de temperatura provocan además en las zonas de transmisión, que las plagas y enfermedades se propaguen con mayor facilidad acelerando las consecuencias para el sector agropecuario.

En el sector agrícola, existen diferentes factores que se deben tomar a consideración para mantener la salud de los cultivos, estos son; lluvia, temperatura, radiación solar y la concentración de dióxido de carbono. La alteración de estos factores debido al cambio climático puede resultar en positivo o en negativo para los diferentes cultivos, los cambios en los periodos de lluvia y en la intensidad de esta, se relaciona directamente con los puntos críticos de crecimiento y la floración de los cultivos, afecta directamente el rendimiento, de esta alteración puede resultar propagación de plagas, sequias e inundaciones. Con respecto a los cambios de temperatura, por lo regular se tienen resultados adversos, repercute directamente en la duración de los ciclos, aumentos de olas de calor o aumento de heladas. La radiación solar y la concentración de CO_2 tienen impacto en la acumulación de biomasa, eficiencia de fotosíntesis, así como el uso de agua y nitrógeno.

En la figura 4 se muestran las estadísticas porcentuales de lluvia del periodo de 1941-2020, las barras azules representan las anomalías de lluvias para cada año y la línea roja continua representa la media móvil, cuando la barra azul se encuentra por debajo de la línea central significa que la precipitación fue menor al valor promedio.

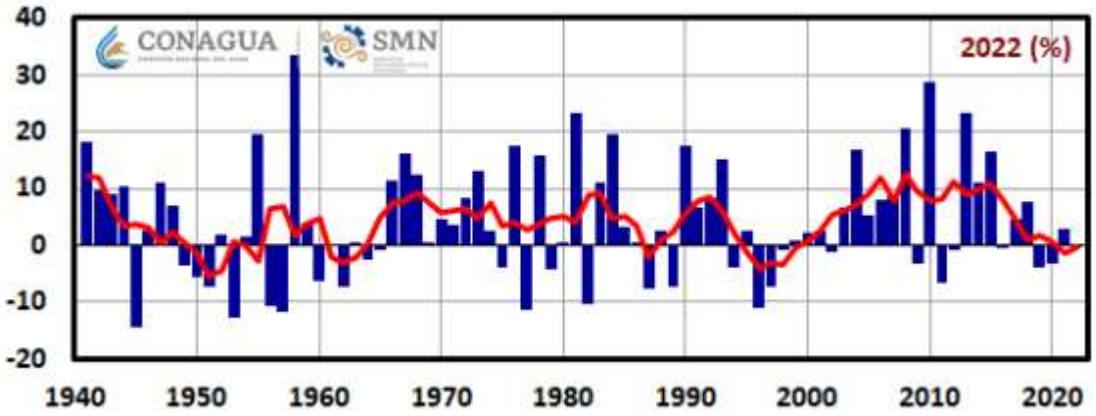


Figura 4 Anomalías de precipitaciones a nivel nacional 2022 (CONAGUA)

2.2.1 Efectos del cambio climático en la producción de Caña

México, debido a su riqueza en clima y características de suelos favorables es un país muy competitivo en la producción agropecuaria a nivel mundial, la producción agrícola es muy variada, los cultivos más importantes son el maíz, aguacate, caña de azúcar, tomate y agave, siendo la caña de azúcar uno de los productos agrícolas con mayor tonelaje de producción, tan solo en el 2017 se produjeron 56.3 millones de toneladas, según la encuesta nacional Agropecuaria. (Encuesta Nacional Agropecuaria (ENA), 2018)

De acuerdo con (Secretaría de Agricultura y Desarrollo Rural, 2021) con datos del comité nacional para el desarrollo sustentable de la caña de azúcar, la agroindustria de la caña genera de manera directa 440 mil empleos mientras que de manera indirecta genera alrededor de 2.2 millones de empleos esto a su vez representa entre 40 y 50 millones de pesos, siendo cultivadas más de 800 mil hectáreas de caña de azúcar en 267 municipios de 15 estados de la república mexicana.

La producción agrícola de la caña de azúcar es expuesta a diferentes factores que afectan o favorecen su rendimiento, estos factores pueden ser; factores humanos, factores ambientales y/o factores agronómicos. Muchos factores pueden ser controlados o mejorados por el humano a través de técnicas y cuidados de agricultura, pero otros factores como los ambientales no, por lo que la producción del cultivo se encuentra vulnerable ante estos factores naturales.

De acuerdo con (CONADESUCA, 2015) los factores son los siguientes:

a) **Factores humanos:** Inciden ya sea de manera positiva o negativa sobre la productividad del sistema de producción; tenencia de la tierra, influencia de la política agrícola, tendencia del mercado, otorgamiento y liberación de créditos, disponibilidad de mano de obra, fluctuación de los precios de compra y venta de los productos, entre otros.

b) **Factores ambientales:** Desde el punto de vista edáfico, destacan aspectos como la capacidad del suelo para retener agua, determinada por su densidad aparente, velocidad de infiltración, porosidad y textura. También es relevante su susceptibilidad a la erosión, ya sea hídrica o eólica, así como su composición química, incluyendo la presencia de sales solubles, niveles de acidez y alcalinidad. En cuanto al clima, variables como la distribución, intensidad y frecuencia de la lluvia, las temperaturas extremas (mínimas y máximas) y la fuerza y dirección de los vientos, tienen un impacto significativo en el desarrollo de los cultivos.

c) **Factores agronómicos:** hacen referencia a aquellas variables que afectan la calidad y el rendimiento agrícola, pero que pueden ser ajustadas mediante prácticas de manejo adecuadas. Entre ellas se incluyen estrategias para la administración eficiente del agua, el control fitosanitario, la labranza y la fertilización, todas orientadas a optimizar la producción y reducir el impacto de condiciones adversas.

En este contexto los factores que más incertidumbre representan para la producción agrícola son los factores ambientales, que, aunque algunos no se pueden controlar al 100 por ciento, si se pueden mitigar sus efectos.

Dentro de los factores ambientales que propicia el cambio climático pueden ser, cambios significativos en los patrones de precipitación provocando inundaciones de campos agrícolas o sequias prolongadas dañando la calidad y el rendimiento del cultivo. Por otro lado, el aumento de temperaturas propiciado por el cambio climático somete muchas veces a los cultivos a estrés térmico, reduciendo la productividad y el crecimiento, así mismo la fotosíntesis se ve afectada en condiciones de calor extremo,

además el ciclo de crecimiento del cultivo se ve afectado por las temperaturas altas al reducir su tiempo de desarrollo y acelerar el tiempo de maduración.

La figura 5 muestra los efectos del cambio climático a nivel mundial, respecto a dos variables de suma importancia para cultivos como lo son las temperaturas y precipitaciones, se observa una proyección de acuerdo con el panel intergubernamental en cambio climático (IPCC, 2013), a) se refiere a los cambios en la temperatura media de la superficie, en la cual hay una proyección de aumento de temperaturas hasta de 9 grados Celsius en algunas regiones del mundo, por otro lado b)muestra los cambios en los patrones de precipitación, se observa para este caso aumento y disminución de precipitaciones, en México la proyección muestra una disminución de precipitación de entre 10 y el 20%.

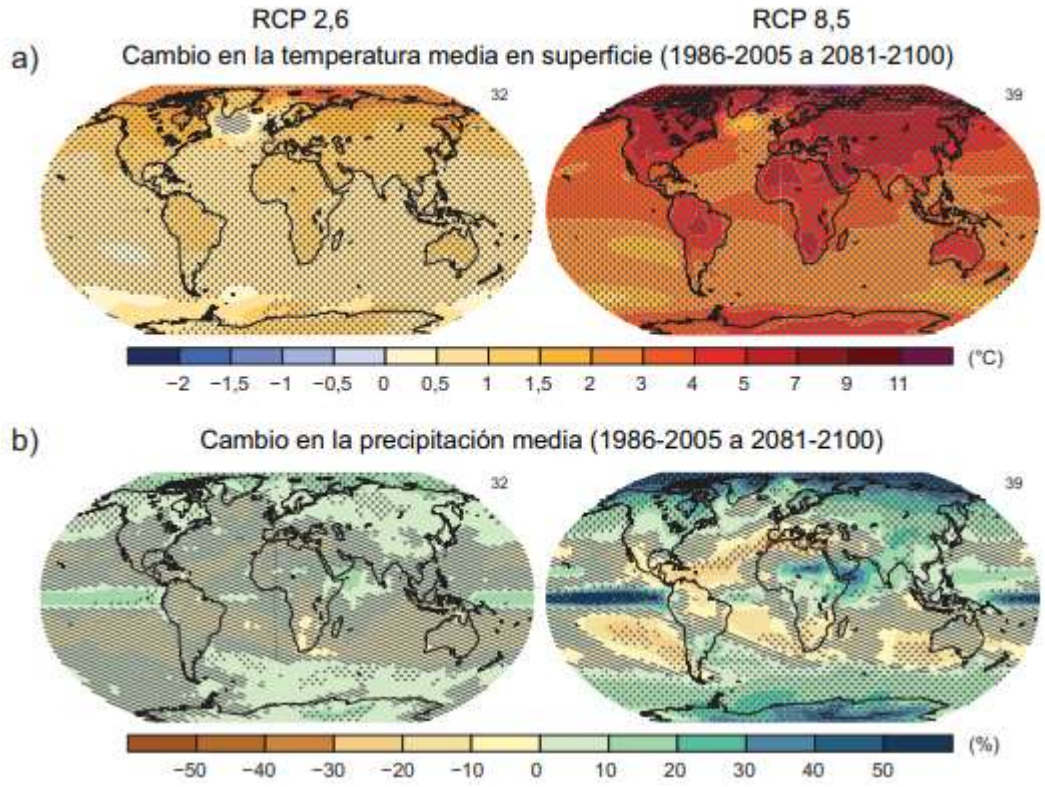


Figura 5 comparación de modelos acoplados (CMIP5) de los escenarios RCP2,6 y RCP8,5, correspondientes al período 2081-2100

Los cambios en el clima antes mencionados también favorecen el desarrollo de enfermedades y plagas del cultivo proliferándose con mayor facilidad y requiriendo más uso de fertilizantes y plaguicidas.

Otros daños resultantes del aumento de temperatura y el cambio en el patrón de precipitación se tienen, mayor erosión del suelo, lo que disminuye su calidad y fertilidad, también se consideran los impactos en la disponibilidad de agua en los sistemas agropecuarios, así como los cambios en la productividad.

Todos estos efectos del cambio climático se ven directamente relacionados con la variabilidad en los costos de producción de los cultivos ya que se dificulta la planificación y conlleva a fluctuación en el rendimiento anual, generando así incertidumbre económica y alimentaria.

2.3 Inteligencia artificial

La inteligencia artificial (IA) ha experimentado un crecimiento significativo en los últimos años y actualmente está teniendo un impacto profundo en la vida cotidiana de las personas. La IA es un campo de la informática que se centra en desarrollar sistemas y tecnologías que pueden realizar tareas que, en su mayoría, requieren inteligencia humana, como el aprendizaje, la resolución de problemas y la toma de decisiones.

En general, según (Boden , 2017) la inteligencia artificial tiene por objeto que los ordenadores hagan la misma cosa que puede realizar la mente humana con la ventaja de que puede articularse sistemas automáticos que posibiliten la ejecución.

La inteligencia artificial (IA) se utiliza cada vez más como apoyo a la toma de decisiones en una amplia gama de campos, desde la atención médica hasta las finanzas y la logística, y cada vez serán mayores las áreas en la que se irá integrando el uso de las diferentes técnicas de inteligencia artificial.

2.3.1 Redes neuronales

Las redes neuronales artificiales (RNA) forman parte de las técnicas de inteligencia artificial las cuales son un tipo de modelo de aprendizaje automático inspirado en el funcionamiento del cerebro humano. Estas redes están diseñadas para procesar información y aprender patrones a partir de datos, de manera similar a cómo lo hacen las neuronas en el cerebro.

Las Redes Neuronales Artificiales (RNA) o sistemas conexionistas son sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas. Consisten en un conjunto de elementos simples de procesamiento llamados nodos o neuronas conectadas entre sí por conexiones que tienen un valor numérico modificable llamado peso (Montaño, 2002).

En un sistema de redes neuronales artificiales, la función de cada unidad de procesamiento es relativamente sencilla. Su tarea principal es sumar los valores de las entradas (inputs) recibidas de otras unidades conectadas, compararlos con un valor umbral y, en caso de alcanzarlo o superarlo, generar una señal de activación o salida (output) hacia las unidades con las que está vinculada. El comportamiento de estas conexiones está determinado por los pesos asignados a cada vínculo, lo que influye tanto en la intensidad de las entradas recibidas como en la magnitud de las señales enviadas.

“Las neuronas tienen tres componentes principales, las cuales son denominadas dendritas, el cuerpo de la célula o soma y el axón. El punto de conexión entre el axón de una célula y una dendrita de otra célula se llama sinapsis”. Desde una perspectiva computacional, las dendritas actúan como los receptores de la red, encargadas de transmitir señales eléctricas al cuerpo de la célula. Este último procesa dichas señales sumándolas para determinar su activación. El axón, una fibra alargada, transporta la señal desde el cuerpo de la célula hasta otras neuronas, facilitando la comunicación neuronal. Aunque una neurona individual es diminuta, cuando se interconecta con muchas otras, forma una red compleja capaz de resolver problemas sofisticados. Un ejemplo notable es el cerebro humano, que alberga billones de neuronas interconectadas. A esta comunicación entre neuronas se le denomina entonces una red neuronal (Acevedo M & Serna A, 2017)

Las neuronas están organizadas en varias capas, de manera que cada una se conecta con la siguiente, permitiendo el flujo de información a través de la red. Cada neurona actúa como una unidad de procesamiento, recibiendo información de las neuronas de la capa previa mediante una capa de entrada, que se encarga de recibir estímulos del exterior. En las redes biológicas, esta función la desempeñan las dendritas. Además,

existen capas ocultas que procesan y transforman la información dentro de la red, cumpliendo un papel equivalente al soma en el sistema neuronal biológico. Finalmente, la capa de salida proporciona el resultado del procesamiento y transmite la información hacia otras neuronas, en un mecanismo similar al que realiza el axón en redes neuronales biológicas

2.3.2 Procesamiento digital de imágenes

"Al conjunto de técnicas y procesos para descubrir o hacer resaltar información contenida en una imagen usando como herramienta principal una computadora se le conoce como procesamiento digital de imágenes (PDI)" (Domínguez, 1996).

El procesamiento digital de imágenes (PDI) es un campo de la informática que se enfoca en el procesamiento y análisis de imágenes digitales. Implica la manipulación de imágenes digitales para mejorar su calidad, extraer información útil, realizar transformaciones y aplicar diversas técnicas para su análisis. El (PDI) es una disciplina amplia y en constante evolución, con numerosos algoritmos y técnicas para abordar problemas específicos en diversas áreas de estudio. El desarrollo de herramientas de software y hardware ha permitido avances significativos en este campo y ha llevado a su aplicación en una variedad de industrias y campos de estudio. A grandes rasgos, el procesamiento digital de imágenes se compone de diferentes etapas que a continuación se describen:

- Preprocesamiento: En esta etapa, se realizan tareas como corrección de ruido, ajuste de contraste, eliminación de artefactos y normalización de las imágenes para mejorar su calidad y hacerlas adecuadas para su posterior análisis.
- Filtrado de imágenes: Los filtros se utilizan para resaltar o atenuar ciertas características de la imagen. Los filtros suavizantes pueden reducir el ruido, mientras que los filtros de realce pueden resaltar bordes o características de interés.
- Transformaciones de imágenes: Se pueden realizar diversas transformaciones en una imagen, como rotación, escala, traslación y cambio de perspectiva. Estas transformaciones son útiles en aplicaciones como la corrección de distorsiones geométricas.

- Segmentación: La segmentación implica dividir una imagen en regiones o segmentos que contienen objetos o características de interés. Esto se hace para facilitar el análisis y la extracción de información relevante
- Extracción de características: En esta etapa, se identifican y se extraen características específicas de la imagen, como bordes, texturas, colores, formas, entre otros. Estas características se utilizan para describir y clasificar objetos en la imagen.
- Reconocimiento de patrones: El reconocimiento de patrones implica el uso de algoritmos y técnicas para identificar objetos, caracteres o patrones en una imagen

2.3.3 Lógica difusa

La lógica difusa, introducida por Lotfi Zadeh (1965) como extensión de la lógica booleana, permite manejar incertidumbre mediante conjuntos difusos (fuzzy sets) que asignan grados de pertenencia en el intervalo [0, 1], superando las limitaciones de las clasificaciones binarias tradicionales (ej.: de "alto/bajo" a "parcialmente alto") (Ross, 2005). Sus aplicaciones abarcan desde control inteligente en sistemas de climatización y frenos ABS hasta diagnóstico médico con síntomas subjetivos y toma de decisiones robóticas en entornos imprecisos o con mucha incertidumbre.

Un sistema difuso típico opera en tres fases:

1. Fuzzificación, donde entradas nítidas (como temperatura = 25°C) se traducen a valores de pertenencia (ej.: 0.7 para "templado")
2. Inferencia, que aplica reglas lingüísticas (como "Si es templado, enfriar ligeramente")
3. Defuzzificación, que convierte los resultados difusos en acciones concretas (ej.: ajustar un ventilador al 40% de velocidad) (Wang, 1997). Esta capacidad para procesar información ambigua la hace indispensable en sistemas donde la precisión clásica es inalcanzable o contraproducente.(Espinosa Oviedo et al., 2005)

2.3.4 Sistema basado en agentes

Los modelos basados en agentes (Agent-Based Models, ABM) son una metodología de simulación que se utiliza para analizar sistemas complejos y dinámicos mediante

la interacción de agentes autónomos e inteligentes. Cada agente en el modelo representa una entidad individual con comportamientos y características propias que interactúa con otros agentes y el entorno. (Narváez et al., 2016)

Los modelos basados en agentes (MBA) representan una nueva generación de métodos computacionales diseñados para modelar sistemas complejos y simular su evolución dinámica a lo largo del tiempo. Los agentes inteligentes que conforman estos modelos poseen características específicas que les permiten desempeñar funciones avanzadas (Rodríguez Z & Roggero, 2015). Son autónomos, lo que significa que pueden operar sin intervención humana, y tienen la capacidad de interactuar con su entorno, detectar cambios y actuar en consecuencia. Además, pueden aprender y modificar su comportamiento con base en la información que reciben, lo que les permite mejorar su desempeño a lo largo del tiempo. También son proactivos, capaces de tomar las medidas necesarias para alcanzar sus objetivos de manera efectiva. Por último, poseen una dimensión social, ya que pueden interactuar y coordinarse con otros agentes dentro del sistema, lo que contribuye a la optimización y eficiencia del modelo en distintos escenarios.

2.3.5 Dinámica de sistemas

La Dinámica de Sistemas es una metodología que se utiliza para comprender el comportamiento de sistemas complejos a lo largo del tiempo mediante la construcción de modelos de simulación. Esta disciplina fue desarrollada por Jay W. Forrester en la década de 1950 y se basa en la observación de los sistemas en su totalidad, analizando las relaciones entre sus partes constitutivas. Los sistemas se representan mediante variables acumulativas (stocks) y flujos que aumentan o disminuyen estos stocks. Los stocks representan los estados del sistema en un momento dado, mientras que los flujos son las tasas de cambio de estos estados. (Sterman, 2000).

2.4 Conclusión de capitulo

El análisis teórico desarrollado en este capítulo permite establecer que el cambio climático no solo es un fenómeno ambiental, también es un factor estructural que redefine la seguridad alimentaria, la estabilidad económica y la resiliencia de los sistemas productivos. México y, en particular, su sector agropecuario, enfrentan un escenario de alta vulnerabilidad que obliga a replantear los enfoques tradicionales de producción y gestión de recursos. El capítulo no solo consolida el marco teórico que sustenta la investigación, sino que también plantea una visión prospectiva: comprender la interacción entre factores climáticos, ambientales y socioeconómicos resulta esencial para el diseño de modelos innovadores de vulnerabilidad. Estos modelos, apoyados en metodologías computacionales avanzadas, representan una vía estratégica para responder a los desafíos que impone el cambio climático y garantizar la sostenibilidad del sector agropecuario en el largo plazo.

Capítulo III. Metodología

La metodología presentada es presentada en (A. E. Badillo, 2021), la metodología consta en total de 4 etapas, diagnostico, que abarca la definición del objeto de estudio, la creación de un perfil de cambio climático, determinación de los factores que causan desastres, y la construcción de indicadores de vulnerabilidad. En esta etapa se permite crear un perfil de cambio climático.

La segunda fase es la creación del modelo de vulnerabilidad consiste en 3 subetapas que inician con la caracterización de las variables utilizando técnicas de dinámica de sistemas, posteriormente se desarrolla los agentes de indicadores de vulnerabilidad y se obtienen submodelos dinámicos.

La tercera etapa del modelo propuesto es un modelo de cultivo, subdividido en el desarrollo del agente de vulnerabilidad de cultivo, obtención de submodelos difusos, obtención de vulnerabilidad del sistema. Además, la obtención del agente reactivo.

Por último, la metodología propone un modelo de riesgo, con ayuda de técnicas de inteligencia artificial, en específico tratamiento digital de imágenes que se lleva a cabo de la siguiente manera, la selección de las variables de interés, recolección de imágenes, preprocesamiento de imágenes, proceso de detección de imágenes y aplicación de Deep learning (Desarrollo de red neuronal convolucional). Figura 6

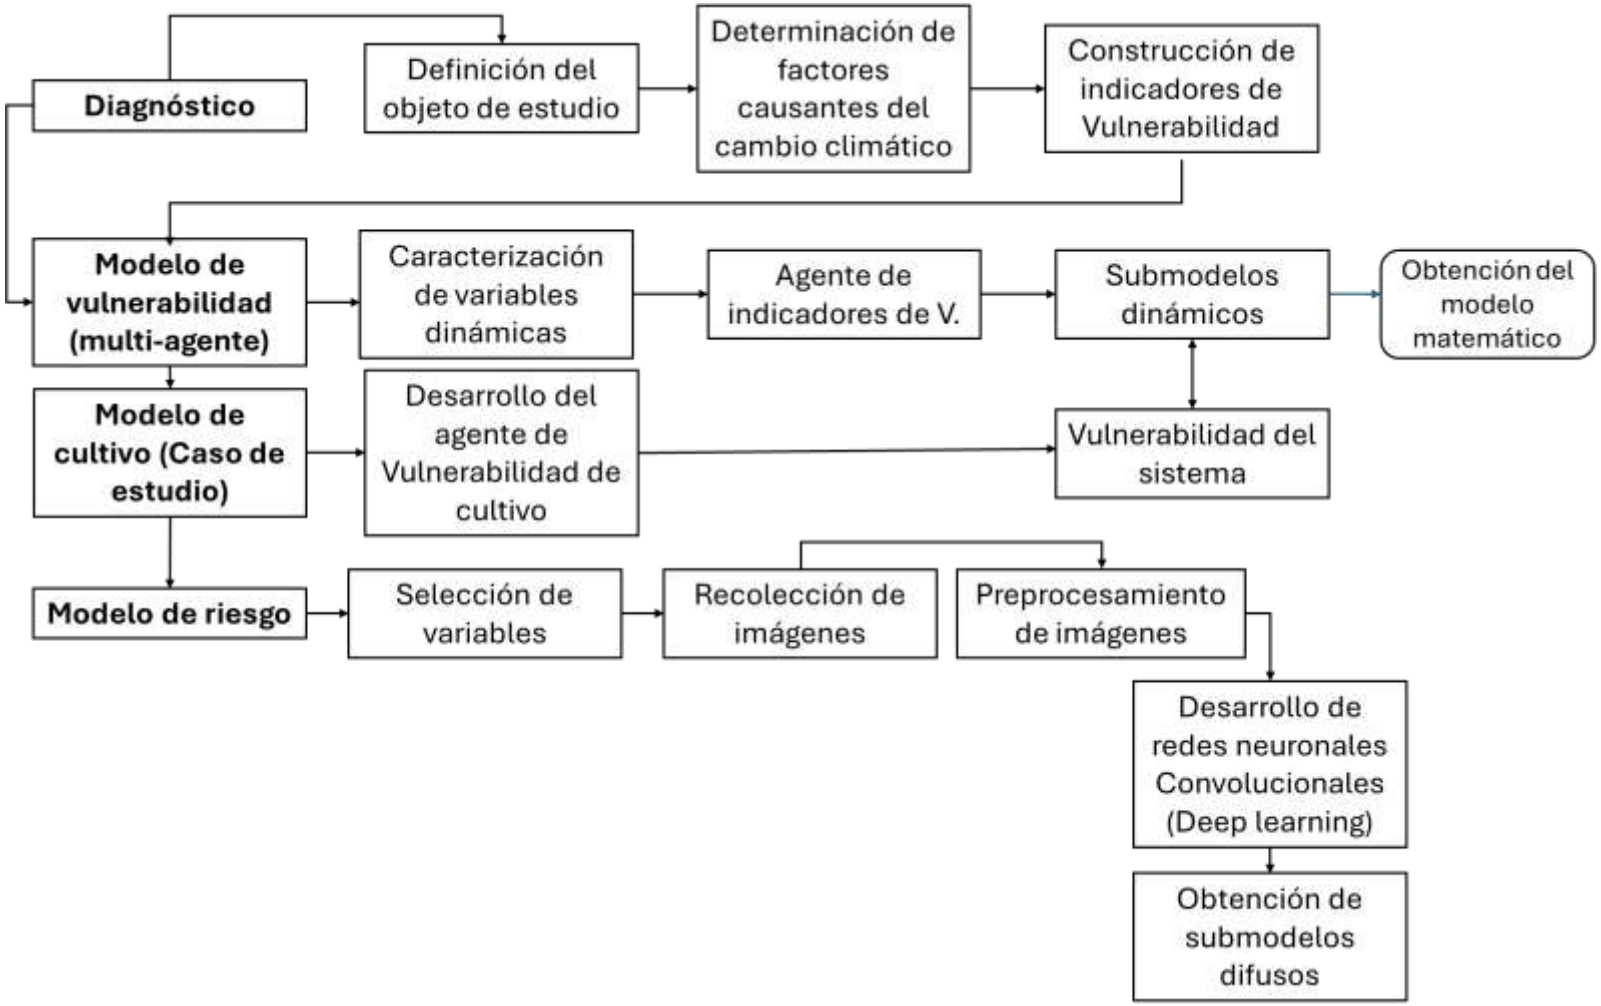


Figura 6 Metodología general (A. E. Badillo, 2021)

3.1 Diagnóstico

Según lo mencionado en la metodología el diagnostico delimita el objeto de esta investigación, se crea un perfil de cambio climático que permita detectar factores causantes de desastres, lo cual aumenta la vulnerabilidad del sector agropecuario.

En esta investigación se busca estimar la vulnerabilidad y riesgo en el sector agropecuario en México a causa del cambio climático.

a. Definir objeto de estudio: La evaluación del caso de estudio consiste en la obtención y proyección de las variables más representativas que permitan modelar indicadores de vulnerabilidad en términos de sensibilidad, exposición y capacidad adaptativa que permitan desarrollar un modelo de vulnerabilidad y riesgo agrícola mediante técnicas de IA. Se evalúa la producción agropecuaria comprendiendo el ganado y caña de azúcar en la región de lerdo de tejada Veracruz.

b. Crear un perfil de cambio climático; en donde se determinan los factores climatológicos que provocan un riesgo y son causantes impactos en contra. La información y datos recolectados se utiliza para la creación de un perfil generando escenarios de impactos ambientes, socioeconómicos, riesgos históricos, población, sectores vulnerables, medidas de adaptación, etc.

c. Determinar factores que causan desastres: Los indicadores de vulnerabilidad proporcionaran la información necesaria para generar modelos que engloben todo el sistema para la evaluación de la vulnerabilidad.

d. Construir indicadores de vulnerabilidad: Con base a la construcción de indicadores de vulnerabilidad, representa la ponderación del indicador con respecto a la influencia que tiene en el sistema.

3.1.1 Factores causantes de desastres.

En México el crecimiento de la población, aumento de contaminación y eventos meteorológicos como “el niño” y “la niña” han causado cambios significativos en el comportamiento de las lluvias y las temperaturas, esto incrementa significativamente los eventos de sequias más prolongadas y ocurrentes, así como tormentas ciclones huracanes, etc., poniendo en riesgo eminente las actividades agropecuarias, los cambios en los patrones

de comportamiento en el clima aumentan la vulnerabilidad en la producción agropecuaria aumentando el riesgo de perdidas por condiciones desfavorables o aumentando el desarrollo de plagas y enfermedades en el ganado y el cultivo agrícola.

3.1.2 Características de los factores.

Según el panel intergubernamental de expertos en cambio climático se pueden establecer 3 clasificaciones para los indicadores de vulnerabilidad

- Indicadores de exposición
- Indicadores de sensibilidad
- Indicadores de adaptación

Los indicadores de vulnerabilidad evalúan impactos que puede generar el cambio climático en la producción agropecuaria, lo cual resulta fundamental debido a que estos efectos pueden influir en el desempeño de los cultivos y en la gestión de los recursos utilizados en las actividades agrícolas y pecuarias. Por ello, la construcción de indicadores de vulnerabilidad se puede obtener a partir de bases de datos abiertos de diferentes organismos e instituciones, organismos gubernamentales internacionales, nacionales, la tabla 5 muestra la información de

Tabla 5 Fuentes de información consultadas

Base de datos Nacionales	Base de datos internacionales
Instituto Nacional de Estadística y Geografía (INEGI)	Banco Mundial de Datos (The World Bank)
Secretaria de Medio Ambiente y Recursos Naturales (SEMARNAT)	CLImate COMputing project (CLICOM)
Comisión Nacional del Agua (CONAGUA)	
Servicio de Información Agroalimentaria y Pesquera (SIAP)	
Secretaria de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación (SAGARPA)	
Instituto Nacional de Ecología y Cambio Climático (INECC)	
Consejo Nacional de Población (CONAPO)	
Encuesta Nacional Agrícola 2012 - 2022 (ENA)	
Servicio Meteorológico Nacional (SMN)	
Atlas Nacional de Riesgos	
Centro Nacional para la Prevención de Desastres (CENAPRED)	
Comisión Nacional Forestal (CONAFOR)	
Instituto Nacional de Ecología (INE)	
Sistema de Información Agroalimentaria de Consulta (SIACON)	
Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP)	

3.1.3 Clasificación de los indicadores de vulnerabilidad

Las variables correspondientes a los indicadores de exposición que se obtuvieron fueron; Las variables de Temperatura (C°) y Precipitación (mm) se obtuvieron mediante datos observados anualmente. Para las variables de Sequía e Incendios forestales se basan en valores observados del número de eventos declarados como un estado de emergencia y/o como un desastre natural.

El Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP) se encarga de emitir los dictámenes técnicos para la validación de desastres naturales tales como ciclones, granizadas, inundaciones severas, lluvias torrenciales, heladas, huracanes, deslaves y sequías atípicas. Se basa en el análisis de registros meteorológicos y en la interpretación agronómica del grado de afectación ocasionado por dichos fenómenos. En este contexto, la Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación (SAGARPA) ha designado al INIFAP como la autoridad competente para la elaboración de estos dictámenes.

La variable “Superficie afectada por incendios forestales” señala el número total de hectáreas donde ocurrieron pérdidas totales y/o parciales de los cultivos ocasionados por los diferentes incendios forestales.

La variable de “Gases de Efecto Invernadero” se expresa en porcentaje de Gases de Efecto Invernadero emitidos en la atmosfera en un periodo anual.

En la tabla 6 se muestran enumeradas las variables mencionadas, así mismo la relación entre estas y la vulnerabilidad, también la fuente de donde se recopilo la información y el periodo en el que fue captada.

Tabla 6 Indicadores de exposición

	Indicador	Descripción	Periodo	Relación ante Vulnerabilidad	Fuente
1	Temperatura	Temperatura histórica en México, en °C	1991-2022	Temp ↑ → Vul ↑	The World Bank
2	Precipitación	Precipitación histórica en México, en mm	2000-2022	Pp ↑ → Vul ↑	CONAGUA, SEMARNAT, SMN
3	Sequía	Eventos con falta de lluvias durante un período prolongado de tiempo produciendo sequedad en los campos agrícolas y escasez de agua	2000-2016	Sequía ↑ → Vul ↑	CENAPRED, INIFAP
4	Sismo	Eventos con declaración de "Riesgo y/o Desastre" por sismos mayores a 6.9° Ritcher	2000-2016	Sismo ↑ → Vul ↑	CENAPRED, SSN
5	Incendios forestales	Número de incendios forestales	1991-2018	IncFor ↑ → Vul ↑	CONAFOR
6	Superficie afectada por incendios forestales	Superficie agrícola afectada por incendios forestales, en Ha	1991-2018	Sup.IncFor ↑ → Vul↑	CONAFOR
7	Emisiones GEI	Inventario Nacional de Gases y Compuestos de Efecto Invernadero en agricultura, silvicultura y otros usos de la tierra, en porcentaje.	1990-2022	GEI ↑ → Vul ↑	The World Bank, INECC

3.1.4 Indicadores de sensibilidad

La variable “Área agrícola disponible” se refiere a la proporción existente entre la superficie de tierra cultivable, los cultivos y los pastos permanentes. Las tierras arables comprenden tanto las destinadas a cultivos como las praderas temporales utilizadas para pasto o corte de césped, incluyendo además huertas comerciales, huertos familiares y tierras en barbecho de manera temporal. Por su parte, las tierras de cultivo permanente corresponden a aquellas superficies utilizadas de forma continua en el tiempo, sin requerir necesariamente una siembra al finalizar cada ciclo de cosecha

Las variables climáticas de “Temperatura media mensual” (°C) y “Precipitación media mensual” (mm) representan promedios nacionales obtenidos a partir de registros meteorológicos distribuidos en el territorio durante cada mes del año. Estas variables son fundamentales para caracterizar las condiciones climáticas a lo largo del tiempo. Por su parte, la variable “Evapotranspiración” hace referencia al proceso combinado de evaporación del agua desde el suelo y otras superficies, junto con la transpiración del agua a través de las plantas, lo que determina la cantidad de agua que regresa a la atmósfera en forma de vapor.

“Disponibilidad de agua en el sector agropecuario” se refiere al volumen total de agua concesionada para uso agropecuario, expresado en hectómetros cúbicos (hm^3). Este volumen incluye los recursos hídricos asignados a distintas regiones hidrológico-administrativas del país, tales como la Península de Baja California, Península de Yucatán, Noreste, Pacífico Norte, Pacífico Sur, Balsas, Río Bravo, Cuencas Centrales del Norte, Lerma-Santiago-Pacífico, Golfo Norte y Centro, Frontera Sur y Aguas del Valle de México. Esta variable resulta esencial para evaluar la presión sobre los recursos hídricos en zonas agrícolas y su sostenibilidad frente a escenarios de cambio climático.

La “Superficie agrícola (Riego-Temporal)” hace referencia a la extensión de tierras las cuales dependen del tipo de riego empleado para el desarrollo y crecimiento de cultivos, es decir, si emplea un sistema de riego o si este depende de la lluvia o precipitaciones de la zona.

La variable “Origen del agua” hace referencia al origen del agua empleada para riego, es decir, si esta proviene de un pozo profundo, bordo, pozo a cielo abierto, rio, manantial o presa. La variable “Sistema de irrigación” corresponde a los riegos por gravedad, canales recubiertos o revestidos, tuberías de compuerta, microaspersión, aspersión o goteo.

La variable “Tipo de agua” hace referencia al agua usada para los cultivos, desde agua negra, agua tratada, agua blanca o agua salubre. “Superficie Sembrada / Cosechada” es representada en unidades de hectáreas para el cultivo.

La tabla 7 enlista y describe brevemente las variables, así mismo muestra la relación ante la vulnerabilidad si aumenta o disminuye y el periodo de recolección de información además de la fuente de obtención.

Tabla 7 Lista de variables y su relación con vulnerabilidad

	Indicador	Descripción	Periodo	Relación ante Vulnerabilidad	Fuente
1	Área agrícola	Tierra agrícola cultivable que incluye cultivos y pastos, en porcentaje	1961-2020	AreAgr ↑ → Vul ↓	Bank The World Bank, SAGARPA
2	Precipitación media mensual	Temperatura media en México, en °C	1991-2022	Ppmed ↑ → Vul ↑	The World Bank, SMN
3	Temperatura media mensual	Precipitación media en México, en mm	1991-2022	Tmed ↑ → Vul ↑	The World Bank, SMN
	Evapotranspiración	Evapotranspiración media anual, en km_3/año	1998-2015	EvT ↑ → Vul ↑	CONAGUA, SEMARNAT
4	Eficiencia del agua en el sector agrícola	Eficiencia en el uso del agua en el sector agrícola de riego, en kg/m^3	1994-2020	EfcAgua ↑ → Vul ↓	CONAGUA, SEMARNAT
5	Disponibilidad de agua en agricultura	Volumen concesionado por uso consuntivo agrupado, en hm^3	2001-2020	H_2OAgr ↑ → Vul ↓	CONAGUA, SAGARPA
6	Superficie agrícola (Riego y/o Temporal)	Superficie agrícola con disponibilidad de agua para reproducción de sus cultivos (riego y/o temporal), en Ha	2007-2019	Riego_Temporal ↑ → Vul ↓	INEGI, ENA, SEMARNAT
7	Origen de agua	Superficie agrícola de riego según el origen de agua, en porcentaje	2007-2019	OrigenH_2O ↑ → Vul ↓	INEGI, ENA, SEMARNAT
8	Sistemas de irrigación	Producción con superficie agrícola de riego y tipo de canales por sistema de irrigación utilizado, en porcentaje	2007-2019	Irrigación ↑ → Vul ↓	INEGI, ENA, SEMARNAT
9	Tipo de agua	Tipo de agua utilizada en agricultura (negra, tratada, blanca, salobre), en porcentaje	2007-2019	Tipoh_2O ↑ → Vul ↓	INEGI, ENA
10	Superficie Sembrada/Cosechada (2)	Superficie agrícola sembrada y cosechada, en Ha	1980-2020	SupSembrada ↑ → Vul ↓ SupCosechada ↑ → Vul ↓	SAGARPA, SIACON, SIAP

3.1.5 indicadores de vulnerabilidad y obtención de índice de vulnerabilidad

Se construyen indicadores en base a la clasificación de los factores de vulnerabilidad. Los indicadores normalizados permiten obtener el índice de vulnerabilidad. Los indicadores se normalizan en un rango correspondiente a [0, 1] para ser estandarizados, donde, a mayor sea el resultado del indicador, mayor será la vulnerabilidad. La normalización se obtiene mediante la siguiente ecuación.

Ecuación 1

$$X_j = \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

Donde:

- X_j, corresponde al valor normalizado de los valores de la variable $x_{i.}$
- x_{min} y x_{max} son los valores mínimos y máximos del conjunto de datos $x_{i.}$

Los indicadores normalizados para cada grupo de indicadores: Sensibilidad (S), Exposición (E) y Capacidad Adaptativa (CA) se estimaron mediante la siguiente expresión:

Ecuación 2

$$E, S, CA = \sum_{j=1}^{n} P_i X_j$$

Donde:

- P_j, corresponde al factor de ponderación.
- X_j corresponde al valor normalizado del indicador j para estimar los componentes de vulnerabilidad.

El índice de vulnerabilidad se situa entre [0,1]; por lo que mientras el índice se acerque a cero la vulnerabilidad será mínima y, por otro lado, si el valor se acerca a uno la vulnerabilidad aumenta.

Ecuación 3

$$P_i = \frac{c}{\frac{1}{\sqrt{var_i(X_{i,j})}}}$$

Donde:

- P_j, es el peso para el indicador normalizado i.
- c es la constante de normalización estimada como la suma total de las inversas de las desviaciones estándar, de los indicadores seleccionados en componentes de vulnerabilidad.

La constante de normalización se obtuvo mediante la ecuación:

Ecuación 4

$$c = \sum_{i=1}^{n} \frac{1}{\sqrt{var_i(X_{i,j})}}$$

3.2 Desarrollo de modelo de vulnerabilidad, sistema multi-agente

Para poder analizar el la vulnerabilidad y riesgo agropecuario se desarrolla un modelo basado en agentes inteligentes, denominados agentes indicadores de vulnerabilidad, se divide en tres sistemas de vulnerabilidad, rendimiento de tierras agrícolas, eficiencia del recurso hídrico, vulnerabilidad climática.

Cada etapa se representa por un agente bajo el enfoque ABM, que en conjunto representa un sistema multi-agente donde estos son entidades que muestras autonomía y proactividad (agentes activos). La tabla 8 describe los tipos de agentes empleado y la función principal de cada uno.

Tabla 8 Tipos de agentes y sus funciones

Agente	Rol	Actividades
Indicadores de vulnerabilidad	Activo	Modela el comportamiento de las redes para llevar la información al centro de decisión.
Vulnerabilidad de cultivo	Decisión	Se encarga de la toma de decisiones al modificar las prácticas agrícolas para minimizar la vulnerabilidad en el cultivo.
Prácticas agrícolas	Reactivo	Proporciona un estímulo-respuesta ante eventos no esperados en el sistema.
Vulnerabilidad total del sistema	Activo	Modela la información obtenida por los agentes para determinar el nivel de vulnerabilidad en el sistema.
Redes de información (población de agentes)	Pasivo	Almacenar información a través de bases de datos. Distribuir información hacia los agentes a través de redes.

3.2.1 Aplicación de dinámica de sistemas en Anylogic

El enfoque de la dinámica de sistemas se basa en la idea de que el comportamiento de un sistema es el resultado de su estructura interna. Los elementos clave de un sistema incluyen variables de estado, flujos, retroalimentaciones y demoras temporales. A través de la modelización de estos elementos, se pueden identificar las relaciones causales y los bucles de retroalimentación que dictan cómo cambia el sistema con el tiempo. Por otro lado, El análisis sistémico es un enfoque metodológico utilizado para comprender la complejidad y las interrelaciones dentro de un sistema. Este tipo de análisis se centra en estudiar cómo los componentes de un sistema interactúan entre sí y con su entorno, en lugar de analizar cada componente de forma aislada.

3.2.1.1 Conceptualización

Identificar las variables principales de aspectos ambientales que describen en los indicadores de vulnerabilidad sentaran las bases para la construcción del diagrama causal, ordenando y sistematizando la información (Figura 7).

"Rendimiento de tierras agrícolas" determina la disponibilidad de tierras correspondiente a la agricultura y la vulnerabilidad del producto de sobreexplotación con respecto al suelo agrícola o la degradación.

La red "Eficiencia de recursos hídricos en la agricultura" determina la vulnerabilidad del uso del agua respecto a actividades del tipo agropecuarias.

"Vulnerabilidad climática" describe la cantidad de dióxido de carbono emitido por la agricultura, la ganadería y los eventos de incendios forestales ocurridos, aportando a la emisión de gases de efecto invernadero causantes del cambio climático.

Las variables que alimentan al agente de indicadores de vulnerabilidad están modeladas mediante distribuciones de probabilidad que describen datos históricos del periodo 2001- 2022. (CENAPRED; CONAFOR; CONAGUA; ENA; INECC; INEGI; INIFAP; SAGARPA;SEMARNAT; SIAP; SMN; The World Bank).

La Tabla 9 y Tabla 10 describen las principales variables empleadas en los modelos que constituyen el agente de indicadores de vulnerabilidad.

Tabla 9 Variables indicadores de vulnerabilidad (A. E. Badillo, 2021)

Variable	Descripción	Unidad
Terreno agrícola	Extensión de tierras destinadas a la agricultura	Ha
Extensión de tierras	Extensión de tierra en territorio mexicano	Ha
Superficie afectada por incendios forestales	Extensión de tierra afectada por incendios forestales	Ha
Degradación física	Degradación del suelo originada por aspectos físicos: Compactación (Fc), Pérdida de la función y productividad (Fu), Anegamineto (Fa), Disminución de la disponibilidad de agua (Fd), Encrostamineto y sellamiento (Fe)	Ha
Degradación química	Degradación de suelo originada por aspectos químicos: Reducción de fertilidad y contenido de materia orgánica (Qd), Polución (Qp), Salinización y/o alcalinización (Qs), Eurotrificación (Qe)	Ha
Sobrepastoreo	Superficie agrícola afectada por pastoreo intensivo durante un periodo prolongado	Ha
Erosión eólica	Desgaste de la superficie debido a la acción del viento	Ha
Erosión hídrica	Segregación y sedimentación de partículas de agua en el suelo a causa de lluvia o escurrimiento superficial	Ha
Superficie incultivable	Superficie no apta para actividades agrícolas debido a degradación severa o extrema	Ha
Superficie sembrada/cosechada	Superficie agrícola sembrada y cosechada	Ha
Tierras para cultivar	Extensión de tierras disponibles para cultivo	Ha
Tierras de cultivo	Extensión de tierras permanentes para cultivo	Ha
Rendimiento de tierras agrícolas	Rendimiento del área agrícola por hectárea	Kg/Ha
Unidad de producción agrícola	Unidad estadística agropecuaria para medir la producción agrícola en un área determinada	m^2

Tabla 10 Variables indicadores de vulnerabilidad parte 2 (A. E. Badillo, 2021)

Variable	Descripción	Unidad
INPC	Índice Nacional de Precios al Consumidor, indicador para estimar la evolución de precios de bienes y servicios en México.	-
Origen de agua	Origen de agua según su tipo de fuente: pozo, río, manantial, presa, pozo de agua a cielo abierto, etc.	Hm^3
Suministro de agua	Abastecimiento de agua subterráneo y superficial	Hm^3
Disponibilidad nacional de agua	Volumen de agua disponible, el cual es distribuido a diversos sectores	Hm^3
Tipos de agua	Volumen de agua según su clasificación: aguas negras, aguas de tratamiento residual, agua salobre, etc.	Hm^3
Eficiencia de recursos hídricos	Eficiencia de los recursos hídricos destinados para el desarrollo de actividades agrícolas	Kg/m^3
GEI agrícolas	Gases de efecto invernadero (GEI) generados por el desarrollo de actividades agrícolas	Gt CO_2eq
Emisiones de CO_2	Emisiones de dióxido de carbono, el cual es un gas incoloro, denso y poco reactivo que forma parte de la capa de la atmósfera más cerca de la tierra	Gt CO_2eq
Emisiones de CH_4	Emisiones de metano producidas por la descomposición de la materia orgánica.	Gt CO_2eq
Emisiones de N_2O	Las emisiones de óxido nitroso son el principal contaminante de la capa de ozono	Gt CO_2eq
Emisiones de HFC	Los hidrofluorocarbonos es la tercera generación de gases refrigerantes	Gt CO_2eq
Emisiones de PFC	Los perfluororcarburos son compuestos sintéticos que contienen átomo de flúor y carbono. Son gases incoloros no flamables a temperatura ambiente	Gt CO_2eq
Emisiones de SF_6	El hexafluoruro de azufre es un compuesto inorgánico que en condiciones normales de presión y temperatura es un gas no tóxico y no flamable. El SF6 es cinco veces más pesado que el aire.	Gt CO_2eq

Ton/Ha: toneladas por hectárea m^2: metros cuadrados MUS$:Millones de dólares Hm^3: hectómetros cúbicos Kg/m^3: kilogramos por metro cúbico Gt CO_2eq: gigatoneladas de dióxido de carbono equivalente.



Figura 7 Diagrama causal del modelo de vulnerabilidad

3.2.1.2 Implementación

El modelo de agente de indicadores de vulnerabilidad se desarrolló en el software Anylogic® en la librería de dinámica de sistemas simulándose durante un periodo de doce ciclos.

Las figuras 8-10 muestran el diagrama de flujo para cada red del modelo de vulnerabilidad para el sector agropecuario.

Rendimiento de tierras agrícolas (Figura 8) está determinado por los principales tipos de degradación referente al suelo y también dependiendo del grado de degradación se puede estimar la superficie incultivable.

La superficie agrícola disponible estima el área potencialmente cultivable evitando aquellas superficies que han sido afectadas de forma severa y extrema, para así, poder determinar el rendimiento y la vulnerabilidad de la superficie agrícola.

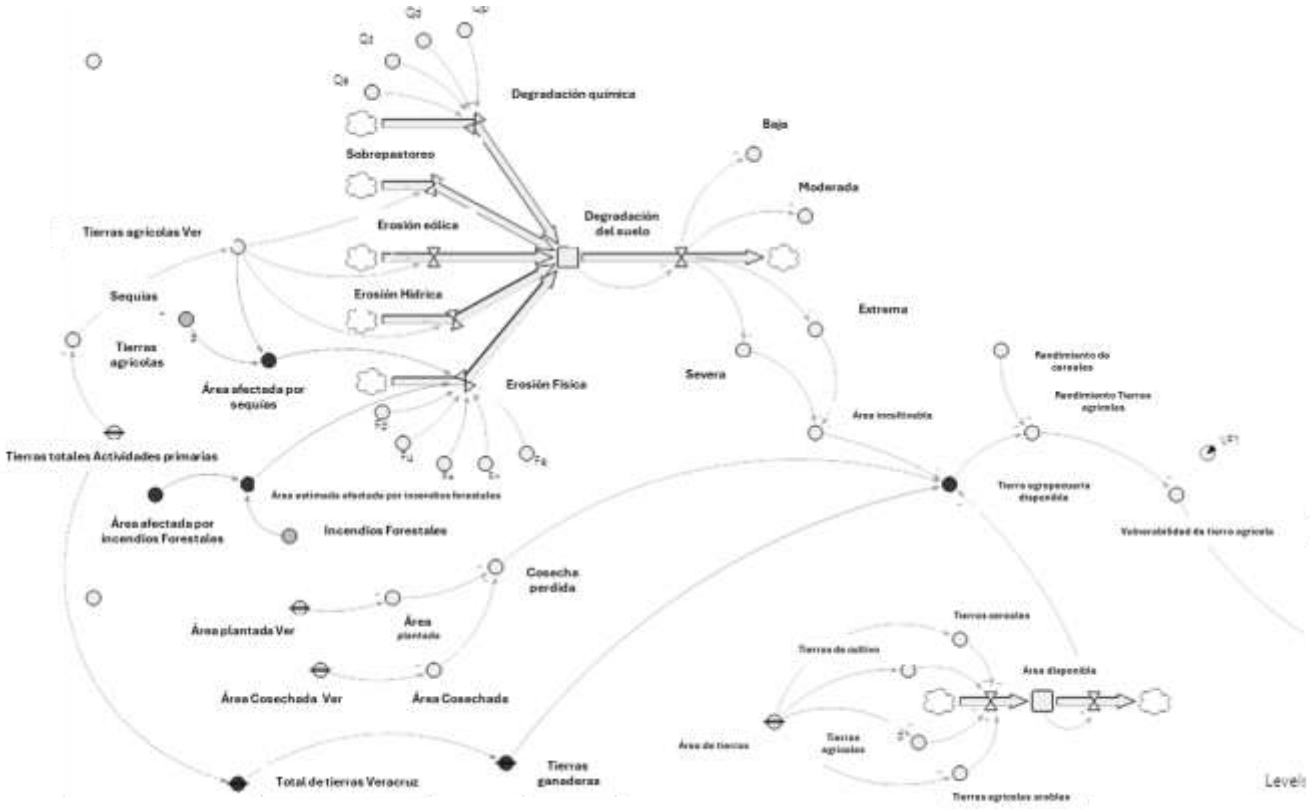


Figura 8 Rendimiento de tierras agrícolas

Eficiencia de los recursos hídricos (Figura 9) se obtiene mediante el cálculo correspondiente a la cantidad de agua disponible para el sector agropecuario tanto de fuentes subterráneas como superficiales y si dicha superficie agrícola emplea algún sistema de irrigación.

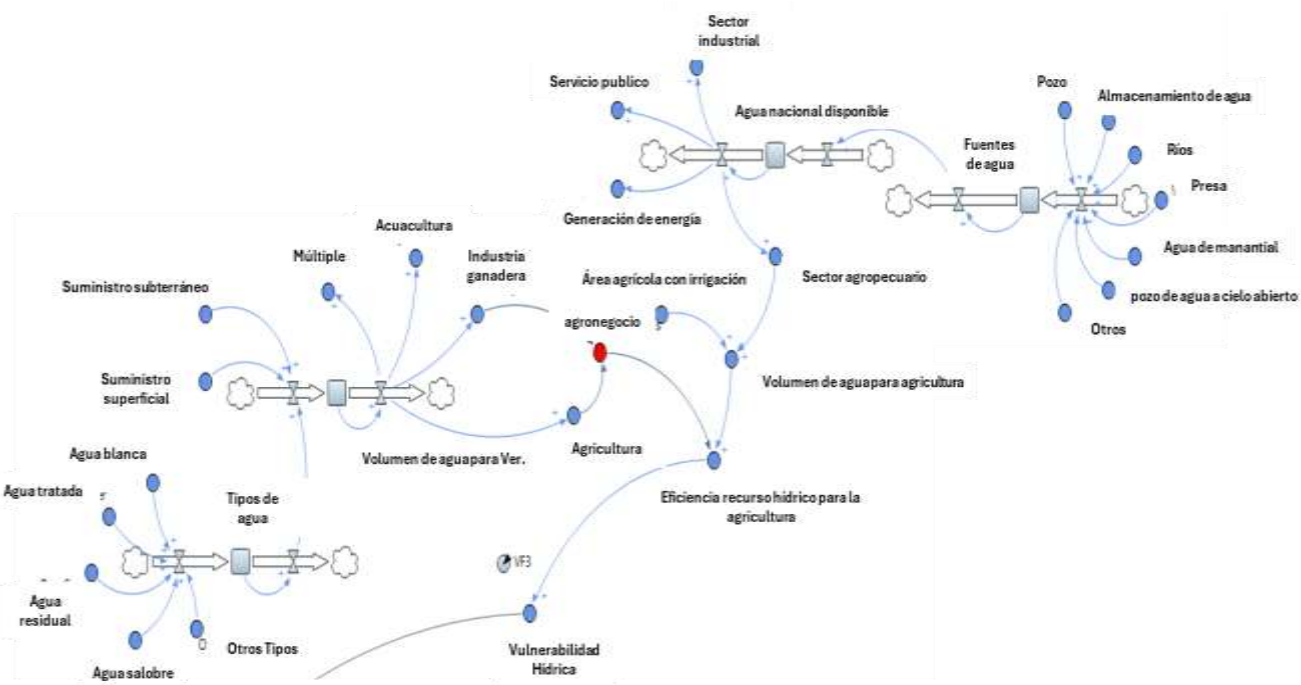


Figura 9 Eficiencia de los recursos hídricos para el sector agropecuario

La red Vulnerabilidad climática (Figura 10) se obtiene de la suma de las emisiones de gases de efecto invernadero que son emitidos por tres grupos, el sector agrícola que emite principalmente contaminantes a causa de los fertilizantes; sector ganadero, que comprende aves (pollos), ganado porcino y ganado bovino, las principales emisiones en ganadería es por el manejo de estiércol y fermentación entérica; la tercera emisión son aquellas provocadas por la ocurrencia de incendios forestales y esta comprende dióxido de carbono, metano y PM2.5 o carbono negro. Las emisiones aquí enlistadas son los principales causantes del cambio climático.

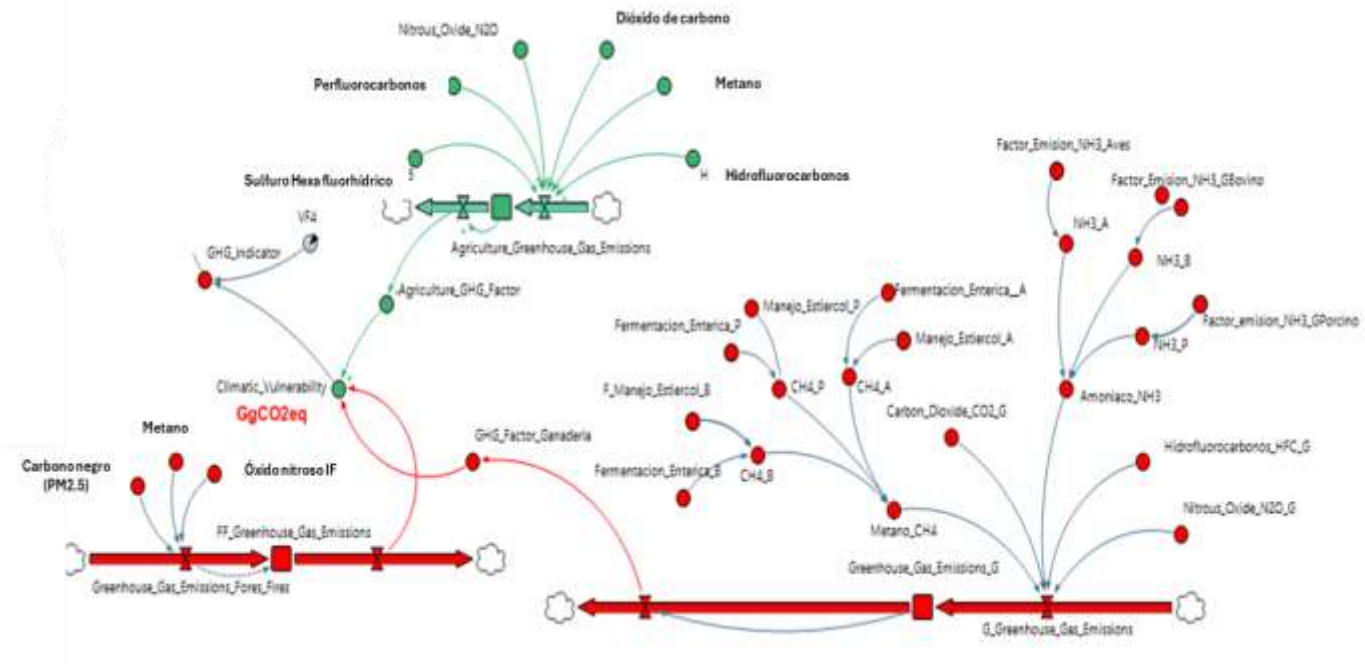


Figura 10 Diagrama de flujo Vulnerabilidad climática

3.2.1.3 formulación

Para la formulación del modelo matemático se realizaron predicciones en las variables de interés de cada subsistema. Para evaluar el comportamiento de cada subsistema se desarrollaron series de tiempo que simulen el comportamiento de las variables que integran los subsistemas. La Tabla 11 muestra el tipo de tendencia para cada serie temporal analizada y el modelo matemático utilizado cuando $t > 0$ para la red de vulnerabilidad de emisiones de gases de efecto invernadero del sector agropecuario.

Tabla 11 formulación matemática para series de tiempo del modelo matemático

Time series	Kind of trend	Mathematical model
Methane CH_4 Fores Fires	Upward	$f(t) = 103e^{-103\,t}$
Black Carbon	Upward	$f(t;\mu,\sigma) = \frac{1}{(t-0.594)\sqrt{2\pi(0.473)^2}}\exp\left(\frac{-[\ln(t-0.594)-0.13]^2}{2(0.473)^2}\right)$
Nitrous Oxide NO_2 Fores Fires	Upward	$f(t) = 138e^{-138\,t}$
Enteric fermentation B	No trend	0.000151443
Manure management B	No trend	0.00000812
Cattle heads (B)	No trend	24563565
Methane CH_4 Cattle heads	Upward	$\sum[(Enteric\ fermentaion\ B * Cattle\ heads) + (Manure\ management\ B * Cattle\ heads)]$
Enteric fermentation P	No trend	0.00000105
Manure management P	No trend	0.0000006944
Pig heads (P)	No trend	16021318
Methane CH_4 Pig heads	Upward	$\sum[(Enteric\ fermentaion\ P * Pig\ heads) + (Manure\ management\ P * Pig\ heads)]$
Enteric fermentation A	No trend	0.00001
Manure management A	No trend	0.0000000159
Poultry heads (A)	No trend	522409099
Methane CH_4 Poultry heads	Upward	$\sum[(Enteric\ fermentaion\ A * Poultry\ heads) + (Manure\ management\ A * Poultry\ heads)]$
Ammonia NH_3 Poultry heads	Upward	$1.9\ E^{-7} * Pultry\ heads$
Ammonia NH_3 Cattle heads	Upward	$1.51762\ E^{-4} * Cattle\ heads$
Ammonia NH_3 Pig heads	Upward	$4.05\ E^{-6} * Pig\ heads$
Ammonia NH_3 Total	Upward	$\sum(NH_3\ Pultry\ heads + NH_3 Cattle\ heads + NH_3 Pig\ heads)$
Methane CH_4 Total	Upward	$\sum(CH_4\ Pultry\ heads + CH_4 Cattle\ heads + CH_4 Pig\ heads)$
Carbon Dioxide CO_2 Agriculture	Upward	$f(t) = 13438e^{-13438t}$
Methane CH_4 Agriculture	Upward	$f(t) = 64986e^{-64986t}$
Nitrous Oxide NO_2 Agriculture	Upward	$f(t) = 32669e^{-32669t}$

3.3 Modelo agropecuario caso de estudio

La clasificación de las regiones geográficas de México dependiendo de su extensión territorial y diferencias climáticas, la elección del caso de estudio se realiza de acuerdo con esta clasificación geográfica del territorio mexicano, la tabla 12 muestra las regiones de México y que estados la comprenden.

Tabla 12 Clasificación Geográfica

#	Región	Estados
1	Noroeste	Baja California, Baja California Sur, Sonora, Sinaloa y Nayarit
2	Noreste	Chihuahua, Coahuila, Durango, Nuevo León, Tamaulipas y Zacatecas.
3	Centro Occidente	Aguascalientes, Colima, Guanajuato, Jalisco, Michoacán, Querétaro y San Luis Potosí
4	Centro	Ciudad de México, Estado de México, Guerrero, Hidalgo, Morelos, Puebla y Tlaxcala
5	Sur-Sureste	Campeche, Chiapas, Oaxaca, Quintana Roo, Tabasco, Veracruz y Yucatán

La (Secretaría de Agricultura y Desarrollo Rural, 2021) informa que los principales productos agropecuarios para cada región son los siguientes: Tabla 13

Tabla 13 Producción Agrícola y Pecuaria por región en Ton

Region	Produccion agrícola Ton	Produccion Pecuaria Ton	Principal producto Producido Agricola, Pecuario
1	32,698,813	1,610,279	Maíz grano, Carne de Bovino
2	50,237,983	5,383,233	Maíz grano, Carne de Bovino
3	75,086,363.00	9,568,188	Aguacate, Carne de Ave
4	32,387,496.00	3,001,987	Maíz grano, Carne de Ave
5	72,054,283.00	3,492,675	Caña de Azúcar, Carne de Bovino

La región sur sureste en la cual se clasifica el estado de Veracruz produce principalmente caña de azúcar y ganado, representando un valor en mdp de $103,263 para la producción de caña de azúcar y $96,709 mdp para la producción de carne de ganado bovino

(A. E. Badillo, 2021) Muestra en su trabajo el valor de la producción de caña de azúcar del año 2001 al 2018, figura 11, así como la producción de caña de azúcar en toneladas, (en la figura 26 y tabla 15 respectivamente).

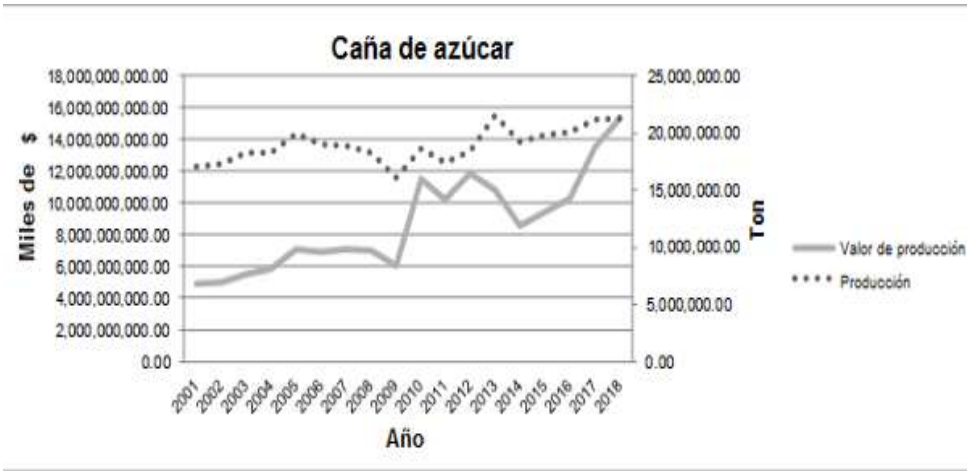


Figura 11 Valor de la producción de caña de azúcar (A. E. Badillo, 2021)

Por su parte, (D. Badillo, 2025) con estadísticas del Servicio de Información Agroalimentaria y Pesquera (SIAP), sistematizadas por el Grupo Consultor de Mercados Agrícolas (GCMA), afirma que, tan solo en el 2025, México importará el 20% de los productos pecuarios que requiere concretamente tendrá que comprar el 51% de la carne de cerdo y 20% del pollo que consumen los mexicanos en 2025. Figura 12

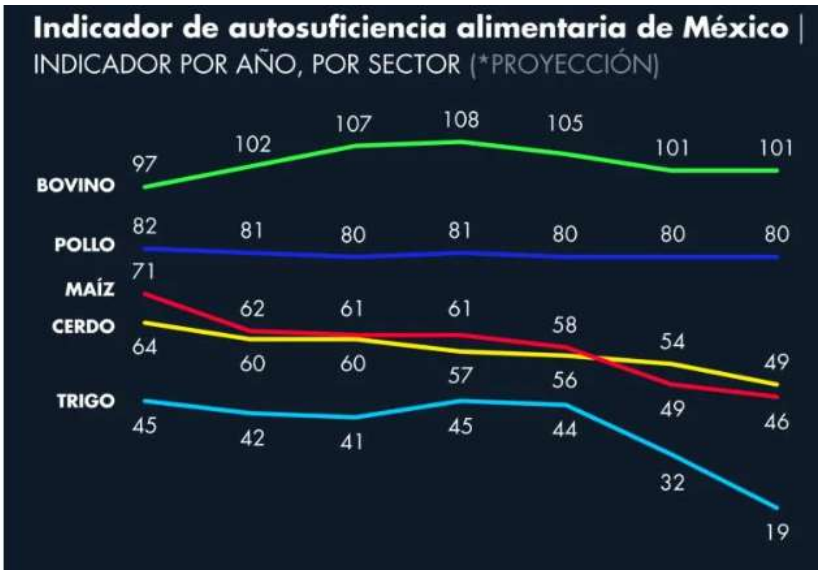


Figura 12 Indicador de autosuficiencia alimentaria de México (D. Badillo, 2025)

Dicho esto, el sector agropecuario en Veracruz representa vulnerabilidad ante los efectos del cambio climático, disminuyendo la calidad y el rendimiento de la cosecha de los productos y subproductos.

3.3.1 Aplicación de tratamiento de imágenes satelitales.

Los parámetros climatológicos desempeñan un papel relevante en la determinación de la vulnerabilidad del sector agropecuario, estos parámetros afectan directamente los procesos fisiológicos de los cultivos y los animales, además de la disponibilidad de recursos como el agua y la calidad y disponibilidad de suelos. Los factores que más influyen se encuentran la temperatura, precipitación, la humedad relativa, la radiación solar, los vientos y la ocurrencia de fenómenos extremos. Estos elementos pueden incrementar o reducir el grado de vulnerabilidad dependiendo de la magnitud de sus variaciones y de la capacidad de adaptación de los sistemas productivos.

El aumento de la temperatura es uno de los principales efectos asociados al cambio climático con implicaciones significativas en la producción agropecuaria. En la agricultura, temperaturas más elevadas pueden acelerar los ciclos de crecimiento de algunos cultivos reduciendo la calidad del producto final, al disminuir el contenido de compuestos como la sacarosa en el caso de la caña de azúcar (Lobell et al., 2008). Por su parte, en el ámbito pecuario, el incremento térmico provoca estrés calórico en los animales, lo que conlleva una disminución en la producción láctea y cárnica, así como una reducción en la tasa reproductiva (Nardone et al., 2010).

La precipitación, por su parte, representa un factor determinante en la productividad agropecuaria. La variabilidad en las lluvias ya sea por déficit o exceso, tiene consecuencias adversas. Las sequías reducen la disponibilidad de agua para el riego y para el consumo animal, lo cual afecta la productividad de los cultivos y la regeneración de los pastizales. Por otro lado, las lluvias intensas pueden ocasionar inundaciones, erosión del suelo y pérdida de nutrientes, afectando severamente la fertilidad de las tierras agrícolas(FAO, 2023)

3.3.1.1 Monitoreo

El servicio meteorológico nacional permite a través de animaciones satelitales monitorear eventos meteorológicos que podrían afectar los sistemas productivos agrícolas y pecuarios. La información contenida en la animación satelital del "Tope de Nubes" del Servicio Meteorológico Nacional (SMN) de México, se derivan del satélite GOES Este y constituye una herramienta estratégica para la vigilancia agroclimática del país. Esta animación permite observar en tiempo casi real la evolución de la cobertura nubosa y, específicamente, identificar la altura de las nubes, un parámetro estrechamente relacionado con la intensidad de los sistemas convectivos y la posibilidad de eventos extremos como lluvias intensas, tormentas o ciclones tropicales. Esta información es particularmente relevante para regiones productoras de caña de azúcar y zonas ganaderas

Los parámetros monitoreados en la animación proporcionada en el sistema meteorológico nacional son, humedad relativa, temperatura, velocidad de viento, presencia o ausencia de nubes que podrían ser indicador de lluvia o condiciones secas para el sector agropecuario. La figura 13 muestra la metodología para la aplicación del tratamiento digital de imágenes y la aplicación de lógica difusa para el modelo de riesgo agropecuario.

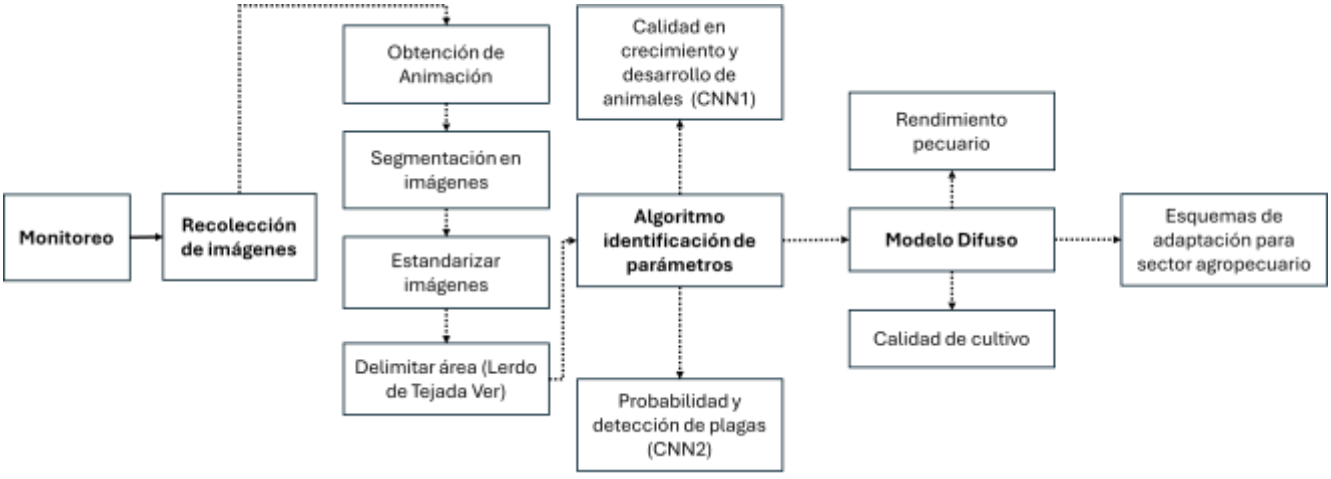


Figura 13 Metodología para la aplicación del procesamiento digital de imágenes

3.3.1.2 Recolección de imágenes

Del Servicio Meteorológico Nacional (SMN), específicamente al producto satelital denominado Tope de Nubes, con el fin de conformar una base de datos de imágenes atmosféricas que permiten caracterizar variables climáticas relevantes para el sector agropecuario. Dichas imágenes fueron obtenidas mediante un algoritmo implementado en Jupyter Notebook, el cual automatiza la descarga y almacenamiento sistemático, garantizando así un repositorio estandarizado y de uso consistente para los procesos posteriores de análisis y modelado.

El producto Tope de Nubes es ampliamente utilizado en el ámbito meteorológico debido a que permite inferir la temperatura del tope nuboso, lo que a su vez se relaciona con la altitud aproximada de las nubes y con fenómenos atmosféricos específicos. En este contexto, la escala cromática que acompaña a las imágenes constituye un elemento clave para la interpretación. Cada color representa un rango térmico asociado a distintos niveles de nubosidad y procesos meteorológicos, lo cual posibilita identificar desde formaciones nubosas de desarrollo limitado hasta sistemas convectivos de gran magnitud.

La Tabla 14 sintetiza esta correspondencia, mostrando de manera organizada la relación entre color, temperatura estimada, altura aproximada del tope nuboso y fenómenos atmosféricos típicamente vinculados, además, se describen también las etiquetas correspondientes que alimentaran los sistemas difusos para la determinación de riesgo en cada sector.

Las tonalidades que van del azul al verde indican nubes de altura baja a media con temperaturas relativamente cálidas, asociadas a estratos o altocúmulos sin mayor inestabilidad. En contraste, las gamas amarillo-naranja reflejan nubes más frías y elevadas, mientras que los tonos rojos o fucsias se corresponden con cimas nubosas extremadamente frías, propias de cumulonimbos y sistemas convectivos intensos que suelen estar relacionados con tormentas eléctricas, lluvias intensas y eventos extremos. De esta manera, el Tope de Nubes no solo funge como una fuente de datos climatológicos de alta resolución espacial y temporal, sino que

constituye también una herramienta de apoyo para correlacionar fenómenos atmosféricos con los riesgos que impactan directamente al sector agrícola y pecuario.

Tabla 14 Interpretación cromática del Tope de nubes

Color	Temperatura aproximada (°C)	Altura del tope nuboso	Interpretación meteorológica
Blanco	–65 °C o menor	Muy alto (≥ 15 km)	Cimas de nubes muy frías, asociadas a tormentas intensas, sistemas convectivos severos o huracanes.
Rojo intenso	–50 a –64 °C	Alto (12–15 km)	Cumulonimbos desarrollados, convección profunda, alta probabilidad de lluvias intensas y actividad eléctrica.
Amarillo	–30 a –49 °C	Medio-alto (8–12 km)	Nubes de gran extensión vertical, cúmulos y altostratos densos, posibles precipitaciones moderadas.
Verde claro	–10 a –29 °C	Medio (4–8 km)	Nubes medias, altocúmulos y estratocúmulos, condiciones generalmente estables o precipitaciones ligeras.
Azul	0 a –9 °C	Bajo (2–4 km)	Nubes bajas, estratos, nubosidad ligera sin desarrollo convectivo significativo.
Gris	> 0 °C	Muy bajo (< 2 km)	Superficie terrestre cálida o cielo despejado; ausencia de nubosidad significativa.

3.3.2 Entorno de trabajo

El flujo metodológico diseñado se desarrolla en el entorno de Anaconda, utilizando el lenguaje de programación Python en su versión gratuita. Esta elección responde a la necesidad de contar con una plataforma de código abierto que, además de ser ampliamente reconocida en el ámbito académico, ofrece un ecosistema robusto para la gestión de proyectos científicos y de análisis de datos. El uso de Anaconda permite integrar de manera ordenada las distintas librerías requeridas, garantizando compatibilidad y facilidad en la instalación de dependencias. En cuanto a la dinámica de interacción, el procedimiento se caracteriza por una sencilla interfaz de usuario implementada en Jupyter

Notebook. El algoritmo opera de manera totalmente autónoma durante periodos establecidos, realizando capturas periódicas de la pantalla, estandarizando las dimensiones de cada imagen y almacenándolas en los directorios designados. Este esquema combina la automatización con una mínima interacción manual, asegurando tanto la eficiencia operativa como el control sobre la calidad de los datos generados. La figura 14 muestra el diagrama de flujo seguido para la elaboración de la base de datos.

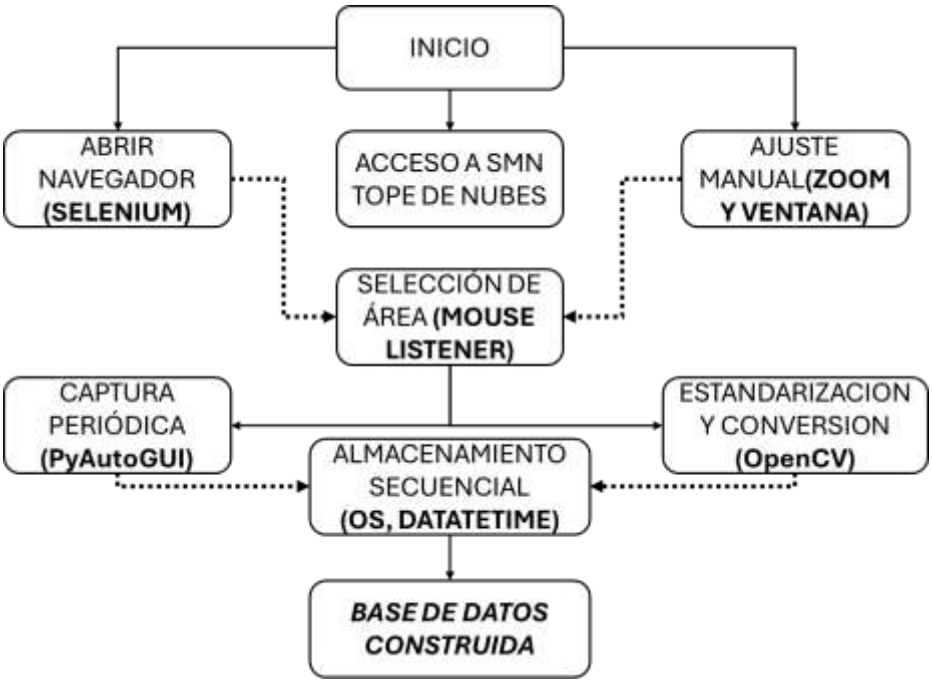


Figura 14 Diagrama de fujo construcción base de datos SMN

3.3.2.1 Librerías Python

Para la construcción del algoritmo en Jupyter Notebook es necesario utilizar un conjunto de librerías de Python que cumplen funciones específicas dentro del flujo de trabajo. Figura 15.

a. *OpenCV (cv2)*, que constituye uno de los paquetes más utilizados en procesamiento digital de imágenes. Esta librería permite convertir los archivos capturados a estructuras matriciales, realizar cambios en el formato de color (por ejemplo, de RGB a BGR) y almacenar las imágenes en disco en formato estandarizado.

b. *NumPy (np),* orientada a la manipulación de arreglos multidimensionales y operaciones matemáticas vectorizadas. Su inclusión resultó indispensable ya que cada imagen capturada se representa como una matriz de píxeles, y la eficiencia en el manejo de estos datos es crítica para mantener la fluidez del proceso automatizado.
c. *PyAutoGUI* desempeña un papel fundamental al posibilitar la captura directa de la pantalla en las coordenadas previamente delimitadas. Gracias a esta herramienta es posible registrar el área de interés en tiempo real sin necesidad de descargar directamente la animación desde el servidor del SMN, lo cual representa una solución práctica y adaptable.
d. A nivel de organización y control de archivos se emplea *os* y *time*. La primera permite crear directorios y gestionar las rutas de almacenamiento de las imágenes, mientras que la segunda facilita la programación de pausas entre capturas, asegurando la toma de imágenes en intervalos regulares. También se integra la librería *datetime* para manejar referencias temporales, aunque en este caso su papel es secundario.
e. *Pynput.mouse*, específicamente su clase *Listener*, con el propósito de registrar las interacciones del usuario mediante el ratón. Esto permite implementar un mecanismo de selección manual del área de estudio dentro de la pantalla, lo que dota al algoritmo de mayor flexibilidad, ya que el usuario puede delimitar de manera precisa la región de interés en cada sesión de captura.
f. *Selenium* y *webdriver_manager*, son herramientas orientadas a la automatización de navegadores web. Su función es abrir y controlar de forma programática el navegador "Google Chrome", accediendo directamente al portal del Servicio Meteorológico Nacional (SMN) en la sección Tope de Nubes. Estas librerías son esenciales para garantizar que la obtención de imágenes en un entorno controlado y replicable.

```
import cv2
import numpy as np
import pyautogui
import os
import time
from datetime import datetime
from pynput.mouse import Listener
from selenium import webdriver
from selenium.webdriver.chrome.service import Service
from webdriver_manager.chrome import ChromeDriverManager
```

Figura 15 librerías para la recopilación de imágenes en tiempo real

3.3.3 Obtención de imágenes desde SMN

El proceso de obtención de imágenes se basa en la automatización del acceso a la página oficial del Servicio Meteorológico Nacional (SMN). Para ello, el script desarrollado abre una instancia del navegador Google Chrome a través de Selenium y accede de manera directa a la sección del producto satelital Tope de Nubes. Con este procedimiento se elimina la dependencia de interacciones manuales repetitivas y se asegura la homogeneidad en la adquisición de datos.

Una vez cargada la página, el algoritmo ajusta automáticamente el tamaño de la ventana y aplica un nivel de zoom predeterminado. Este ajuste tiene como objetivo optimizar la visualización del área de interés y maximizar la calidad de las imágenes capturadas. En esta fase, se incluye también una interacción manual por parte del usuario, quien debe confirmar mediante la consola de Jupyter que la interfaz estaba lista para iniciar la secuencia de capturas. Este mecanismo híbrido (automatizado y manual) garantiza un mayor control sobre la calidad de los datos recolectados.

3.3.3.1 Definición del área de estudio

La delimitación del área de estudio representa un paso clave para el éxito de la investigación, dado que el análisis debe concentrarse exclusivamente en la Región IV del satélite GOES Este, correspondiente a la zona de interés agrícola en México. Para ello, el algoritmo permite al usuario marcar dos puntos en la pantalla mediante clics del ratón: el primero en la esquina superior izquierda y el segundo en la esquina inferior derecha de la región deseada.

Con estas coordenadas, el script calcula automáticamente las dimensiones del rectángulo de captura (ancho y alto en píxeles), así como la ubicación exacta de la esquina superior izquierda. Esta información es utilizada por PyAutoGUI para capturar únicamente la sección definida de la pantalla, excluyendo elementos irrelevantes de la interfaz del navegador.

3.3.3.2 Estandarización de las imágenes

Las imágenes generadas durante el proceso de captura se almacenan con dimensiones constantes, lo que permite estandarizar el conjunto de datos. Esta homogeneidad en la resolución y el formato constituye un requisito indispensable para su posterior procesamiento digital mediante técnicas de visión por computadora y redes neuronales convolucionales.

En particular, la estandarización reduce la necesidad de transformaciones adicionales en fases posteriores de la metodología, mejorando la consistencia del conjunto y evitando sesgos asociados a variaciones en la resolución. De este modo, cada imagen capturada se integra de manera directa en la base de datos.

3.3.3.3 Programación de intervalos y almacenamiento

El algoritmo se configura para llevar a cabo capturas en intervalos regulares, permitiendo obtener un registro temporal continuo de la evolución de las condiciones atmosféricas. La rutina está diseñada para operar durante 10 horas consecutivas, con intervalos de 20 minutos entre cada serie de capturas, esto a consideración del usuario y se puede modificar a conveniencia. Durante cada ronda de adquisición, el sistema genera seis imágenes consecutivas con un intervalo de 2 segundos entre cada una.

En cuanto al almacenamiento, se establece un directorio específico en el disco local del equipo. Cada archivo es guardado en formato .png con un número consecutivo asignado automáticamente por el programa. Adicionalmente, el algoritmo detecta la numeración de las imágenes ya almacenadas y continua la secuencia de manera incremental, evitando sobrescribir archivos previos. Los archivos también se pueden guardar por fechas secuenciales para poder monitorear por estacionalidad los fenómenos climáticos recurrentes.

El desarrollo del algoritmo en Anaconda con Python y su implementación en Jupyter Notebook permitió diseñar un flujo de trabajo automatizado, flexible y replicable para la obtención y estandarización de imágenes satelitales del producto Tope de Nubes del SMN. La integración de librerías especializadas, junto con la combinación de procesos automatizados y una mínima intervención manual, asegura la generación de una base de datos robusta, homogénea y confiable, que constituye un insumo fundamental para el análisis posterior de variables climáticas y la construcción de modelos de apoyo a la decisión en el sector agropecuario. Figura 16

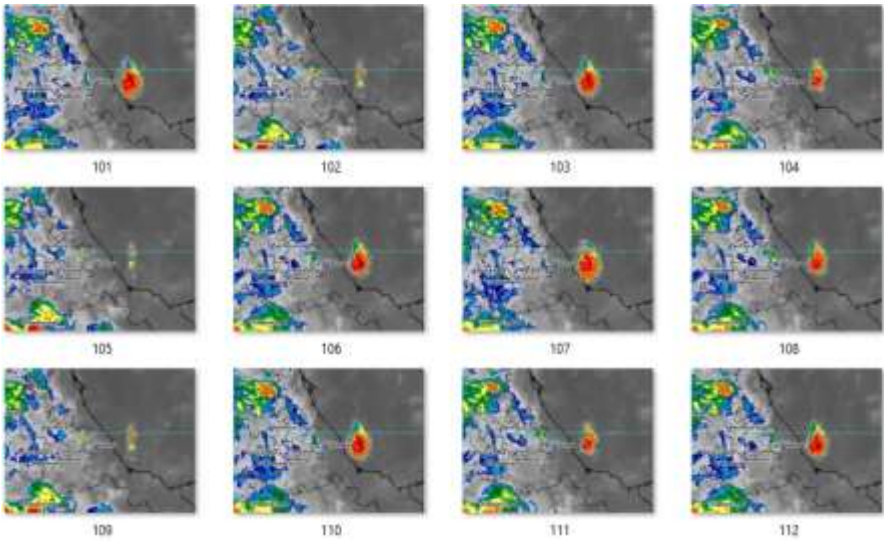


Figura 16 Base de datos tope de nubes de SMN

3.3.4 Algoritmo de extracción de parámetros climáticos a partir de colores

En el caso específico del producto Tope de Nubes del Sistema Meteorológico Nacional, el algoritmo de identificación de parámetros se basa en la interpretación cromática de las imágenes satelitales, donde cada color refleja la altura y temperatura de las nubes. Los tonos azules corresponden a nubes muy frías y altas, asociadas a sistemas convectivos intensos y alta humedad; los verdes indican nubosidad media con temperaturas moderadas; los amarillos reflejan nubes más cálidas y bajas; y los rojos o anaranjados señalan ausencia de nubosidad o condiciones de fuerte insolación en superficie. A través de esta escala de colores es posible inferir variables climáticas como temperatura atmosférica, cobertura nubosa, velocidad del viento y grado de humedad relativa, todas ellas

fundamentales para comprender los patrones meteorológicos. En el sector agropecuario, esta información resulta crítica, ya que la nubosidad y la altura de los topes nubosos influyen directamente en la ocurrencia de lluvias, la radiación solar sobre los cultivos, el estrés térmico en el ganado y la probabilidad de eventos extremos, factores que determinan tanto la productividad agrícola como la sanidad pecuaria.

Este trabajo implementa un pipeline reproducible que, a partir de las imágenes del Tope de Nubes (SMN) figura 17, detecta los colores puros de la paleta, divide cada imagen en cuadrantes, calcula proporciones por color y determina el color predominante por cuadrante. Con esas salidas se entrena una red neuronal capaz de etiquetar automáticamente cada cuadrante; dichas etiquetas serán la entrada de un sistema externo de toma de decisiones

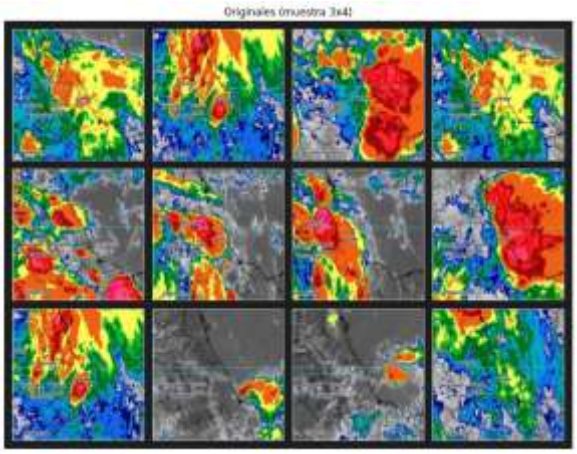


Figura 17 Imágenes cargadas y descomprimidas obtenidas del SMN

3.3.4.1 Segmentación cromática por umbrales HSV

Durante la preparación de los datos se aplicó una segmentación cromática para aislar únicamente los colores de interés de Tope de Nubes. Para ello, cada imagen se convierte del espacio BGR/RGB al espacio HSV, y se definen umbrales de tono (H), saturación (S) y valor (V) por cada color de la paleta. La operación de umbralización (cv2.inRange) genera una máscara binaria donde los píxeles que caen dentro del rango se marcan como 1 (255) y el resto como 0; de esta forma, al aplicar la máscara sobre la imagen, solo permanecen los colores válidos y todo lo

demás se vuelve negro, logrando el efecto de “negativo del fondo” sobre regiones no clasificadas (Figura 18).

Para reducir ruido puntual, a cada máscara se le aplicó una apertura morfológica (erosión seguida de dilatación) con un kernel elíptico 3×3, preservando las manchas de color coherentes y eliminando píxeles aislados. En términos de codificación, los niveles de gris siguen el rango habitual [0, 255], donde 0 representa ausencia de la clase (negro) y 255 presencia (blanco); cuando esas máscaras se proyectan a color, el fondo queda negro y únicamente los píxeles de la clase mantienen su color.

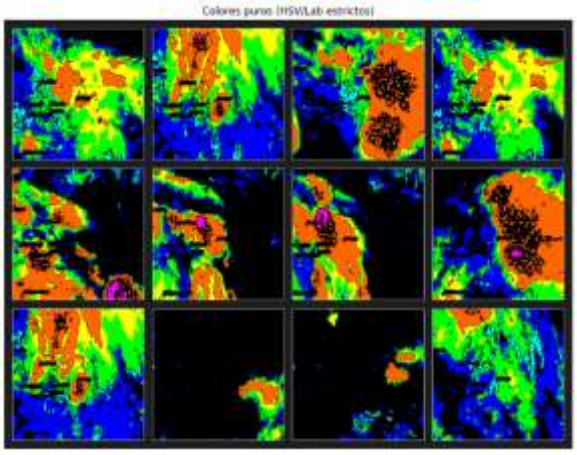


Figura 18 Segmentación cromática RGB a HSV

La Tabla 15 resume los rangos iniciales por color (en OpenCV: H∈[0,179], S,V∈[0,255]) que se usan para generar las máscaras binarias y, tras una apertura morfológica, obtener los “colores puros”. Estos valores son guía y son ajustables: se calibran contra la barra de color del producto y se validan visualmente para evitar “sangrado” entre clases.

Tabla 15 Rangos iniciales por color

Color	H (min–max)	S (min)	V (min)	Observaciones
Magenta	145–170	≥ 80	≥ 90	Núcleos muy fríos/altos
OrangeRed	0–15	≥ 120	≥ 90	Núcleos fríos a muy fríos
Yellow	20–35	≥ 120	≥ 110	Nube alta/estratiforme
Green	36–75	≥ 100	≥ 90	Nube media/templada
Cyan	85–95	≥ 100	≥ 90	Nube templada–fría
Blue	100–130	≥ 100	≥ 90	Cálido/superficie (despejado)

La Figura 19 muestra la *paleta por clase* con cuatro tonos por color dentro de su intervalo. Las etiquetas RGB en cada recuadro permiten verificar visualmente que los filtros capturan el aspecto esperado y sirven como referencia para calibrar o ajustar umbrales.

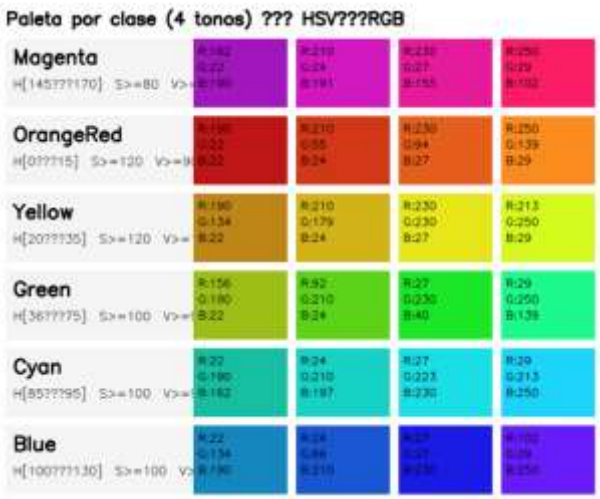


Figura 19 Paleta por clase derivada de los rangos HSV

3.3.4.2 Segmentación por cuadrantes y construcción del dataset global

Cada imagen se divide en una rejilla 2×2 (extensible a N×M) y, para cada cuadrante, se calculan las fracciones de píxeles que pertenecen a los colores de la paleta (Magenta, OrangeRed, Yellow, Green, Cyan y Blue), se identifica el color

predominante (máxima fracción) y se estima la cobertura coloreada del tile; los cuadrantes con cobertura baja se descartan para evitar sesgos.

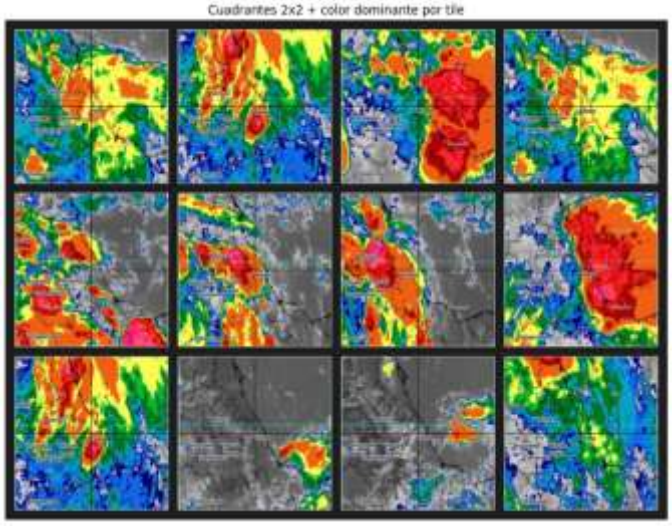


Figura 20 Segmentación por cuadrante y color predominante

3.3.4.3 Preparación, entrenamiento y evaluación de la red

Antes de entrenar, se revisan las distribuciones de los indicadores derivados a partir de las fracciones de color (p. ej., *Temp_estC*, *Wind_est_kmh*, *RH_est_pct*) para validar rangos, asimetrías y atípicos. Esta inspección sirve como control de calidad y evita alimentar la red con valores inconsistentes (figura 21).

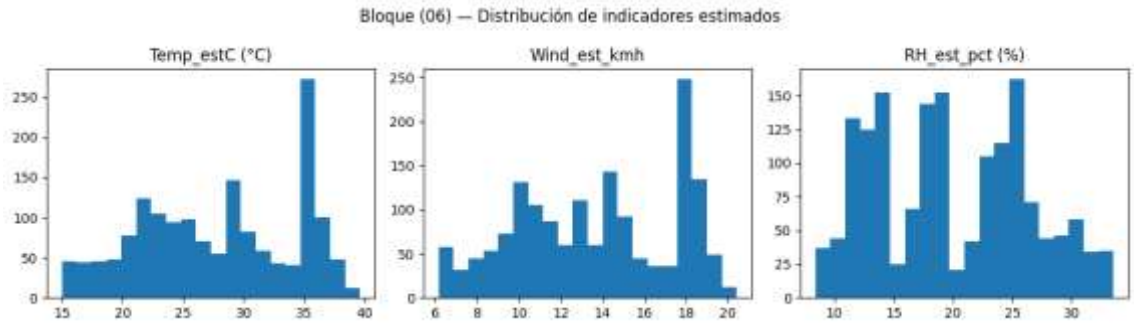


Figura 21 Distribución de indicadores derivados del color

Preparación

Desde el CSV global se recortan los parches correspondientes a cada cuadrante y se asigna como etiqueta el color predominante. Se aplica un umbral mínimo de cobertura para descartar mosaicos poco informativos; luego se realiza un split estratificado en train/val/test (70/15/15) preservando la proporción de clases. Para mitigar desequilibrios residuales, se usan aumentos ligeros (volteo horizontal, rotación ±5 %, zoom ±5 %).

Arquitectura

La red es una CNN compacta con bloques Conv–BatchNorm–ReLU y Global Average Pooling, entrada 128×128×3 y salida softmax de 6 clases (Magenta, OrangeRed, Yellow, Green, Cyan, Blue). Se entrena con Adam (lr=1e-3), lote 32, hasta 30 épocas, usando Early Stopping por val_accuracy, ReduceLROnPlateau y checkpoint del mejor modelo.

Evaluación

El desempeño final se reporta sobre test mediante accuracy global y métricas por clase (precision, recall, F1) junto con la matriz de confusión (normalizada por fila) para interpretar confusiones específicas entre colores.

3.3.5 Integración de parámetros cromáticos a un sistema difuso

En esta etapa, los valores obtenidos a partir del algoritmo de identificación cromática del producto Tope de Nubes constituyen las salidas primarias del modelo. Dichos valores corresponden a parámetros climáticos estimados temperatura, velocidad del viento, humedad relativa y altura de nubosidad, que son fundamentales para caracterizar el estado atmosférico de la región de estudio. Una vez identificados, estos parámetros se integran en un sistema de lógica difusa diseñado para generar dos variables de salida. La primera está orientada al sector pecuario, donde se busca representar un indicador de vulnerabilidad productiva, ya sea en términos de estrés térmico del ganado, condición zoosanitaria o productividad potencial, con el fin de vincular las condiciones climáticas con la calidad y desempeño de la actividad ganadera. La segunda salida corresponde al riesgo fitosanitario de la caña de azúcar, particularmente para enfermedades de

alta incidencia como Rust, Red Rot, Yellow y Mosaic, cuyo desarrollo depende en gran medida de la interacción de temperatura, humedad y nubosidad.

De esta manera, cuando el sistema difuso determina un riesgo elevado de enfermedades en caña, los resultados sirven como señal de activación para un segundo nivel de análisis basado en una red neuronal convolucional previamente entrenada, especializada en la clasificación de enfermedades a partir de imágenes de hojas de caña. Este flujo metodológico permite vincular la información satelital con la detección temprana de riesgos, y a su vez, conectar el diagnóstico climático con la confirmación visual en campo, proporcionando una herramienta robusta para la toma de decisiones en el sector agropecuario.

Para efectos metodológicos, se establece un umbral de riesgo en 0.7; cuando el índice calculado por el sistema difuso excede este valor, se considera que existe un riesgo elevado de afectación en el cultivo. En ese momento, el sistema activa un segundo nivel de análisis basado en una red neuronal convolucional previamente entrenada, especializada en la clasificación de enfermedades a partir de imágenes de hojas de caña. De esta manera, el modelo no solo estima condiciones de riesgo a partir de información satelital, sino que también confirma la presencia específica de enfermedades mediante un análisis visual directo, fortaleciendo así la precisión del diagnóstico.

Este flujo metodológico permite articular la información satelital, la inferencia difusa y la detección automática por redes neuronales, conformando un sistema robusto para la gestión pecuaria y agrícola en condiciones de cambio climático.

3.3.5.1 Planteamiento y selección de variables modelo difuso pecuario-agrícola

El objetivo central de este modelo difuso es estimar, de manera interpretable el nivel de riesgo sanitario en el sector pecuario (LSHR) y la probabilidad de ocurrencia de enfermedades en el cultivo de caña de azúcar (SCDP), tomando como base las condiciones meteorológicas locales. Esta aproximación permite integrar variables climáticas críticas en un esquema lógico que traduce información compleja en indicadores claros de riesgo, facilitando así la toma de decisiones en ambos sectores productivos.

En primer término, las variables de entrada del sistema difuso las que el algoritmo previamente entrenado reconoce a partir de las imágenes recolectadas del *tope de nubes* en el área de interés que establecimos; es decir, derivan del producto operativo que evaluamos en la página del Servicio Meteorológico Nacional (SMN). En este flujo, ese módulo extrae y normaliza los campos meteorológicos y los entrega al sistema difuso, asegurando trazabilidad entre la fuente original (SMN) y los indicadores de riesgo generados para los dos sectores.

Con base en ello, se definen tres variables de entrada de naturaleza meteorológica. *La amplitud térmica* diaria (Amplitud_T), entendida como la diferencia entre la temperatura máxima y mínima en un mismo día, captura el impacto de cambios bruscos de temperatura: estos generan estrés térmico en animales y plantas y pueden favorecer patógenos sensibles a oscilaciones térmicas. Figura 22.

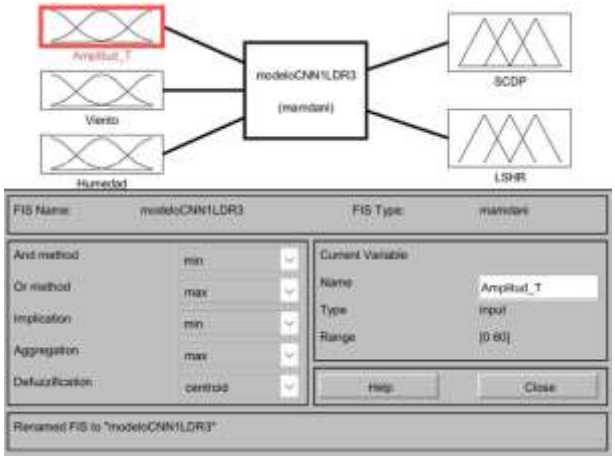


Figura 22 Interfaz de definición de variables modelo de riesgo agrícola y pecuario derivada de Tope de nubes SMN

La *velocidad del viento (Viento),* expresada en km/h, además de dispersar esporas y bacterias a mayores distancias, intensifica las pérdidas de calor (riesgo de estrés por frío) y modula la evapotranspiración, afectando el balance hídrico de cultivos y ganado.

Finalmente, la *humedad ambiental (Humedad)*, es determinante en la supervivencia y proliferación de hongos y bacterias; niveles altos propician condiciones favorables para la infección, mientras que niveles bajos inducen estrés hídrico y debilitan defensas naturales. En la región de estudio, la

combinación de humedad elevada con frentes fríos (“nortes”) agrava los riesgos respiratorios en el ganado y favorece infecciones fúngicas en la caña.

3.3.5.2 Etiquetas lingüísticas y funciones de membresía

El universo y las etiquetas lingüísticas de cada variable se construyen a partir de la información obtenida del producto Tope de Nubes del Servicio Meteorológico Nacional (SMN), Cada variable es discretizada en categorías lingüísticas que representan distintos niveles de intensidad, y se les asignan funciones de pertenencia de tipo triangular o trapezoidal con solapes intermedios, permitiendo que el modelo capte gradualmente la transición entre estados (de “bajo” a “medio”), evitando saltos bruscos en la inferencia, garantizando un comportamiento realista. La tabla 16 enlista los universos, etiquetas y parámetros de pertenencia definidos para las variables de entrada.

Tabla 16 Definición del universo y etiquetas lingüísticas de las variables de entrada derivadas del Tope de Nubes (SMN)

Variable	Etiqueta	Tipo MF	Parámetros MF	Intervalo
Amplitud_T (°C)	VL	trapmf	[0, 0, 8, 12]	Muy baja (0–12)
	L	trimf	[10, 16, 22]	Baja (10–22)
	M	trimf	[20, 26, 32]	Media (20–32)
	MH	trimf	[30, 36, 42]	Media-alta (30–42)
	H	trimf	[40, 46, 52]	Alta (40–52)
	VH	trapmf	[50, 56, 60, 60]	Muy alta (50–60)
Viento (km/h)	VL	trapmf	[0, 0, 4, 6]	Muy bajo (0–6)
	L	trimf	[5, 8, 11]	Bajo (5–11)
	M	trimf	[10, 13, 16]	Medio (10–16)
	MH	trimf	[15, 19, 23]	Medio-alto (15–23)
	H	trimf	[22, 27, 31]	Alto (22–31)
	VH	trapmf	[30, 33, 35, 35]	Muy alto (30–35)
Humedad (0–60)	EL	trapmf	[0, 0, 4, 8]	Extremadamente baja (0–8)
	VL	trimf	[6, 10, 14]	Muy baja (6–14)
	L	trimf	[12, 18, 24]	Baja (12–24)
	M	trimf	[22, 28, 34]	Media (22–34)
	H	trimf	[32, 40, 48]	Alta (32–48)
	VH	trapmf	[46, 54, 60, 60]	Muy alta (46–60)

Las variables de salida se establecen en categorías lingüísticas que permiten interpretar de forma clara los niveles de riesgo estimados por el sistema difuso. Tanto para el sector pecuario (LSHR) como para el cultivo de caña (SCDP), se

definen en cuatro niveles: bajo, medio, alto y muy alto. Estas salidas son representadas mediante funciones de pertenencia trapezoidales y triangulares distribuidos en el rango de 0 a 100. Tabla 17

Tabla 17 Definición del universo y etiquetas lingüísticas de las variables de Salida derivadas del Tope de Nubes (SMN)

Etiqueta	Tipo MF	Parámetros MF	Interpretación
L	trapmf	[0, 0, 15, 35]	Bajo
M	trimf	[25, 50, 75]	Medio
H	trimf	[60, 75, 90]	Alto
VH	trapmf	[80, 95, 100, 100]	Muy alto

3.3.5.3 Principios físicos/ epidemiológicos (Veracruz) construcción de reglas de inferencia

En el sector pecuario (LSHR), el riesgo sanitario está fuertemente condicionado por los "nortes": combinaciones de temperaturas bajas, viento intenso y humedad elevada que incrementan la probabilidad de afecciones respiratorias. En el extremo opuesto, los episodios de calor con sequedad elevan el riesgo por deshidratación y estrés calórico. Bajo condiciones intermedias típicas de bochorno o tiempo templado, el riesgo tiende a medio, a menos que el viento aumente de forma marcada, lo que puede agravar la situación.
Para el cultivo de caña de azúcar (SCDP), las condiciones de calor y sequedad incrementan la susceptibilidad del cultivo (por microheridas y estrés), favoreciendo la entrada de hongos y bacterias. En ambientes muy húmedos y templados se eleva la presión de inóculo y la esporulación, por lo que el riesgo se incrementa; el bochorno suele expresarse como riesgo medio. En contraste, escenarios de frío con humedad muy alta tienden a reducir o moderar la probabilidad de enfermedad (L–M), salvo eventos específicos que activen patógenos particulares.

La base de conocimiento se construye con una matriz principal que cruza Amplitud_T × Humedad para definir el nivel de riesgo basal, y un ajuste por Viento que modula el riesgo ± un nivel cuando el viento es particularmente alto (aumenta) o bajo (disminuye), reflejando su papel en dispersión y estrés. Para

evitar mesetas o escalones en las superficies de salida, se añaden reglas intermedias de suavizado en los puntos de cruce entre etiquetas lingüísticas, garantizando transiciones graduales y un comportamiento continuo y realista del sistema.

El diseño de las funciones de pertenencia sigue criterios orientados a garantizar tanto la coherencia del modelo como la representación adecuada de las condiciones climáticas locales. Se establece un solape del 20 al 40% entre funciones adyacentes, de manera que las transiciones sean graduales y evite la aparición de discontinuidades bruscas en la inferencia (Figura 23). Para los bordes del universo de discurso, se utilizan funciones trapezoidales (trapmf) en las categorías extremas —baja (L) y muy alta (VH)— con el fin de saturar adecuadamente los valores límite y asegurar estabilidad en los extremos del dominio. En el caso de las categorías intermedias, se adoptan funciones triangulares (trimf), que permiten representar de forma sencilla y clara las transiciones suaves entre niveles consecutivos, como medio y alto. Finalmente, se incorpora un ajuste regional, desplazando los centros de las funciones conforme a la climatología local obtenida a partir de series históricas.

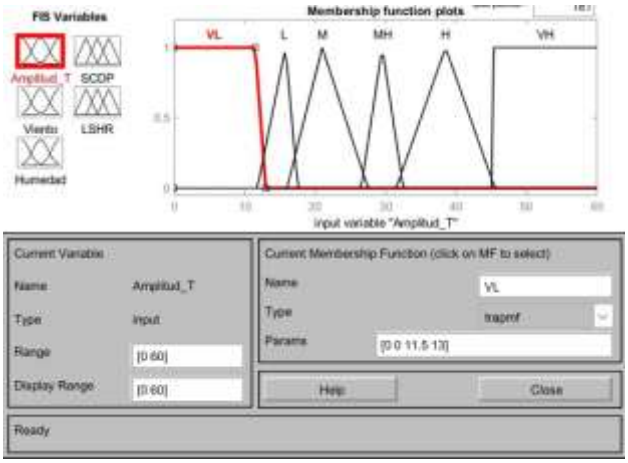


Figura 23 Funciones de pertenencia de las variables de entrada del sistema difuso

3.4 Proyección de valor de la producción pecuaria a partir del modelo difuso

3.4.1 Datos y alcance

Cobertura y unidad de análisis

El estudio se centra en el valor anual de la producción pecuaria del estado de Veracruz (expresado en miles de pesos corrientes). Cuando la fuente lo permite, el análisis se desagrega por especie: bovino, porcino, ovino, caprino, aves y guajolote. Esta variable es el insumo económico que posteriormente se ajusta por riesgo sanitario-climático.

Horizonte temporal

Se emplea información observada 2011–2021 para estimación y calibración (línea base y sensibilidad β) y se proyecta 2022–2030. La elección de 2011–2021 responde a la consistencia y comparabilidad de los cierres anuales en ese tramo, y a la disponibilidad de series consolidadas (existencia de datos en todos sus campos).

Fuentes y formato

Los valores pecuarios provienen del Cierre de la Producción Ganadera (SIAP) y se integran en una base homogénea a partir de las láminas oficiales digitalizadas. Las variables climáticas operativas (periodicidad mensual) son: amplitud térmica ($T_{man} - T_{min}$) humedad relativa y velocidad del viento; estas alimentan el modelo difuso para obtener el riesgo mensual R_m

3.4.2 Base económica "proyección sin riesgo"

El propósito de la línea base es reconstruir la trayectoria del valor anual de la producción pecuaria de Veracruz bajo condiciones "normales" de operación, es decir, sin incorporar aún el riesgo sanitario-climático. Para ello se toma como referencia el periodo 2011–2021, que ofrece series comparables y consolidadas, y a partir de ese historial se extrapola el periodo 2022–2030. Esta proyección constituye el referente contrafactual sobre el cual, más adelante, se aplicará el ajuste por riesgo del modelo FIS.

La preparación de la serie parte de los cierres anuales del SIAP expresados en miles de pesos corrientes. Se realiza una verificación de coherencia interanual, detección de atípicos y, cuando procede, se documentan posibles cambios metodológicos o rupturas contables. Aunque el análisis principal se mantiene en nominales (útiles para planeación presupuestal), se considera como sensibilidad una versión deflactada para aislar el componente real del crecimiento y distinguir efectos de precio y volumen.

Con la serie limpia, se plantean tres especificaciones parsimoniosas y auditables para modelar la tendencia de 2011–2021:

i) Lineal en niveles, que supone crecimiento en montos absolutos

$$V_t = \propto + \beta t + \varepsilon_t$$

ii) Log-lineal, que captura ritmos de crecimiento proporcional más estables

$$lnV_t = \propto + \gamma t + \varepsilon_t$$

iii) Una ruta de tasa compuesta (CAGR) que prolonga la tasa promedio entre 2011 y 2021

$$g = \left(\frac{V_{2021}}{V_{2011}}\right)^{1/(2021-2011)} - 1, V_t^{base} = V_{2021}(1+g)^{(t-2021)}$$

Como apoyo, se contrasta un suavizamiento exponencial simple cuando interesa ponderar con mayor peso la información más reciente sin imponer tendencia.

La estimación de las versiones lineal/log-lineal se realiza por Mínimos Cuadrados Ordinarios, con reporte de parámetros, errores estándar (robustos) y diagnóstico de residuos. Dado el salto de 2021, se examina la estabilidad estructural mediante contraste visual y, si es pertinente, pruebas de ruptura; de detectarse un cambio de régimen, se re-estima en una ventana estable o se introduce una dummy de nivel para evitar sesgos. La selección del modelo de base no se apoya solo en el ajuste in-sample: se privilegia la capacidad predictiva en retrovalidaciones temporales (p. ej., estimar 2011–2016 y evaluar 2017–2021) y en criterios de información (AIC/BIC), eligiendo la especificación con mejor compromiso entre parquedad, estabilidad y error de pronóstico.

3.5 Modelo para la detección y evaluación de enfermedades en caña de azúcar

El modelo CNN–FIS se concibe como una arquitectura híbrida que integra la clasificación automática de una red neuronal convolucional (CNN) con la capacidad de toma de decisiones de un sistema de lógica difusa en dos niveles *(Esquema jerárquico)*. En un primer paso, la CNN clasifica las hojas de caña de azúcar en diferentes estados fitosanitarios (saludable o con presencia de enfermedades), generando información que sirve como base para los sistemas difusos. Posteriormente, el primer nivel difuso (FIS-1) traduce las condiciones nutricionales, fisiológicas y ambientales en un índice de riesgo por enfermedad.

El segundo fis toma del modelo del tratamiento de imágenes variables climáticas que se traducen en impacto para el rendimiento del cultivo de caña de azúcar (t/ha) y la calidad de ese cultivo estimando los kilogramos de azúcar por tonelada cosechada (ATR).

3.5.1 CNN para la clasificación de enfermedades en caña de azúcar

El desarrollo y aplicación de la red neuronal convolucional (CNN) está orientada a la detección y clasificación automática de enfermedades en hojas de caña de azúcar. El modelo está diseñado bajo un enfoque de *transfer learning*, partiendo de una arquitectura pre-entrenada en grandes bases de datos de imágenes (ImageNet), y posteriormente adaptada a las particularidades del dominio agrícola. Esta estrategia permite aprovechar filtros generales de texturas y bordes, al tiempo que se incorporaron capas específicas para discriminar entre las cinco clases de interés (hoja saludable, Mosaic, Red Rot, Rust y Yellow).

3.5.1.1 Preparación del conjunto de datos

Para garantizar un entrenamiento confiable y reproducible, el conjunto de imágenes se reorganiza bajo una estructura limpia y controlada. Partiendo de una carpeta principal (dataset) que contenía cinco subcarpetas correspondientes a las clases de estudio: Saludable, Mosaic, Red Rot, Rust y Yellow.

Se implementa un split estratificado en proporción 80/20, destinando el 80% de las imágenes a entrenamiento y el 20% a validación. Este procedimiento se realiza con la función *train_test_split* de *scikit-learn,* asegurando aleatoriedad controlada mediante una semilla fija *(random_state=42).*

Adicionalmente, se aplica un *oversampling* moderado sobre las clases problemáticas (Mosaic, Rust y Yellow), duplicando una vez las imágenes en el conjunto de entrenamiento. Con ello se busca mitigar el desbalance entre categorías, sin generar un sobreajuste excesivo derivado de réplicas desproporcionadas.

3.5.1.2 Neutralización del fondo en las imágenes (Preprocesamiento)

Para disminuir la influencia de elementos externos y resaltar únicamente la morfología foliar, se desarrolla una función de *preprocesamiento* denominada *preprocess_leaf_neutral_bg*. Esta función opera en el espacio de color HSV para aislar el rango de verdes característico de las hojas de caña de azúcar. El procedimiento consta de los siguientes pasos:

1. Conversión de la imagen de RGB a HSV.
2. Aplicación de máscaras binarias en dos rangos de verde previamente definidos.
3. Filtrado morfológico (operaciones *open* y *close*) para reducir ruido en la segmentación.
4. Selección del contorno principal (hoja más grande).
5. Sustitución del fondo por un tono neutro gris (valor medio 128).

De esta forma, cada imagen final se obtiene normalizada en el rango [0,1], con un contraste enfocado en la hoja y sus posibles lesiones.

3.5.1.3 Generación de lotes con aumentación de datos

Una etapa fundamental en la preparación de los datos consiste en la aumentación controlada del conjunto de imágenes de entrenamiento. Este procedimiento tiene como propósito incrementar la diversidad del dataset sin necesidad de recolectar nuevas muestras, lo que resulta especialmente valioso cuando se trabaja con clases minoritarias o con bases de datos de tamaño limitado. La estrategia implementada

busca conservar la validez biológica de las lesiones observadas en la caña de azúcar, evitando transformaciones que pudieran alterar su morfología o coloración característica.

La aumentación se aplica únicamente en el conjunto de entrenamiento, mientras que el conjunto de validación permanece inalterado, *con el fin de obtener una evaluación objetiva del desempeño del modelo*. Todas las imágenes utilizadas en esta etapa pasan previamente por el proceso de neutralización de fondo (*preprocesamiento*), de manera que las transformaciones se aplicaran exclusivamente sobre el área foliar segmentada.

Los objetivos principales de la aumentación son:

1. Incrementar la variabilidad intra-clase: generar diferentes vistas de una misma muestra (rotaciones, traslaciones, escalados) para que el modelo aprenda a reconocer una enfermedad bajo múltiples condiciones de captura. Figura 18
2. Robustecer la red frente a variaciones fotométricas: simular condiciones de iluminación más brillantes u opacas, como las que ocurren en campo, sin distorsionar los tonos propios de cada lesión.
3. Regularizar el proceso de aprendizaje: reducir el sobreajuste al evitar que la red memorice patrones fijos, incentivándola a identificar características esenciales y no dependientes del encuadre o la iluminación.

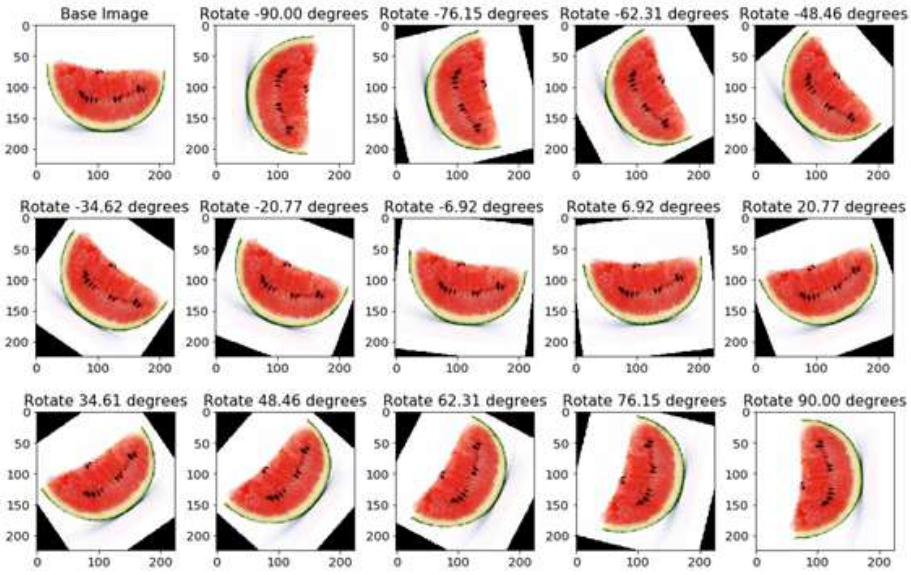


Figura 24 Aumentación en base de datos con clases desbalanceadas

Las transformaciones utilizadas se configurarán en el generador de imágenes *(ImageDataGenerator)* de la librería *Keras*, con parámetros definidos de manera moderada para preservar la integridad diagnóstica de las hojas. Las principales transformaciones de aumentación aplicadas en el conjunto de entrenamiento están descritas en la tabla 18.

Con el fin de asegurar la coherencia de las imágenes aumentadas, se implementó un sistema de inspección visual periódica que comparaba ejemplos originales y transformados. Este control permite verificar que:

1. Las lesiones principales permanecen visibles y sin deformaciones artificiales.
2. Los colores relativos entre tejido sano y tejido enfermo se conservan.
3. No se generan artefactos indeseados, como bordes recortados, manchas irreales o degradaciones del área foliar.

Tabla 18 Generación de lotes con aumentación de datos

Transformación	Parámetro aplicado	Justificación metodológica
Rotación	±25°	Permite robustecer el modelo frente a variaciones de orientación en la captura manual.
Traslación	±20%	Simula encuadres no centrados, comunes en la toma en campo.
Zoom	±20%	Asegura tolerancia a variaciones de distancia de captura sin recortar las lesiones.
Ajuste de brillo	0.8 – 1.2	Modela condiciones de iluminación natural (cielo nublado o soleado).
Inversión horizontal/vertical	Activa en ambos ejes	Introduce invariancia ante la ausencia de orientación fija de las hojas.
Normalización preprocess_input	Reescalado a [–1,1]	Garantiza compatibilidad con MobileNetV2 preentrenada en ImageNet.

Si en iteraciones posteriores se observa sensibilidad del modelo a cambios de iluminación o encuadre, se recomienda un ajuste fino: ampliar *brightness_range* a [0.75, 1.25] o reducir *rotation_range* a 15°, priorizando la conservación de texturas diagnósticas sobre la agresividad de la aumentación.

3.5.1.4 Arquitectura del modelo y estrategia de transfer learning

Selección de la arquitectura

Para arquitectura del modelo se opta por emplear *MobileNetV2* como base pre entrenada en el conjunto de datos *ImageNet,* lo que permite aprovechar filtros previamente entrenados en reconocimiento de texturas y bordes. Esta red fue seleccionada debido a su equilibrio entre precisión y eficiencia computacional, lo cual resulta particularmente útil cuando se trabaja con conjuntos de datos de tamaño medio y con la necesidad de mantener bajos los tiempos de entrenamiento. Dado que el objetivo es adaptar la red al problema de identificación de enfermedades en hojas de caña de azúcar, se elimina la capa superior de

clasificación general y se reemplaza por una cabeza diseñada específicamente para este caso de estudio.

Entrenamiento por etapas

En la primera etapa del entrenamiento, la base convolucional se mantiene congelada, de manera que sus pesos no se actualizan. Con ello se busca que los filtros de bajo nivel (aquellos que capturan características generales como bordes y formas básicas) permanezcan estables, mientras que la nueva cabeza de la red aprende patrones propios del dominio foliar, es decir, texturas, manchas y variaciones cromáticas asociadas a cada una de las enfermedades. Posteriormente, se plantea una segunda etapa de *fine-tuning* en la cual es posible descongelar gradualmente las capas más profundas de *MobileNetV2* para ajustar los filtros a las particularidades del conjunto de datos, utilizando para ello una tasa de aprendizaje más baja y un control cuidadoso de las capas de normalización (*Batch Normalization*).

Normalización y compatibilidad de datos

En cuanto al preprocesamiento, se tuvo en cuenta que las imágenes del generador llegan en un rango normalizado de 0 a 1 y con el fondo neutralizado. Para garantizar la compatibilidad con lo que espera *MobileNetV2*, las imágenes se escalan nuevamente a un rango de 0 a 255 y se procesan mediante la función *preprocess_input,* que transforma los valores a un intervalo de –1 a 1. De esta manera, se alinea la entrada del modelo con la misma distribución usada en su entrenamiento original, reduciendo así las diferencias estadísticas entre ambos contextos.

Diseño de la cabeza de clasificación

La cabeza de clasificación incorporada al modelo se diseña con una estructura ligera pero efectiva. En primer lugar, se utiliza una capa de *Global Average Pooling* para resumir espacialmente la información de los filtros convolucionales sin generar un exceso de parámetros, seguida de dos bloques de regularización mediante *Dropout* (con tasas de 0.4 y 0.3, respectivamente). Entre estas capas se incluye una densa intermedia de 256 neuronas con activación *ReLU*, que actúa

como proyección no lineal y refuerza la capacidad de la red para diferenciar patrones sutiles entre clases. Finalmente, se añade una capa *Dense* con activación *softmax* cuyo tamaño corresponde al número de categorías del problema, en este caso cinco: hoja saludable, Mosaic, Red Rot, Rust y Yellow.

Equilibrio entre capacidad y regularización

En conjunto, esta arquitectura busca equilibrar capacidad predictiva y control del sobreajuste. Por un lado, la reutilización de filtros entrenados en *ImageNet* brinda una base sólida para identificar características generales; por el otro, la nueva cabeza introduce la flexibilidad necesaria para discriminar las particularidades de cada enfermedad. Además, la incorporación de técnicas de regularización, tanto en la estructura (uso de *dropout*) como en el flujo de entrenamiento (aumentación de datos y preprocesamiento de fondo neutralizado), asegura una mejor generalización del modelo hacia imágenes no vistas.

3.5.1.5 Régimen de entrenamiento en dos etapas

Función de pérdida y regularización

El entrenamiento está diseñado en dos etapas complementarias para equilibrar estabilidad y capacidad de adaptación al dominio. En ambos casos se emplea una función de pérdida con *label smoothing* ($\varepsilon = 0.05$), lo que atenúa la sobre confianza del *softmax* y reduce picos no informativos en la *loss*, favoreciendo probabilidades más calibradas y una mejor generalización.

Callbacks para la estabilidad del entrenamiento

Adicionalmente, se prepara un conjunto de *callbacks* compartidos EarlyStopping con paciencia de 8 épocas y restauración de los mejores pesos, ReduceLROnPlateau con reducción del *learning rate* al 50% tras 4 épocas sin mejora (límite inferior 1×10^{-6}) y ModelCheckpoint para guardar el mejor estado del modelo, con el objetivo de estabilizar el proceso, evitar sobre entrenamiento y retener el punto de desempeño óptimo observado en validación.

Etapa 1: Entrenamiento inicial con base congelada

En la Etapa 1 (warm-up con base congelada) se entrena exclusivamente la cabeza de clasificación manteniendo fija la base convolucional (MobileNetV2 preentrenada). Se utiliza el optimizador Adam con una tasa de aprendizaje inicial de 1×10^{-3} y un máximo de 10 épocas. Con el fin de mitigar posibles desbalances residuales entre clases, se incorporan pesos de clase calculados a partir de la distribución real del conjunto de entrenamiento; estos pesos solo se aplican en esta primera etapa, donde el riesgo de que la cabeza se sesgue hacia clases mayoritarias es más alto. Este primer tramo actúa como una fase de "acoplamiento" entre las representaciones generales de ImageNet y las particularidades del tejido foliar de caña, permitiendo que la cabeza aprenda fronteras iniciales sin perturbar los filtros de bajo nivel.

Etapa 2: Ajuste fino del backbone (fine-tuning)

La Etapa 2 (fine-tuning estable) se orienta a refinar selectivamente el *backbone*. Para preservar la calibración estadística lograda durante el preentrenamiento, se mantienen congeladas todas las capas de *Batch Normalization*, evitando así el desplazamiento de sus medias y varianzas. Sobre el resto del *backbone* se aplica una descongelación progresiva y parcial, habilitando el entrenamiento solo en el tramo superior (≈ últimas 80 capas), mientras el resto permanece fijo. Esta estrategia concentra la adaptación en los bloques con mayor capacidad semántica, donde es más probable capturar patrones específicos de lesiones (pústulas, áreas cloróticas, mosaicos) sin degradar los detectores de bordes y texturas universales de los primeros niveles. El optimizador se sustituye por SGD con *momentum* (0.9) y Nesterov, y se incorpora clipnorm = 1.0 para controlar la norma del gradiente y prevenir inestabilidades en la actualización de pesos.

Control del aprendizaje y tasa de ajuste

El *fine-tuning* emplea un programa de tasa de aprendizaje con *warmup*: durante las tres primeras épocas la LR ascendiendo suavemente desde 1×10^{-5} hasta 3×10^{-4}, y a partir de ahí se aplica una decadencia suave (×0.9 por época) con un piso operativo de 1×10^{-4}. Este esquema reduce saltos bruscos en el paisaje de

optimización al inicio del ajuste fino y, en fases posteriores, promueve una convergencia más estable. A diferencia de la etapa anterior, en el *fine-tuning* no se usan pesos de clase, priorizando la estabilidad global del ajuste en los bloques superiores y evitando que las actualizaciones se polaricen por frecuencia de etiquetas.

Estabilidad y generalización

El tope de entrenamiento se fija en 40 épocas bajo el mismo conjunto de *callbacks*; al finalizar, el modelo recupera el mejor *checkpoint* almacenado, garantizando que los pesos reportados correspondan al mínimo de la pérdida de validación observado, incluso si la última época no fue la mejor.

3.5.1.6 Validación: curvas de entrenamiento, métricas y matriz de confusión

La evaluación del modelo se realiza sobre el conjunto de validación definido en el *split* 80/20. Para garantizar trazabilidad y evitar fuga de datos, el generador de validación se configura sin barajado y, previo a la inferencia, se ejecuta un reinicio del iterador (val_generator.reset()), de forma que las predicciones conservan el mismo orden que las etiquetas reales.

Curvas de entrenamiento y validación

En primer lugar, se inspeccionaron las curvas de entrenamiento y validación de *loss* y *accuracy* mediante la función plot_training_histories, que agrega en la misma figura el historial de la Etapa 1 (warm-up con base congelada) y la Etapa 2 (*fine-tuning*). Para una lectura más estable se aplica un suavizado ligero (*moving average*, ventana = 3), lo cual permite distinguir tendencias generales reduciendo el ruido inter-época. Este análisis visual es crucial para verificar que (i) la pérdida de validación acompaña a la de entrenamiento, (ii) no se observe divergencia sostenida (indicativa de sobreajuste), y (iii) las transiciones entre etapas (cambio de optimizador, descongelado parcial del *backbone*, *warmup* de *learning rate*) no introduzcan inestabilidades.

Predicciones y obtención de etiquetas

Posteriormente, se generan predicciones por lote sobre la validación, obteniendo la distribución de probabilidades por clase (y_prob) y el argmax como etiqueta

predicha (y_pred). Con ello se construye el reporte de clasificación de *scikit-learn* (classification_report) utilizando los nombres originales de las clases (Saludable, Mosaic, Red_Rot, Rust, Yellow). Este reporte incluye, para cada categoría, precisión, *recall* y F1-score, así como los agregados macro y ponderado.

Reporte de métricas de clasificación

El promedio macro trata a todas las clases por igual y es sensible al desempeño en clases minoritarias; es el indicador preferente cuando interesa mejorar Mosaic, Rust y Yellow. El promedio ponderado se ajusta por el soporte (número de muestras por clase) y, por tanto, refleja el desempeño global considerando el desbalance residual. El accuracy reporta la fracción total de aciertos, útil como medida general pero menos informativa cuando el interés se centra en recuperar correctamente (alto *recall*) las clases más difíciles.

Matriz de confusión en conteos y valores normalizados

La matriz de confusión se presenta en dos formatos complementarios. En conteos absolutos, permite identificar los pares de confusión más frecuentes (por ejemplo, errores cruzados entre Mosaic y Yellow si sus patrones cromáticos coinciden en determinadas condiciones de iluminación). En forma normalizada por fila (*normalize='true'*), cada fila suma 1 y muestra la tasa de acierto por clase, ofreciendo una lectura directa del recall por categoría y destacando qué clases requieren estrategias específicas de mejora (p. ej., ajustes de aumentación, *fine-tuning* de mayor profundidad o calibración de umbrales de decisión en escenarios operativos).

Interpretación de resultados y utilidad práctica

Operativamente, los gráficos y métricas cumplen tres propósitos: (i) verificar la calidad de la convergencia (curvas), (ii) cuantificar el desempeño por clase y global (reporte), y (iii) localizar patrones sistemáticos de error (matriz). En trabajos posteriores, y con fines de interpretabilidad, se recomienda complementar este análisis con visualizaciones tipo Grad-CAM sobre verdaderos positivos y falsos negativos de las clases desafiantes, a fin de confirmar que el modelo atiende a regiones lesionales y no a artefactos del preprocesamiento o del fondo neutralizado.

Además del análisis cuantitativo (curvas de entrenamiento/validación, métricas por clase y matrices de confusión), se incorpora una inspección visual sistemática de resultados en validación mediante rejillas de 3×3 imágenes con sus predicciones y probabilidades asociadas. Esta visualización permite contrastar, de forma rápida e interpretativa, el comportamiento del clasificador sobre diferentes clases y niveles de confianza.

Desde una perspectiva metodológica, estas rejillas cumplen tres propósitos. Primero, permiten validar visualmente que las predicciones con alta confianza están alineadas con patrones lesionales plausibles (coloraciones, mosaicos, pústulas, bordes necróticos). Segundo, ayudan a diagnosticar confusiones: por ejemplo, verificar si el modelo se apoya en texturas del tejido o si aún existe influencia residual de sombras/iluminación a pesar del fondo neutralizado. Tercero, sirven como material de soporte en futuras presentaciones, aportando evidencia cualitativa del desempeño y de la calibración de confianza del modelo (coherencia entre probabilidad reportada y acierto observable).

3.5.2 Sistema difuso para enfermedades de caña de azúcar

El sistema está diseñado bajo un esquema jerárquico en dos niveles de inferencia difusa, con el propósito de representar la relación entre condiciones nutricionales, ambientales y fisiológicas de la caña de azúcar, y su impacto tanto en la incidencia de enfermedades como en los indicadores productivos e industriales.

3.5.2.1 Sistema difuso por enfermedad (FIS-1)

Definición de Variables de entrada

El sistema FIS-1 se implementa por cada enfermedad (Mosaic, Rust, Yellow, Red Rot y Healthy como referencia). Las siete variables de entrada son seleccionadas por su relevancia directa en la aparición y severidad de enfermedades:

1) Índice N/K (NKI): Refleja el balance entre nitrógeno y potasio. Un desbalance con exceso de nitrógeno o deficiencia de potasio favorece la susceptibilidad a enfermedades foliares.
2) Fósforo (P): Nutriente esencial en metabolismo energético; niveles bajos comprometen la resistencia natural del cultivo.

3) K + Mg foliar (KMg): Índice que integra dos cationes fundamentales para vigor y fotosíntesis. Niveles bajos limitan la tolerancia a estrés biótico.
4) Vigor (VIG): Indicador fisiológico (0–100). Plantas con vigor bajo son más propensas a infecciones y menor resiliencia.
5) Humedad de suelo (SM): Condición que regula la predisposición a pudriciones radiculares y estrés hídrico.
6) Mojado foliar (LWH): Número de horas de hoja húmeda por día; parámetro crítico para la germinación de esporas y el avance de patógenos como Rust.
7) Edad del cultivo (AGE): Determina la fase fenológica; enfermedades como Red Rot tienen mayor incidencia en caña madura.

La Tabla 19 resume las principales variables de entrada consideradas en el sistema difuso de primer nivel (FIS-1), especificando sus abreviaturas, unidades, rangos de trabajo, fuentes típicas de obtención y la justificación fisiopatológica de su inclusión. Esta tabla permite apreciar cómo cada variable se fundamenta en criterios agronómicos y fitosanitarios, integrando tanto datos medibles en campo o laboratorio como su relación con la susceptibilidad del cultivo frente a diferentes enfermedades.

Tabla 19 Variables de entrada FIS-1

Abrev.	Variable	Unidad	Rango	Fuente típica	Justificación fisiopatológica
NKI	Balance N/K (−1: K relativo; +1: N relativo)	—	(−1)-1	Análisis foliar, ratio normalizado	Exceso de N (NH) favorece tejidos tiernos y **eleva susceptibilidad** (p.ej., Roya); déficit de K reduce defensa osmótica.
P	Fósforo disponible	ppm	0-30	Suelo/Lab	P bajo limita energía/ATP y raíces; en **Red Rot** P bajo con humedad alta agrava pudriciones.
KMg	Índice K+Mg foliar	—	0-2	Foliar	**K y Mg** sostienen osmorregulación y clorofila; **deficiencia → VIG bajo**, **mayor riesgo** (Yellow, Mosaic).
VIG	Vigor (NDVI/SPAD escalado)	0–100	0-100	Sensor/dron/SPAD	Proxy de salud y fotosíntesis; **bajo vigor** se asocia a **mayor progreso** de enfermedad.
SM	Humedad de suelo	%	0-60	Sonda/suelo	Humedad alta facilita **inóculo/propagación** (Red Rot) y prolonga mojado foliar.
LWH	Horas de mojado foliar	h/d	0-12	Estación/hoja mojada	**Ventana de infección** (roya y otros hongos). Mojado **prolongado** ↑ riesgo.
AGE	Edad del cultivo	meses	0-18	Registro	Fase fenológica: **plantas jóvenes** son más susceptibles a Roya/Mosaic; **adultas** a Red Rot.

La tabla 20 por su parte, establece todos los valores para los parámetros de cada una de las variables de entrada, de esta manera, se establece el marco de referencia sobre el cual se construyen las funciones de pertenencia y las reglas de inferencia que conforman el modelo

Tabla 20 Parámetros de las variables de entrada FIS-1

Var	MF	Tipo	Parámetros
NKI	KL (K_low)	trapmf	[-1 -1 -0.5 -0.1]
	BAL (Balance)	gaussmf	[0.20 0] *(σ, c)*
	NH (N_high)	trapmf	[0.1 0.4 1 1]
P	PL	trapmf	[0 0 5 10]
	PM	trimf	[8 14 20]
	PH	trapmf	[18 22 30 30]
KMg	KML	trapmf	[0 0 0.3 0.6]
	KMM	trimf	[0.5 1.0 1.5]
	KMH	trapmf	[1.2 1.5 2.0 2.0]
VIG	VL	trapmf	[0 0 35 55]
	VM	gaussmf	[12 65]
	VH	trapmf	[70 80 100 100]
SM	SML	trapmf	[0 0 10 20]
	SMM	trimf	[15 30 45]
	SMH	trapmf	[40 50 60 60]
LWH	LWL	trapmf	[0 0 1 3]
	LWM	gaussmf	[1.2 5]
	LWH	trapmf	[6 8 12 12]
AGE	YNG	trapmf	[0 0 3 6]
	MID	gaussmf	[2 9]
	OLD	trapmf	[10 14 18 18]

3.5.2.2 Variable de salida FIS-1

Risk (0–1): Nivel de riesgo de enfermedad. Se definieron tres etiquetas (Low, Medium, High), con funciones trapezoidales y gaussianas, lo que permitió capturar transiciones suaves y evitar superficies planas. La tabla 18 muestra la variable RISK, sus parámetros y su función de membresía para riesgo bajo (RL), riesgo medio (RM), y riesgo alto (RH) respectivamente.

Tabla 21 Funciones de membresía para Risk

Var	Universo	MF	Tipo	Parámetros
RISK	0-1	**RL**	trapmf	[0 0 0.10 0.25]
		RM	trimf	[0.20 0.45 0.70]
		RH	trapmf	[0.60 0.80 1.0 1.0]

3.5.2.3 Lógica y reglas difusas

Cada enfermedad es modelada en el sistema difuso mediante un conjunto específico de reglas, diseñadas a partir del conocimiento agronómico y de la fisiopatología del cultivo de caña de azúcar. El propósito de esta estrategia es capturar la lógica particular con la que cada patógeno se desarrolla y afecta al cultivo, evitando la aplicación de reglas genéricas que minimicen las diferencias entre enfermedades. (Figura 25)

a) Rust (roya), el sistema enfatiza como variables críticas las horas de mojado foliar (LWH) y la humedad relativa, ya que la literatura y la experiencia en campo coinciden en que la germinación de esporas de *Puccinia melanocephala* requiere la presencia prolongada de agua libre sobre la superficie de la hoja. Bajo estas condiciones, incluso plantas con buen vigor pueden presentar incrementos significativos en el nivel de riesgo.(Ilmer Barrera Arrera et al., 2012)
b) La enfermedad conocida como Red Rot (pudrición roja) se modela principalmente en función de la edad del cultivo y de la humedad del suelo. Este patógeno tiene mayor impacto en caña madura, donde los tejidos internos son más susceptibles a colonización, y se ve favorecido por condiciones de exceso de humedad que prolongan la saturación del suelo. Por ello, las reglas asociadas a esta enfermedad refuerzan el peso de la variable AGE en combinación con niveles altos de SM.
c) En el caso de *Mosaic y Yellow*, el riesgo se relacionó con el estado nutricional de la planta, especialmente con desbalances entre nitrógeno y potasio (NKI) y con los niveles de K+Mg foliar (KMg), generando tejidos menos resistentes y un metabolismo fotosintético ineficiente.

d) Healthy (cultivo sano), que cumple la función de referencia o calibración del sistema. En este caso, las reglas se diseñaron para establecer escenarios de bajo riesgo cuando las condiciones nutricionales, fisiológicas y ambientales se encuentran dentro de rangos óptimos.

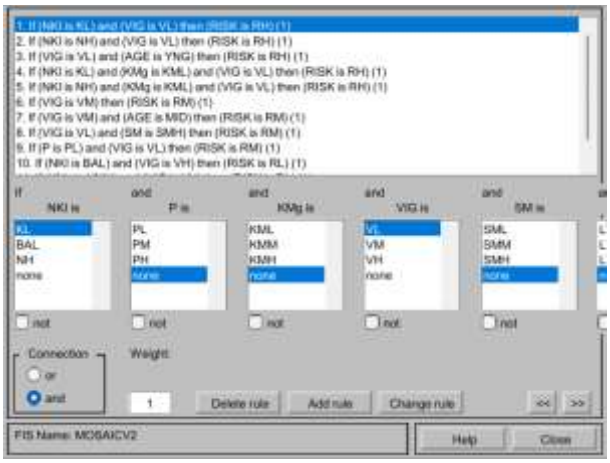


Figura 25 Ejemplo de reglas difusas en la interfaz de MATLAB

3.5.2.4 Módulo difuso de rendimiento y calidad (FIS-2)

El desarrollo del sistema difuso de dos salidas por enfermedad está orientado a estimar: (i) Rendimiento (t/ha) y (ii) Calidad (ATR, kg/t), a partir de variables de severidad de la enfermedad y condiciones climáticas. Para cada patología (Mosaic, Red Rot, Rust, Yellow) se define un subsistema con idéntica estructura y universos de discurso, variando únicamente las reglas según la fisiopatología y el comportamiento empírico de cada enfermedad.

Variables de entrada y salida

Entradas comunes (Tabla 22): severidad (0–100), humedad (0–60%), viento (0–35 km/h), amplitud térmica (0–60 °C) y edad del cultivo (0–18 meses). Salidas comunes (tabla 23): rendimiento (0–120 t/ha) y ATR (80–160 kg/t). Se incluyeron salidas auxiliares de manejo (recomendación de fungicida, saneamiento y nutrición; escala 0–100) para vincular el modelo con decisiones agronómicas.

Tabla 22 Variables de entrada Fis-2

Variable (símbolo)	Tipo	Universo (unidad)	Conjuntos de pertenencia (MFs)	Nota de forma
Severidad de la enfermedad (SEV)	Entrada	0–100 (%)	baja, media, alta	trapmf–trimf–trapmf
Humedad	Entrada	0–60 (%)	EL, VL, L, M, H, VH	extremos trapmf; intermedias trimf
Viento	Entrada	0–35 (km/h)	VL, L, M, MH, H, VH	extremos trapmf; intermedias trimf
Amplitud térmica (AMP_T)	Entrada	0–60 (°C)	VL, L, M, MH, H, VH	extremos trapmf; intermedias trimf
Edad del cultivo (EDAD)	Entrada	0–18 (meses)	joven, media, madura	extremos trapmf; intermedia trimf

Tabla 23 Variables de salida Fis-2

Variable (símbolo)	Tipo	Universo (unidad)	Conjuntos de pertenencia (MFs)	Nota de forma
Rendimiento (RINDE)	Salida	0–120 (t/ha)	muy_bajo, bajo, medio, alto, muy_alto	extremos trapmf; intermedias trimf
Calidad – ATR (ATR)	Salida	80–160 (kg/t)	bajo, medio, alto	extremos trapmf; intermedia trimf (solape moderado)
Recomendación fungicida (FUNG)	Salida	0–100	baja, media, alta	extremos trapmf; intermedia trimf
Recomendación saneamiento (SAN)	Salida	0–100	baja, media, alta	extremos trapmf; intermedia trimf
Recomendación nutrición (NUTR)	Salida	0–100	baja, media, alta	extremos trapmf; intermedia trimf

Se emplean trapmf en los extremos (para saturar colas) y trimf para categorías intermedias, con solapes de 20–35% entre conjuntos adyacentes.

Cada enfermedad se modeló con un conjunto de reglas Mamdani que relacionan severidad y clima con las salidas. Las reglas capturan tres ideas guía:

1) Efecto directo de la severidad sobre el cultivo.
2) Modulación climática (humedad, amplitud térmica y viento) sobre la progresión/diseminación.
3) Regulación higro-térmica de ATR (azúcar teóricamente recuperable): ATR tiende a mejorar cerca de condiciones “óptimas” y a caer en extremos de sequedad o calor.

Generación de escenarios y simulación

Con el propósito de determinar qué enfermedad exige mayor urgencia de atención, se diseña la creación de escenarios que somete al modelo a condiciones contrastantes y representativas, empleando dos modalidades complementarias: (i) escenarios canónicos: *benigno, húmedo-ventoso y brote severo*, que reflejan situaciones agronómicas típicas y permiten comparar respuestas en condiciones límite; y (ii) muestreo aleatorio: (uniforme dentro de los rangos definidos) para explorar de manera amplia el espacio de estados y caracterizar la variabilidad de resultados.

Cada escenario se evalúa obteniendo Rendimiento (t/ha), ATR (kg/t) e indicadores de manejo (recomendaciones de fungicida, saneamiento y nutrición). Las salidas se almacenan en archivos CSV para trazabilidad y reproducción. A partir de estas simulaciones se calcularon métricas de decisión; promedios, cuantiles (p. ej., P90 de pérdida) y un índice compuesto de severidad (0.6·Rendimiento + 0.4·ATR, ambos normalizados) que permiten jerarquizar las enfermedades y señalar prioridades de intervención bajo distintos contextos climáticos.

3.5.2.6 Implementación de los modelos difusos

La implementación del modelo se llevóa a cabo en el entorno MATLAB Fuzzy Designer y Python con scikit-fuzzy, incorporando rutinas de evaluación por escenario/condición. Se optan por el enfoque Mamdani en ambos niveles (FIS-1 y FIS-2), por su capacidad de manejar reglas en lenguaje natural y traducirlas en resultados cuantitativos mediante inferencia difusa.

3.6 Conclusiones del capítulo

La metodología presentada en este capítulo ofrece un marco robusto para evaluar la vulnerabilidad y el riesgo agropecuario frente al cambio climático en México, con especial atención al caso de Veracruz. La combinación de construcción de indicadores, modelado multiagente, dinámica de sistemas, procesamiento digital de imágenes satelitales y redes neuronales convolucionales posibilita un abordaje multidimensional del problema.

El empleo de imágenes satelitales y su tratamiento digital, junto con la integración de sistemas difusos, aporta una herramienta innovadora para monitorear en tiempo casi real parámetros climáticos críticos, vinculando la información meteorológica con el desempeño productivo. Asimismo, la articulación de redes neuronales convolucionales en el diagnóstico fitosanitario de la caña de azúcar fortalece el modelo, al permitir una validación visual precisa y automática de las condiciones de las hojas.

Este capítulo sienta las bases técnicas y operativas para la implementación del modelo híbrido propuesto. La metodología no solo organiza y sistematiza la investigación, sino que también proyecta un enfoque replicable y escalable para evaluar riesgos agropecuarios en distintos contextos geográficos, combinando ciencia de datos, inteligencia artificial y conocimiento agroclimático con el fin de generar soluciones orientadas a la resiliencia y sostenibilidad del sector.

CAPITULO IV RESULTADOS

4.1 Análisis de sensibilidad (Modelo multiagentes)

La consistencia dimensional es usada para analizar que las ecuaciones y series de tiempo estén conectados correctamente.

Los valores de salida de los submodelos utilizan kilogramos por hectárea (Kg/Ha) para determinar el rendimiento del cultivo agrícola; kilogramos por metro cúbico (Kg/m3) para determinar la eficiencia de los recursos hídricos en la agricultura; y gigatoneladas de dióxido de carbono equivalente (Gt CO_2eq) para medir la cantidad de emisiones GEI emitidas por el sector agropecuario e incendios forestales.

A cada valor de salida de los submodelos se les asigna un factor de vulnerabilidad con escala de 0 a 1 para unificar los valores en términos de vulnerabilidad, siendo 1 el valor máximo de vulnerabilidad.

El rendimiento de las tierras agrícolas tiene que ver directamente con la disponibilidad de agua, temperaturas óptimas para el cultivo, así como la extensión de tierras disponibles.

Los cambios en los patrones de temperaturas y patrones de precipitación en México según el instituto nacional de ecología y cambio climático (INEC) en sus proyecciones a corto mediano y largo plazo (figura 26) se espera disminución de precipitación de hasta 10% desatando sequias más prolongadas y más frecuentes, además de un aumento de temperatura máxima, media y mínima, este aumento de temperatura representa una mayor evotranspiración acelerando la perdida de agua de los cultivos tanto la proveniente del suelo como la perdida de agua de la vegetación. Hacia 2050, se estima una pérdida acumulada de entre el 40% y 50% en comparación con niveles históricos, debido a sequías más intensas, alteraciones en las lluvias y una baja recarga de acuíferos, el escenario más crítico sugiere una caída del 70-80% en la disponibilidad hídrica, llegando a niveles de 1,800 m^3 per cápita. (Instituto Mexicano de tecnología del Agua, 2015)

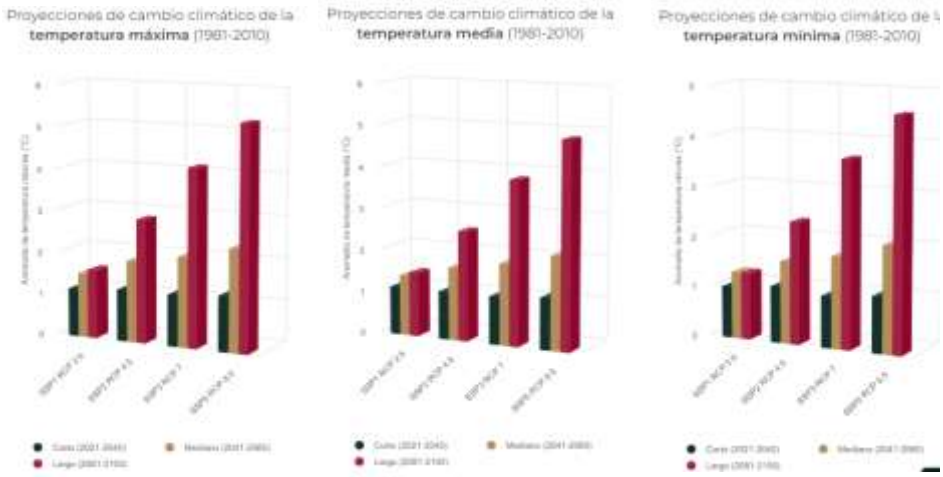


Figura 26 Proyecciones de temperaturas ante el cambio climático

En este contexto se visualizan cinco escenarios simulados en 12 ciclos, el primer escenario es con el 100% del rendimiento de las tierras agrícolas, el segundo con un rendimiento del 90%, el tercero con un rendimiento del 70, el cuarto un rendimiento de 40 y por último un rendimiento del 10% es decir hasta un decremento del 90% del rendimiento de las tierras agrícolas tomando un escenario muy pesimista ante los efectos del cambio climático.

4.1.1 análisis de sensibilidad Recurso Hídrico

A partir de ello, se plantean 6 escenarios para las redes de información modeladas, el escenario 1 representa un aumento de disponibilidad de recurso hídrico del 15 % este aumento como resultado de las mejoras en la gestión del recurso hídrico y medidas de adaptación que se toman frente a los efectos del cambio climático, dicho escenario es el más optimista de la simulación, el escenario 2 representa el comportamiento del recurso hídrico sin ninguna tendencia, los escenarios 3, 4, 5 y 6 se plantea una tendencia de disminución de la eficiencia del recurso hídrico de 20, 40, 60 y 80% respectivamente de acuerdo con los datos de del instituto mexicano de tecnología del agua en donde se menciona que se podría tener una disminución hasta de un 80% el cual representa el escenario más pesimista para dicho recurso, mostrando el impacto de la disponibilidad de agua en la eficiencia del recurso hídrico destinados para el cultivo de caña de azúcar y la ganadería (ganado bovino, porcino, avícola). Figura 27

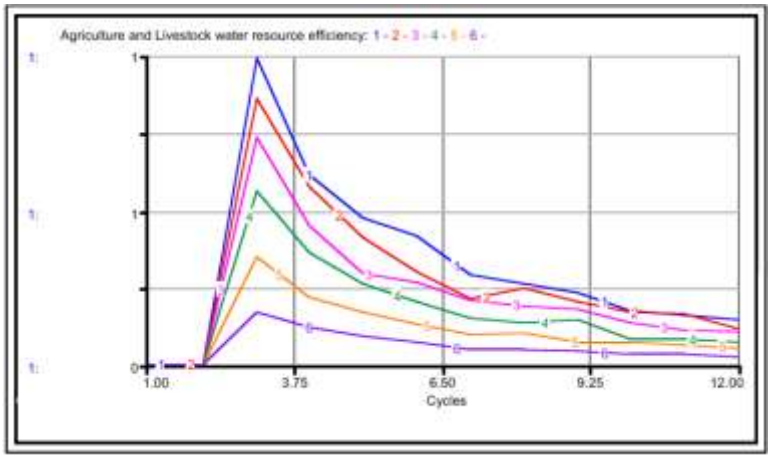


Figura 27 Escenarios para la eficiencia del recurso hídrico

Los valores de vulnerabilidad se encuentran en una escala de 0-1 en donde cero representa la vulnerabilidad más baja y uno la vulnerabilidad más alta para los recursos hídricos destinados al agricultura y ganadería. En la tabla 20 se encuentran los resultados obtenidos con respecto a los escenarios planteados para el recurso hídrico, la variable de eficiencia del recurso hídrico para la agricultura y la ganadería depende directamente de la disponibilidad de agua para dicha industria, la eficiencia aumenta con mayor disponibilidad de agua y al mismo tiempo disminuye la vulnerabilidad de dicho recurso. El escenario más optimista es el 1 aumentando la eficiencia del recurso hídrico en un 15%. El escenario uno, aumentando la tendencia nos muestra una vulnerabilidad del recurso hídrico de 0.41, el escenario actual en donde no se modifica la tendencia da un valor de vulnerabilidad de 0.44 representa un valor de vulnerabilidad aún bajo, si el valor del factor obtenido de cada una de las redes de información es mayor o igual a 0.54 se habla de vulnerabilidad alta.

Tabla 24 Resultados para los escenarios del recurso Hídrico

Variable	**Value**					
	+15% Trend	**0% Trend**	**-20% Trend**	**-40% Trend**	**-60% Trend**	**-80% Trend**
Agriculture and Livestock water available	41,128.75	3,949.41	3,524.36	3,509.93	2,828.91	2,531.68
Water Resource Efficiency	0.897	0.812	0.552	0.424	0.229	0.14

La vulnerabilidad del recurso hídrico para la industria agrícola y ganadera depende directamente de la disponibilidad de agua para esta industria como se representa en la figura 28, en donde la vulnerabilidad disminuye en aquellos puntos en donde la disponibilidad de agua aumenta.

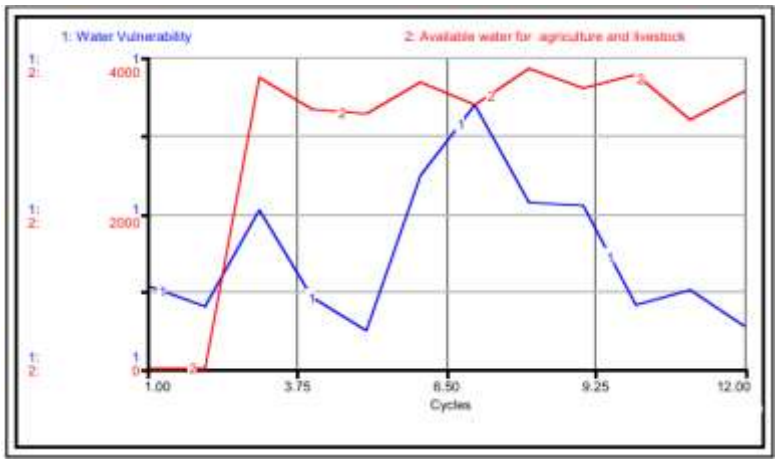


Figura 28 Disponibilidad de agua y su relación con la Vulnerabilidad del recurso hídrico

4.1.2 Análisis de sensibilidad Tierras agrícolas y pecuarias

En cuanto a las tierras destinada para el cultivo de caña de azúcar y para la crianza y explotación de ganado bovino, porcino y avícola, se plantean también los 6 escenarios, en el escenario 1 se aumenta la tendencia en un 15% siendo el más optimista para el rendimiento de tierras agrícolas y ganaderas, el escenario 2 representa el comportamiento de las variables simuladas sin aumento o decremento de tendencia, en los escenarios 3 al 6 se hace un decremento del 20%, quedando la eficiencia de 80, 60, 40 y 20% respectivamente. Figura 16

La disponibilidad de tierras para agricultura y ganadería enfrenta desafíos crecientes a corto, mediano y largo plazo debido al cambio climático, la urbanización y la degradación del suelo.

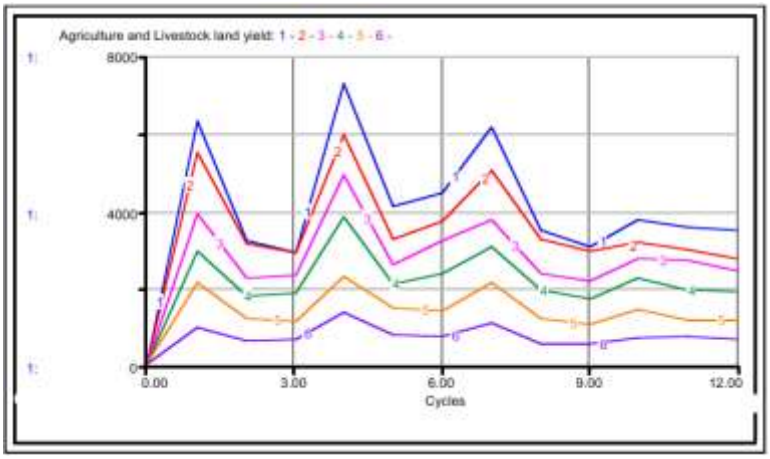


Figura 29 Escenarios de las tierras agrícolas y pecuarias

En el corto plazo, la intensificación de la producción es notable, mientras que, a mediano plazo, los efectos climáticos y la demanda por otros usos del suelo reducen la calidad y cantidad de tierras disponibles. La tabla 24 enlista los resultados obtenidos en la simulación de los diferentes escenarios, en donde la vulnerabilidad menor se presenta en el escenario 1 con 0.46 aumentando la tendencia en un 15% y la vulnerabilidad mayor con 0.96 se presenta en el escenario 6 disminuyendo el rendimiento de las tierras agrícolas y pecuarias hasta un 80%, las tierras dedicados al sector agrícola y pecuario se encuentran en vulnerabilidad alta a partir de la tendencia actual, es decir este sector necesita ya medidas de mitigación de los efectos del cambio climático.

Tabla 25 Resultados para los escenarios de las tierras agropecuarias

Variable	**Value**					
	+15% Trend	**0% Trend**	**-20% Trend**	**-40% Trend**	**-60% Trend**	**-80% Trend**
Agriculture and Livestock Land available	68,356,762.95	79,769,545.14	75,711,537.75	70,053,687.06	69,687,992.58	72,444,716.21
Agriculture and Livestock yield	3340.84	3898.63	2574.12	1786.32	1776.99	615.76

La relación que existente entre la disponibilidad de tierras destinadas para el sector agrícola y pecuario y la vulnerabilidad se puede observar en la figura 30, a medida que la disponibilidad de tierras aumenta el rendimiento también crece y disminuye la vulnerabilidad de dicho recurso, de lo contrario, cuando la disponibilidad de tierras decrece la vulnerabilidad aumenta y el rendimiento decrementa.

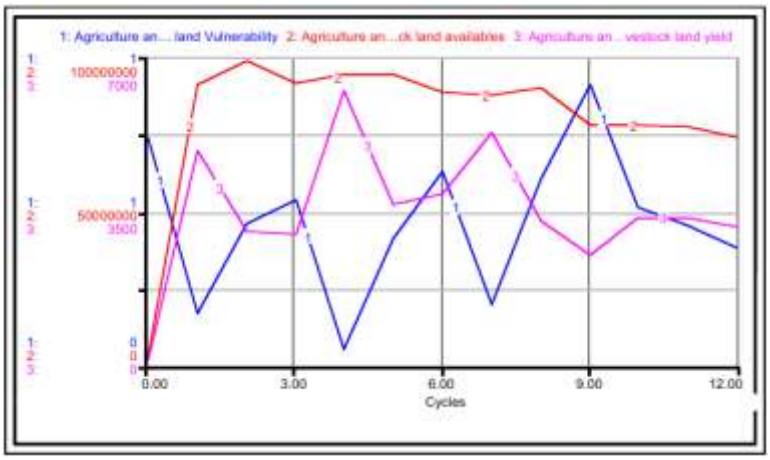


Figura 30 Vulnerabilidad y rendimiento de las tierras agropecuarias

4.1.3 Emisiones de gases de efecto invernadero

La agricultura y la ganadería son actividades que generan importantes emisiones de contaminantes al medio ambiente, contribuyendo significativamente a los gases de efecto invernadero (GEI), como el metano (CH_4) y el óxido nitroso (N_2O). En particular, un aumento en la producción de ganado y cultivos agrícolas, como la caña de azúcar, implica un incremento en las emisiones de dióxido de carbono (CO_2). Durante la cosecha de la caña, el CO_2 se libera principalmente a través de la quema de biomasa, un proceso integrado en el modelo de agentes inteligentes utilizado para analizar estos impactos.

Dado que las emisiones están directamente relacionadas con los niveles de producción agropecuaria, los escenarios evaluados consideran cambios proporcionales. Por ejemplo, un aumento del 15% en la producción agrícola y pecuaria generaría un incremento equivalente en las emisiones de GEI, mientras que una reducción en la producción de ganado y caña de azúcar resultaría en una disminución de dichas emisiones. La figura 31 ilustra los escenarios propuestos, mostrando las emisiones totales en gigatoneladas de CO_2. Los escenarios 1 y 2

presentan un comportamiento similar debido a la diferencia mínima del 15% entre ellos, mientras que los escenarios 3 al 6 reflejan una disminución del 20%, alineándose con los ajustes proyectados para los recursos hídricos y tierras agropecuarias.

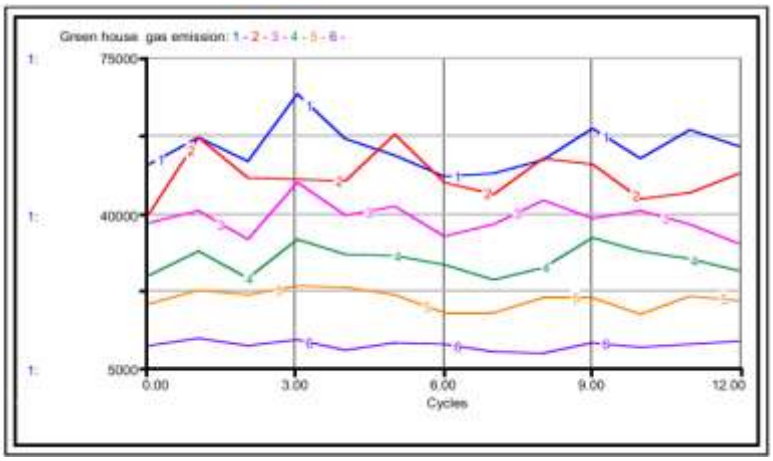


Figura 31 Escenarios para las emisiones de gases de efecto invernadero

Un incremento en la producción agrícola y pecuaria conlleva un aumento proporcional en las emisiones de gases de efecto invernadero al medio ambiente. En un escenario donde la industria agropecuaria crece un 15%, la vulnerabilidad asciende a 0.62, ubicándose dentro de los rangos considerados como alta vulnerabilidad. Por otro lado, una disminución en la producción agropecuaria impacta directamente en la reducción de emisiones de dióxido de carbono equivalente, expresadas en gigatoneladas, como se observa en la tabla 25.

Tabla 26 Resultados para los escenarios de gases de efecto invernadero

Variable	Value					
	+15% Trend	**0% Trend**	**-20% Trend**	**-40% Trend**	**-60% Trend**	**-80% Trend**
Green House Emission	58,565.59	58,143.71	56,774.80	50,454.49	47,287.37	18,091.06
Climatic Vulnerability	0.62	0.58	0.63	0.62	0.45	0.41

En la tabla 26 se presentan los resultados de una simulación realizada a lo largo de 12 ciclos, donde se detallan las variables clave de cada una de las redes de información modeladas. Estos resultados incluyen indicadores relacionados con

los recursos hídricos, las tierras agrícolas y pecuarias, así como las emisiones de gases de efecto invernadero.

Tabla 27 Resultados de la simulación

Variable		Water Volume available	Water resource efficiency	Land Available	Land Yield	GHG Emissions
Unit		Hm^3	Hg/m^3	Ha	Kg/Ha	$Gt\ CO_{2\ eq}$
Cycle:	1	4,077.82	0.96	3,513,953.04	3,577.06	48,832.48
	2	3,880.66	0.61	91,568,378.10	4,923.34	61,806.27
	3	3,460.97	0.41	100,936,286.57	3,091.28	56,717.80
	4	3,509.75	0.35	98,446,222.74	3,201.30	60,400.04
	5	3,516.67	0.25	96,151,103.38	6,346.13	56,087.68
	6	3,650.16	0.26	83,811,523.97	3,238.30	70,065.63
	7	4,038.91	0.23	86,178,073.38	3,785.68	51,471.68
	8	3,801.23	0.18	90,280,349.80	5,444.80	56,185.62
	9	3,391.94	0.15	84,675,284.40	3,090.37	60,799.43
	10	3,798.21	0.13	79,015,938.58	2,549.47	60,706.19
	11	2,786.83	0.11	81,441,286.48	3,491.91	58,330.12
	12	3,312.97	0.12	71,259,088.72	3,082.85	49,062.37

Los escenarios planteados subrayan la necesidad urgente de implementar medidas de adaptación en el sector agropecuario, abarcando tanto el cultivo de caña de azúcar como la producción de ganado bovino, porcino y avícola. Entre las estrategias clave se encuentran la tecnificación del riego, la gestión sostenible de los acuíferos y el uso de tecnologías eficientes, con el objetivo de reducir los impactos ocasionados por temperaturas extremas, escasez de agua y un aumento en la incidencia de plagas. Estas acciones deben centrarse en fortalecer la resiliencia de los sistemas agrícolas y pecuarios, promoviendo prácticas sostenibles que optimicen los recursos y disminuyan las emisiones contaminantes asociadas a estas actividades.

Además, las actividades agrícolas que dependen directamente de variables meteorológicas, como la temperatura y la precipitación, enfrentan una vulnerabilidad constante frente al cambio climático. En el caso del cultivo de caña de azúcar, su desarrollo está estrechamente condicionado por las fluctuaciones del clima, lo que genera un comportamiento altamente variable en su productividad.

4.2 Resultados modelo de riesgo agropecuario

Con el fin de evaluar cuantitativamente el desempeño de la red neuronal en la identificación de los colores característicos del producto satelital Tope de Nubes

del Servicio Meteorológico Nacional, se calculan métricas de precisión, recall y F1-score para cada una de las clases. Estos resultados permiten analizar la capacidad del modelo no solo en términos de exactitud global, sino también en el comportamiento individual de cada categoría, lo cual resulta fundamental para validar su utilidad en aplicaciones meteorológicas y agroclimáticas.

En la Figura 32 se presentan las curvas de pérdida (loss) y exactitud (accuracy) obtenidas durante el proceso de entrenamiento y validación de la red neuronal. En la gráfica de pérdida se aprecia una disminución progresiva en el conjunto de entrenamiento, lo que indica un aprendizaje estable y sostenido. La pérdida de validación, si bien presenta inestabilidad en las primeras iteraciones con picos que superan el valor de 2.5, posteriormente logra estabilizarse después de la época 10, convergiendo hacia valores bajos y similares a los de entrenamiento (≈0.2). Este comportamiento refleja que, a pesar de la fase inicial de oscilación, la red logra generalizar adecuadamente hacia los datos no vistos. Por su parte, la gráfica de exactitud muestra un incremento constante en el conjunto de entrenamiento, alcanzando niveles cercanos al 96%. La exactitud de validación, aunque con fluctuaciones en las primeras épocas, a partir de la época 12 mantiene valores superiores al 90%, llegando a ser muy cercanos a los del entrenamiento, lo cual confirma que no existe sobreajuste significativo y que el modelo logra un desempeño robusto.

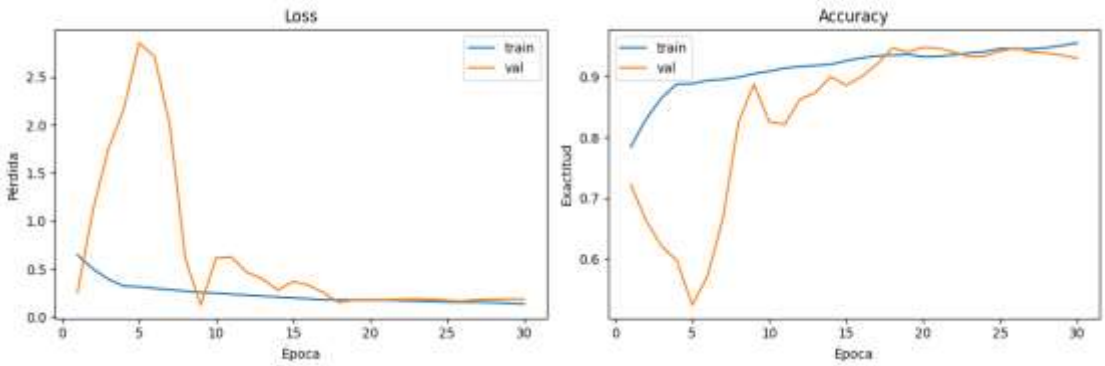


Figura 32 Curvas de pérdida y exactitud durante el entrenamiento y validación de la red neuronal convolucional aplicada al Tope de Nubes

La Tabla 28 presenta las métricas de evaluación por clase, calculadas en términos de precisión, recall y F1-score. Los resultados evidencian un comportamiento

sobresaliente en la clasificación de los colores derivados de las imágenes satelitales del producto Tope de Nubes del Servicio Meteorológico Nacional. La clase Blue alcanzó valores de 0.99 en todas las métricas, evidenciando la alta capacidad del modelo para reconocer correctamente este tipo de nubosidad. Las clases OrangeRed y Magenta también reportan desempeños elevados, con métricas de 0.99 y 0.94 respectivamente, lo cual refleja una adecuada discriminación en condiciones de nubosidad baja y ausencia de nubosidad. Para las clases con mayor variabilidad, como Cyan, Green y Yellow, los valores se mantienen en torno a 0.90–0.93, lo cual indica una detección confiable, aunque con ligeras confusiones en los límites de transición entre tonalidades. En términos globales, el modelo alcanza una exactitud del 96%, con promedios macro y ponderado de 0.95 y 0.96 respectivamente, lo que demuestra un equilibrio satisfactorio entre las distintas categorías, sin que una clase en particular domine el aprendizaje del modelo.

Tabla 28 Métricas de evaluación por clase en la clasificación de colores Tope de Nubes.

Clase	Precisión	Recall	F1-score	Soporte
Blue	0.99	0.99	0.99	524
Cyan	0.93	0.93	0.93	13
Green	0.9	0.9	0.9	182
Magenta	0.94	0.94	0.94	2
OrangeRed	0.99	0.99	0.99	179
Yellow	0.93	0.93	0.93	44
Accuracy			0.96	944
Macro avg	0.95	0.95	0.95	944
Weighted avg	0.96	0.96	0.96	944

Por su parte, la Figura 33 muestra la matriz de confusión normalizada, donde se aprecia la distribución de aciertos y errores por clase. El modelo logra identificar correctamente la gran mayoría de instancias, evidenciando valores de 0.99 en la diagonal principal para las clases Blue y OrangeRed, así como 0.93 en Cyan y Yellow, y 0.90 en Green. La clase Magenta presenta un desempeño también

elevado (0.94), confirmando que el modelo no presenta problemas de detección en categorías con menor representación. Los errores de clasificación se concentran en proporciones mínimas y en transiciones esperadas, como entre Cyan–Blue o Green–Yellow, lo cual es consistente con la naturaleza espectral de las imágenes satelitales y con los rangos de temperatura y nubosidad que estas tonalidades representan.

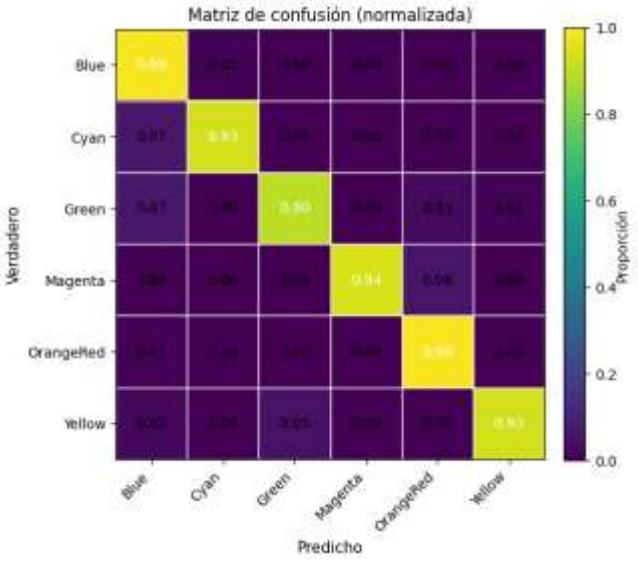


Figura 33 Matriz de confusión normalizada de la clasificación de colores Tope de Nubes.

4.3 Resultados de modelo difuso riesgo agrícola y pecuario

4.3.1 Superficies difusas del sector pecuario

En el caso del sector pecuario, los resultados del sistema difuso se enfocan en la estimación del riesgo para la salud animal (LSHR, Livestock Health Risk) en función de variables climáticas clave. Particularmente, se analizan los efectos combinados de la amplitud térmica, la velocidad del viento y humedad, parámetros que influyen directamente en el balance térmico y en la susceptibilidad del ganado a enfermedades respiratorias y estrés calórico.

Modelo difuso LSHR (Livestock Health Risk), respecto a Viento y amplitud térmica.

La Figura 34 presenta la superficie de salida del sistema difuso para la variable LSHR (Livestock Health Risk) en función de la amplitud térmica (Amplitud_T) y

la velocidad del viento (Viento), para analizar de manera conjunta los efectos de la variabilidad térmica y la circulación de aire sobre la probabilidad de afectaciones en el ganado.

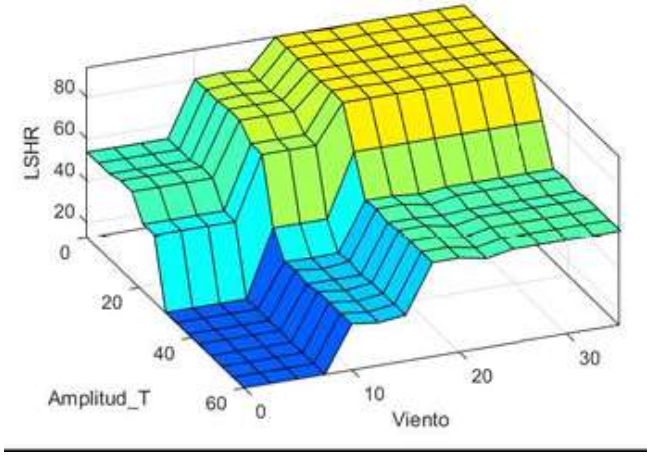


Figura 34 Superficie difusa de riesgo pecuario (LSHR) en función de amplitud térmica y velocidad del viento

El sistema proyecta valores de riesgo que oscilan entre 0 y 100, donde 0 representa ausencia de riesgo y 100 corresponde a condiciones críticas para la salud animal. Se observa que:

1. Condiciones de baja amplitud térmica (<20 °C) y viento reducido (<10 km/h): el riesgo estimado se mantiene en rangos bajos (LSHR ≈ 20–30), lo que sugiere un ambiente estable donde la homeotermia del ganado no se ve comprometida.
2. Escenarios de amplitud térmica intermedia (20–40 °C) con vientos de 10–15 km/h: el riesgo se incrementa de manera notable, alcanzando valores entre 40 y 60, reflejando un mayor nivel de estrés fisiológico.
3. Situaciones de amplitud térmica elevada (>40 °C) y viento superior a 20 km/h: el sistema estima un riesgo alto (LSHR > 70), llegando en los casos más extremos a valores cercanos al 90–95. Estas condiciones representan un escenario crítico, pues la combinación de fuertes contrastes térmicos con corrientes de aire intensas favorece la pérdida excesiva de calor corporal y aumenta la vulnerabilidad a enfermedades respiratorias.

Estos resultados concuerdan con observaciones epidemiológicas previas que relacionan climas fríos, ventosos y con elevada amplitud térmica con una mayor incidencia de afecciones respiratorias en bovinos y porcinos. En ambientes cálidos, por el contrario, una alta amplitud térmica combinada con sequedad y viento favorece estados de estrés calórico y deshidratación, con repercusiones en el bienestar y en los indicadores productivos. La amplitud térmica y el viento actúan de forma sinérgica en la determinación del riesgo pecuario.

Modelo difuso LSHR (Livestock Health Risk), respecto a amplitud térmica y humedad.

La Figura 35 muestra la superficie generada por el sistema difuso para la variable LSHR (Livestock Health Risk) en función de la amplitud térmica (°C) y la humedad relativa (%).

Para valores de baja amplitud térmica (<10 °C) y baja humedad (<20 %): el sistema estima un riesgo intermedio, con valores de LSHR ≈ 65–70. Estas condiciones se asocian a ambientes secos y relativamente estables, donde el ganado no enfrenta un contraste térmico marcado, aunque la baja humedad puede generar irritación en mucosas respiratorias.

Amplitud térmica intermedia (15–30 °C) con humedad de 20–30 %: el riesgo disminuye a valores mínimos (LSHR ≈ 55–60), lo que representa un escenario favorable para la salud animal. Esto indica que una humedad moderada ayuda a amortiguar los efectos del cambio de temperatura, reduciendo el estrés fisiológico.

Alta amplitud térmica (>30 °C) con humedad elevada (>35 %): el riesgo se incrementa de forma considerable, alcanzando valores de LSHR ≈ 85–90. Esta situación refleja el impacto de la combinación entre contrastes térmicos intensos y humedad alta, la cual limita la evaporación del sudor y dificulta la termorregulación en los animales, generando estados de estrés calórico.

Regiones extremas de baja humedad con amplitud térmica alta: el modelo también proyecta riesgos altos (LSHR > 80), debido a que la sequedad, sumada a los

cambios bruscos de temperatura, puede favorecer deshidratación y comprometer la resistencia inmunológica del ganado.

La humedad actúa como un modulador del riesgo: en valores intermedios ayuda a estabilizar la respuesta fisiológica, pero en valores extremos (muy baja o muy alta) potencia los efectos negativos de la amplitud térmica.

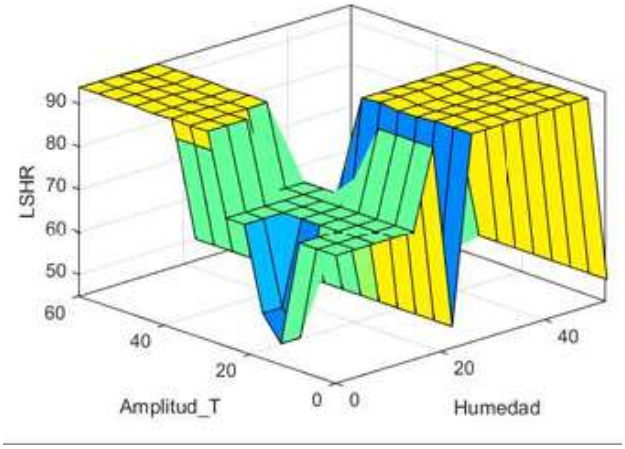


Figura 35 Superficie difusa de riesgo pecuario (LSHR) en función de Amplitud Térmica y Humedad

Por su parte, la Figura 36 presenta la superficie del sistema difuso que estima el riesgo para la salud pecuaria (LSHR) a partir de la velocidad del viento y la humedad relativa. El patrón general muestra que el viento es el principal disparador del riesgo, mientras que la humedad actúa como modulador. Bajo condiciones de viento bajo (≈0–5 km/h) y humedad intermedia (≈20–35 %), el modelo proyecta un entorno fisiológicamente tolerable, con LSHR en torno a 20–30. A medida que el viento aumenta a rangos moderados (≈10–15 km/h) en presencia de sequedad (<20 %), el riesgo se eleva a valores medios (≈40–50), reflejando la mayor pérdida de calor corporal por convección y la irritación de vías respiratorias asociada al aire seco. En escenarios de vientos intensos (>20 km/h) combinados con baja humedad (<15 %), el sistema estima condiciones críticas con LSHR por encima de 70 y picos que se aproximan a 85–90, compatibles con estrés respiratorio y térmico significativo.

Cuando la humedad es alta (>40 %) y el viento permanece bajo o moderado, la respuesta tiende a amortiguarse y el riesgo desciende nuevamente hacia 20–25, aunque el ambiente puede resultar térmicamente incómodo. No obstante, si la

humedad elevada coincide con vientos fuertes, el modelo vuelve a incrementar la vulnerabilidad hasta niveles medios (≈40–50), evidenciando que la acción del viento puede anular parcialmente el efecto estabilizador de la humedad. Esta lectura respalda decisiones de manejo orientadas a mitigar la exposición del ganado a rachas intensas —en particular durante episodios secos— y a priorizar resguardos microclimáticos que mantengan la humedad ambiental en rangos moderados.

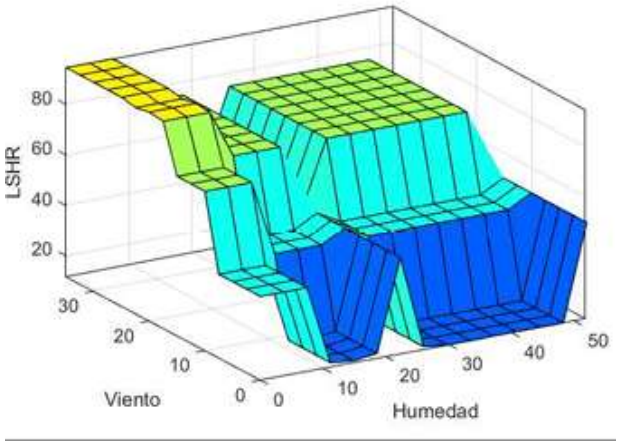


Figura 36 Superficie difusa de riesgo pecuario (LSHR) en función de Humedad y viento

4.3.2 Proyecciones del valor de la producción pecuaria

Para contextualizar los hallazgos del componente pecuario, primero se integró una base histórica del valor de la producción pecuaria de Veracruz a partir del Cierre de la Producción Ganadera (SIAP). Las cifras se digitalizaron y normalizaron en miles de pesos corrientes, verificando consistencia entre subtotales por especie (bovino, porcino, ovino, caprino y aves) y el total estatal. La base de datos cubre el periodo largo 1980–2021 y, para el análisis gráfico principal, se enfatiza el tramo reciente 2011–2021 (más actual).

La Figura 37 resume la trayectoria del valor de la producción pecuaria de Veracruz a partir de los cierres anuales del SIAP. Entre 2011 y 2021 se observa una tendencia creciente sostenida, con un incremento acumulado cercano a 2.6 veces (de ~19 mil millones a ~50 mil millones de pesos). El ascenso no es homogéneo: tras avances graduales entre 2014–2019, en 2021 se registra un salto

que consolida el máximo de la serie analizada. Estas cifras son nominales, por lo que el crecimiento integra tanto cambios de volumen como de precios.



Figura 37 Veracruz: Valor de la producción pecuaria (miles de pesos), observado y proyecciones cortas (lineal y SES, 2011–2024).
Fuente: Elaboración propia con datos del SIAP, Cierre de la Producción Ganadera

la distribución de la producción pecuaria esta distribuida principalmente por ganado Bovino que aporta 44.7% del total, Aves 39.2%, y Porcino 14.7%; los pequeños rumiantes (Ovino y Caprino) suman alrededor de 1%, mientras que Guajolote representa 0.2%. En conjunto, las dos especies líderes (bovino y aves) concentran ~84% del valor (Figura 38).

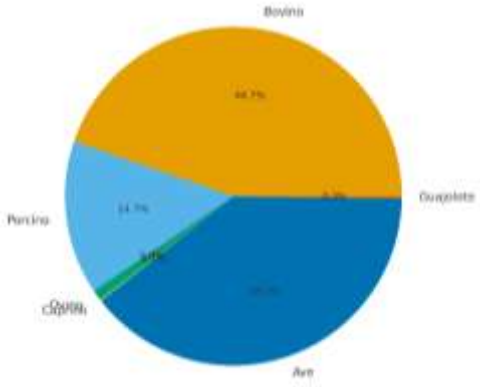


Figura 38 Valor pecuario por especie
Fuente: Elaboración propia con SIAP–SADER, Cierre de la Producción Ganadera

La figura 39 muestra proyecciones del valor pecuario 2022–2030 sin ajuste de riesgo, obtenidas con distintos métodos de extrapolación y usadas como línea base para la planeación. Este escenario no considera choques sanitarios o climáticos. El ajuste por riesgo derivado del modelo difuso (amplitud térmica, humedad y viento) es de utilidad para obtener bandas realistas —escenario medio y conservador—, cuantificar la pérdida esperada y priorizar medidas de gestión del riesgo.



Figura 39 Proyecciones del valor de la producción sin Riesgo hasta 2030

La figura 40 resume, para cada año, los indicadores generados por el modelo difuso (riesgo_media, riesgo_p95, share_alto) y su efecto sobre el valor base mediante el factor (1−β R). A partir de esa base se obtiene el valor ajustado y dos bandas: conservadora (usa P95) y optimista (riesgo bajo). En conjunto, los riesgos se sitúan en niveles moderado–alto y se traducen en mermas de ~8–12% respecto a la base (y 12–18% en el escenario conservador).

riesgo_media	riesgo_p95	riesgo_share_alto	base_miles	ajuste_riesgo	base_ajustada_miles	escenario_conservador_miles	escenario_alto_miles
0.473968	0.752863	0.083333	1.982361e+07	0.905206	1.722030e+07	1.615918e+07	1.767113e+07
0.538363	0.794160	0.250000	2.149811e+07	0.892327	1.918335e+07	1.808352e+07	1.976204e+07
0.547389	0.748300	0.083333	2.331506e+07	0.890522	2.076258e+07	1.906383e+07	2.140070e+07
0.544887	0.818193	0.333333	2.617950e+07	0.891023	2.332652e+07	2.189552e+07	2.481977e+07
0.382695	0.692782	0.083333	2.692815e+07	0.923461	2.486710e+07	2.319708e+07	2.538236e+07
0.554725	0.739331	0.083333	2.746803e+07	0.889055	2.441425e+07	2.340836e+07	2.517591e+07
0.484303	0.655533	0.000000	3.016658e+07	0.903139	2.724463e+07	2.621155e+07	2.797512e+07
0.503640	0.779410	0.250000	3.298182e+07	0.899272	2.965963e+07	2.784714e+07	3.049018e+07
0.428675	0.739224	0.083333	3.428057e+07	0.914265	3.134152e+07	2.921236e+07	3.287628e+07
0.523202	0.661954	0.000000	3.651174e+07	0.895360	3.269114e+07	3.167792e+07	3.364629e+07
0.373419	0.601946	0.083333	5.010196e+07	0.925316	4.636016e+07	4.326859e+07	4.729561e+07
0.447978	0.666467	0.000000	4.432353e+07	0.910404	4.035240e+07	3.841555e+07	4.134520e+07
0.448428	0.760021	0.166667	4.673437e+07	0.910316	4.254305e+07	3.963851e+07	4.359083e+07
0.538152	0.835923	0.333333	4.914515e+07	0.892170	4.385564e+07	4.092804e+07	4.517802e+07
0.486388	0.652674	0.000000	5.155593e+07	0.902724	4.654078e+07	4.482618e+07	4.779457e+07

Figura 40 Calculo de riesgo y ajuste de valor de producción pecuaria en diferentes escenarios

La Figura 41 presenta la trayectoria observada 2011–2021 y tres bandas de proyección para 2022–2030: base (sin riesgo), ajuste medio (riesgo anual promedio del modelo difuso) y ajuste conservador (riesgo anual P95). El ajuste se implementó mediante el esquema multiplicativo $V_t^{aj} = V_t^{base}(1 - \beta R_t)$

Donde R_t proviene del sistema difuso (entradas: amplitud térmica, humedad y viento) y β es la sensibilidad calibrada con 2011–2021. Esta formulación mantiene la inercia productiva que recoge la proyección base, pero descuenta el deterioro esperado por condiciones sanitarias y climáticas.

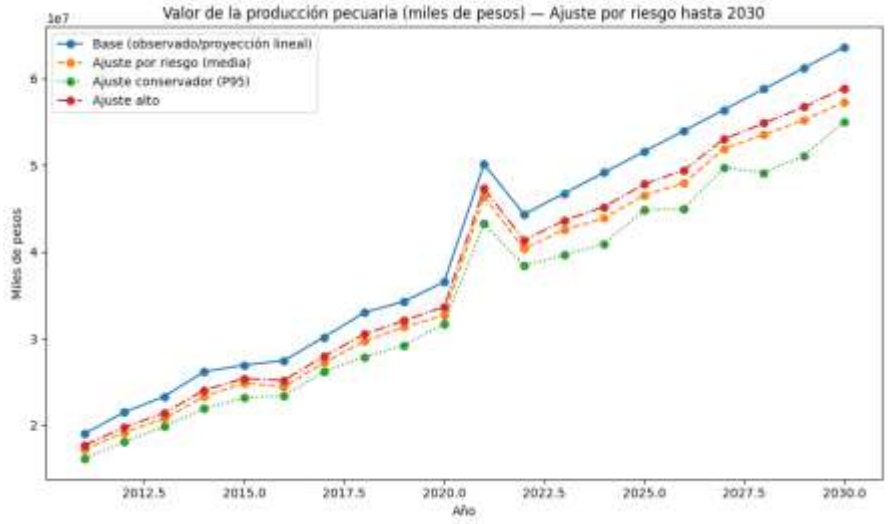


Figura 41 Proyección del valor de la producción pecuaria 2011–2030 con ajuste por riesgo sanitario-climático

Crecimiento esperado

Partiendo del retroceso de 2022 respecto a 2021, la proyección base se recupera y asciende de ~44 a 64 mil millones de pesos hacia 2030 (crecimiento anual compuesto ≈ 4.8%). Las trayectorias ajustadas por riesgo mantienen una pendiente positiva pero más moderada: el escenario medio pasa de ~41 a 57 mil millones (≈4.2% anual), mientras que el conservador lo hace de ~39 a 55 mil millones (≈4.0–4.3%). Así, el riesgo no revierte el crecimiento esperado, pero reduce el ritmo y el nivel proyectado.

Castigo por riesgo

La separación entre la línea base y el ajuste medio equivale a una merma esperada de alrededor de 8–12% del valor anual; en el escenario conservador (P_{95})la reducción se amplía típicamente a 12–18%, reflejando meses pico con humedad

relativa alta combinada con amplitud térmica o viento elevados. El ajuste alto (optimista) acota la banda superior cuando las condiciones de manejo/mitigación reducen efectivamente el riesgo.

La separación entre la proyección base y la ajustada por riesgo es mayor cuando en un año hay más meses con riesgo alto. Eso es lo que ocurre justo después del salto de 2021: en 2022–2023 el modelo difuso registra un share_alto elevado, por lo que el ajuste $(1 - \beta R_t)$ descuenta más y la brecha base–ajustada se ensancha. Conforme avanza el horizonte, share_alto disminuye, el riesgo anual R_t baja y el descuento es menor, de modo que las dos trayectorias vuelven a acercarse. Operativamente, esto implica que las acciones de mitigación (bioseguridad, manejo de humedad y ventilación, refuerzo del calendario sanitario) deben priorizarse en los primeros años del periodo proyectado, cuando el riesgo concentrado en varios meses tiene mayor impacto económico sobre el valor de la producción.

4.3.2 Superficies difusas para el sector agrícola (Probabilidad de enfermedades en el cultivo de caña de azúcar)

En el caso del sector agrícola, se desarrollaron superficies difusas orientadas a estimar la probabilidad de aparición de enfermedades en el cultivo de caña de azúcar a partir de variables climáticas relevantes. Estas superficies permiten visualizar de manera integral la interacción entre factores ambientales y su efecto sobre la vulnerabilidad del cultivo, constituyendo una herramienta para anticipar y/o mitigar escenarios de riesgo.

La superficie obtenida del sistema difuso para la variable SCDP (SugarCane Disease Probability) en función de la humedad relativa y la velocidad del viento (Figura 37) refleja cómo la interacción entre estos factores climáticos determina la susceptibilidad del cultivo de caña de azúcar a la presencia de enfermedades. En condiciones de humedad baja a moderada (≈10–30 %) y viento reducido (<10 km/h), la probabilidad de enfermedad se mantiene en niveles bajos a intermedios, con valores cercanos a 20–40 %, lo que indica un entorno menos favorable para el desarrollo de patógenos. Sin embargo, cuando la humedad relativa se

incrementa por encima del 30–40 %, el riesgo comienza a elevarse progresivamente, especialmente si coincide con vientos intermedios que facilitan la dispersión de esporas y microorganismos.

La combinación de altos niveles de humedad (>40 %) con vientos moderados o intensos genera una probabilidad máxima de enfermedad, con valores cercanos al 90 %. Este resultado coincide con la dinámica epidemiológica observada en cultivos tropicales, donde la permanencia de humedad en follaje y suelo, sumada al movimiento del aire, crea condiciones idóneas para la propagación de hongos y bacterias. Por el contrario, en escenarios de alta humedad, pero viento muy bajo, el riesgo tiende a estabilizarse en niveles intermedios, lo que sugiere que la saturación ambiental por sí sola no es suficiente para detonar los valores más altos de riesgo, sino que requiere la acción conjunta del viento como factor de dispersión.

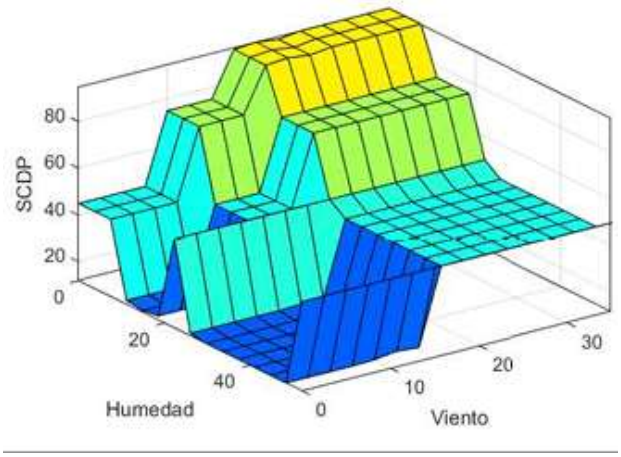


Figura 42 Superficie difusa de probabilidad de enfermedades en caña de azúcar (SCDP) en función de humedad y viento

La probabilidad de enfermedades en caña de azúcar (SCDP) en función de la humedad relativa y la amplitud térmica (Figura 38) refleja cómo la interacción entre estos dos factores climáticos determina la vulnerabilidad del cultivo frente a la aparición de patógenos.

En escenarios de humedad baja (<20 %) y amplitud térmica reducida (<15 °C), el riesgo de enfermedad permanece en valores bajos, con probabilidades cercanas al 10–20 %, lo cual corresponde a un ambiente poco favorable para el desarrollo de

organismos fitopatógenos. Sin embargo, cuando la humedad se incrementa hacia valores intermedios (20–40 %), aun con amplitudes térmicas moderadas (15–30 °C), la probabilidad de enfermedad se eleva de forma progresiva, alcanzando niveles de 50–70 %, lo que indica condiciones de riesgo medio asociadas a un ambiente más propicio para la germinación y propagación de esporas.

El comportamiento más crítico se observa en condiciones de alta humedad (>40 %) combinada con amplitudes térmicas intermedias o elevadas (20–40 °C), donde el modelo estima una probabilidad máxima de enfermedad superior al 80–90 %. Estas condiciones representan el escenario más favorable para la proliferación de hongos y bacterias, dado que la humedad elevada mantiene el follaje húmedo y la amplitud térmica contribuye a la variación de microclimas dentro del dosel de la caña, facilitando el desarrollo de infecciones. Por el contrario, cuando la amplitud térmica es muy alta (>45 °C) y la humedad relativa disminuye, la probabilidad desciende a niveles bajos (<30 %), lo que sugiere que la sequedad ambiental y el calor extremo limitan la supervivencia de los patógenos. Los resultados muestran que la humedad es el factor predominante en la determinación del riesgo de enfermedades, mientras que la amplitud térmica actúa como un modulador que intensifica o reduce dicho efecto.

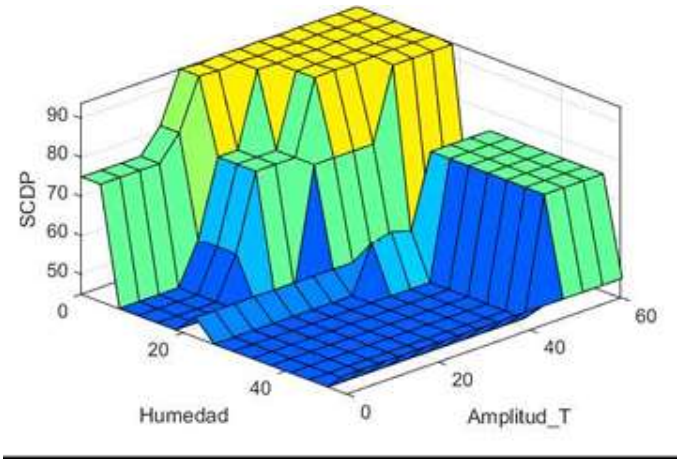


Figura 43 Superficie difusa de probabilidad de enfermedades en caña de azúcar (SCDP) en función de humedad y amplitud térmica

Por su parte, la superficie difusa correspondiente a la probabilidad de enfermedades en caña de azúcar (SCDP) en función de la amplitud térmica y la

velocidad del viento muestra que en condiciones de amplitud térmica baja (<15 °C) y viento reducido (<10 km/h), la probabilidad de enfermedad se mantiene en niveles bajos (≈20–30 %), lo que representa un escenario estable con menor riesgo de proliferación de patógenos. Conforme la amplitud térmica aumenta hacia valores intermedios (20–35 °C), el riesgo comienza a intensificarse, en especial cuando coincide con vientos moderados (10–15 km/h), alcanzando probabilidades entre 50 y 70 %.

El comportamiento más crítico se observa en zonas de alta amplitud térmica (>40 °C) combinada con vientos intermedios o altos, donde la probabilidad de enfermedad se eleva hasta valores cercanos a 80 %, lo que sugiere que la variación térmica intensa, junto con la dispersión de esporas facilitada por el viento, constituye un entorno altamente favorable para la propagación de enfermedades. No obstante, cuando la amplitud térmica es muy alta y coincide con vientos bajos, el riesgo se atenúa, descendiendo a niveles medios (~40 %), lo que indica que la acción del viento es determinante para que la amplitud térmica tenga un efecto crítico sobre el cultivo. En síntesis, esta superficie confirma que la amplitud térmica es un factor desencadenante del riesgo de enfermedades en la caña de azúcar, pero su efecto se ve amplificado por la acción del viento, que actúa como vehículo de dispersión. Figura 39.

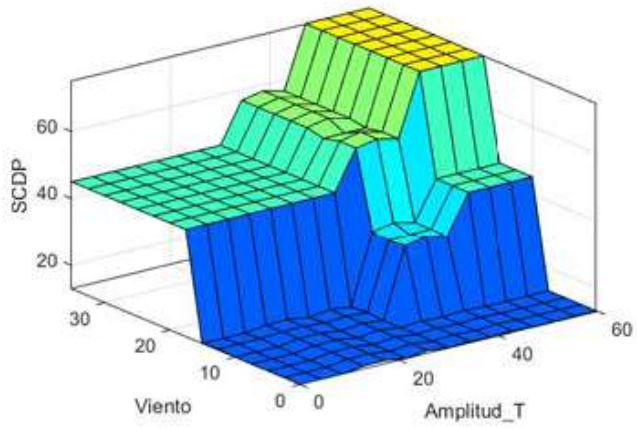


Figura 44 Superficie difusa de probabilidad de enfermedades en caña de azúcar (SCDP) en función de amplitud térmica y viento

Las superficies difusas construidas permiten evidenciar que variables climáticas como la humedad relativa, la amplitud térmica y la velocidad del viento actúan de

manera conjunta en la determinación de la probabilidad de enfermedades en caña de azúcar. Los resultados muestran que condiciones de alta humedad combinada con amplitudes térmicas intermedias y la presencia de vientos moderados o intensos generan escenarios de máxima vulnerabilidad, con probabilidades superiores al 80–90 %, lo que coincide con la epidemiología de enfermedades como rust, red rot, yellow leaf y mosaic, todas ellas favorecidas por ambientes húmedos y dinámicas de dispersión aérea. Por el contrario, situaciones de baja humedad o vientos reducidos tienden a limitar la incidencia, reduciendo las probabilidades de enfermedad a niveles bajos o moderados.

4.3 Resultados modelo RNA-FIS

En una primera etapa, el modelo basado en imágenes satelitales y variables climáticas estima la probabilidad de condiciones conducentes a enfermedad en caña (P_{riesgo}), cuando (P_{riesgo}) supera un umbral operativo (de acuerdo a las condiciones climáticas del lugar) el sistema activa la evaluación foliar del cultivo de caña de azúcar por medio de la red convolucional (Versión 7.2 Stable) para confirmar y tipificar la enfermedad a partir de imágenes foliares (Mosaic, Red Rot, Rust, Yellow).

4.3.1 Resultados generales de las versiones RNA

Durante el desarrollo experimental se trabajaron diferentes versiones de la red neuronal convolucional (CNN), cada una con ajustes progresivos en preprocesamiento, arquitectura y técnicas de entrenamiento. El objetivo fue alcanzar un modelo con estabilidad en las curvas de aprendizaje y un desempeño superior al 90% de accuracy global. A continuación, se describen las versiones y los resultados obtenidos en cada una de ellas, además de la elección de la red con mejor rendimiento para la clasificación de enfermedades foliares de caña de azúcar.

versión 1: sin generadores de datos

El desempeño global fue moderado (accuracy y F1-macro ≈ 0.77, n=505) y heterogéneo por clase: Saludable mostró alto recall (0.93) pero baja precisión (0.64), indicando sobre predicción de la clase mayoritaria; Yellow exhibió el

patrón inverso (precision 0.94, recall 0.72), es decir, detección que omite casos; Red Rot y Rust tuvieron un rendimiento intermedio (F1 ≈ 0.82 y 0.78); y Mosaic fue la clase más débil (F1 = 0.66; recall = 0.58), sujeta a confusiones. Este perfil sugiere sub-ajuste y desbalance entre clases y condiciones de iluminación/color, por lo que se recomendaron ajustes posteriores: reequilibrio (class weights/Focal Loss), augmentación focal para Mosaic/Yellow, preprocesamiento de contraste/color (p. ej., CLAHE) y fine-tuning más profundo con arquitecturas ligeras.

La figura 40 muestra la matriz de confusión (eje vertical: etiqueta verdadera; eje horizontal: predicción), donde la diagonal representa aciertos y las celdas fuera de la diagonal los errores. Se observa buen desempeño en Saludable (98 aciertos) y Red Rot (88), aunque Red Rot se confunde a veces con Rust (11). Rust presenta confusiones con Red Rot (12) y Saludable (11). Yellow logra 73 aciertos, con errores principalmente hacia Saludable (9) y Mosaic (8). El patrón más crítico es Mosaic → Saludable (34), consistente con la menor sensibilidad reportada para Mosaic en esta versión.

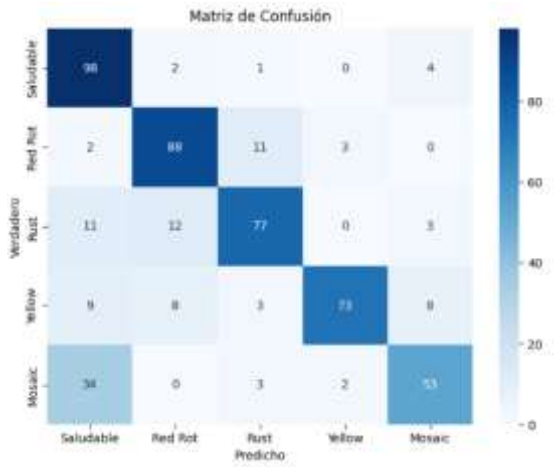


Figura 45 Matriz de confusión, RNA sin generadores de datos

Versión 2: Generadores y aumento de datos para entrenamiento y validación

La precisión aumenta en entrenamiento hasta ~0.91, mientras la validación es menor y oscilante (pico ~0.75 en la época 5), evidenciando sobreajuste a partir de las épocas 5–6 aproximadamente y sugiriendo *early stopping* cerca de la época 5

(Figura 41). La matriz de confusión (figura 42) concentra aciertos en la diagonal (mejor en *Saludable* y *Red Rot*) y revela los errores clave: confusiones Mosaic → Saludable, cruces Red Rot ↔ Rust, y algunos desvíos de Yellow hacia *Saludable/Mosaic*. En conjunto, la brecha de generalización observada en la curva se manifiesta en errores fuera de la diagonal, especialmente en clases visualmente cercanas o menos representadas, motivando mayor regularización y augmentación focal por clase en versiones posteriores.

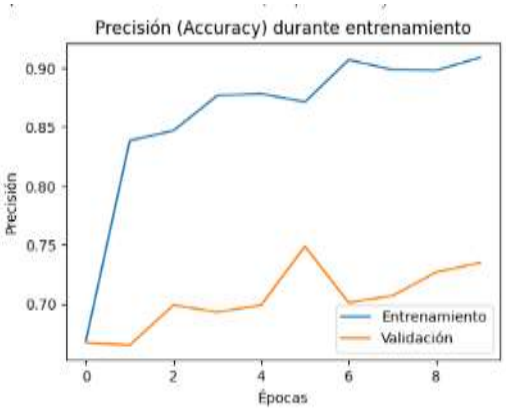


Figura 46Curva de entrenamiento/ Validación RNA generadores y aumento de datos

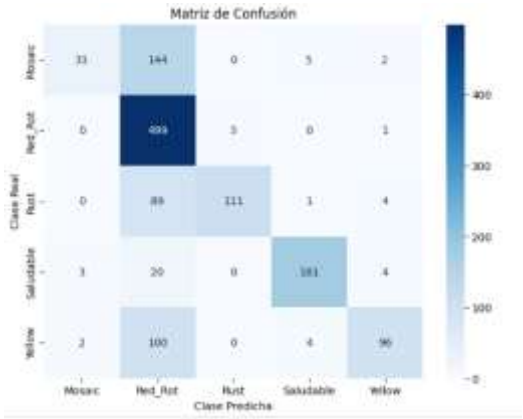


Figura 47Matriz de confusión RNA generadores y aumento de datos

Versiones 3-5 EfficientNetB0, filtros, aumento de datos

En V3 la validación supera sistemáticamente a entrenamiento y presenta alta variabilidad (picos ~0.78–0.81 y caídas abruptas), mientras el entrenamiento asciende lentamente (~0.53→0.64). Este patrón sugiere sub-ajuste con augmentación/regularización fuerte en entrenamiento y posible tamaño reducido de validación que amplifica el ruido (Figura 43). V4 repite la dinámica de V3, con leve suavizado y una ganancia marginal en entrenamiento (~0.64) y validación (~0.81 en el mejor punto), por lo que el mejor *checkpoint* se mantiene en torno a época 5 (Figura 44). En V5 (figura 45) las curvas se estabilizan a lo largo de 50 épocas: entrenamiento crece de ~0.24 a 0.75 y validación converge de ~0.32 a 0.83–0.84, manteniéndose consistentemente por encima de entrenamiento; no hay señales de sobreajuste, sino un ligero subajuste residual (gap inverso) atribuible a la severidad de la augmentación y/o a una base convolucional aún poco afinada.

Operativamente, V5 representa un salto de estabilidad y generalización frente a V3–V4; el *checkpoint* óptimo se ubica hacia épocas 35–48, y puede afinarse liberando más capas para *fine-tuning* y ajustando la severidad de augmentación para cerrar la brecha inversa. Las matrices de confusión complementarán estos hallazgos identificando las clases con mayor confusión residual.

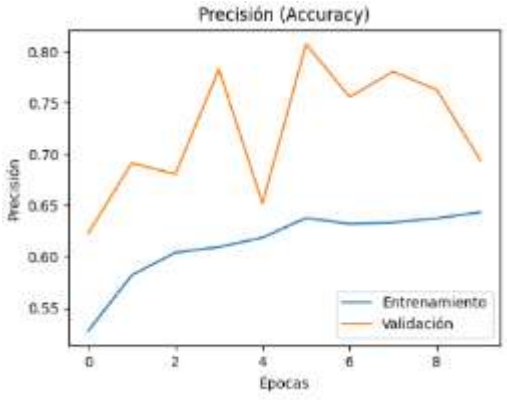


Figura 48 Curvas de entrenamiento y validación versión 3

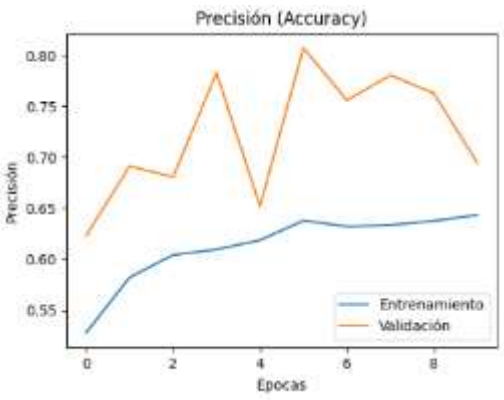


Figura 49 Curvas de entrenamiento y validación versión 4

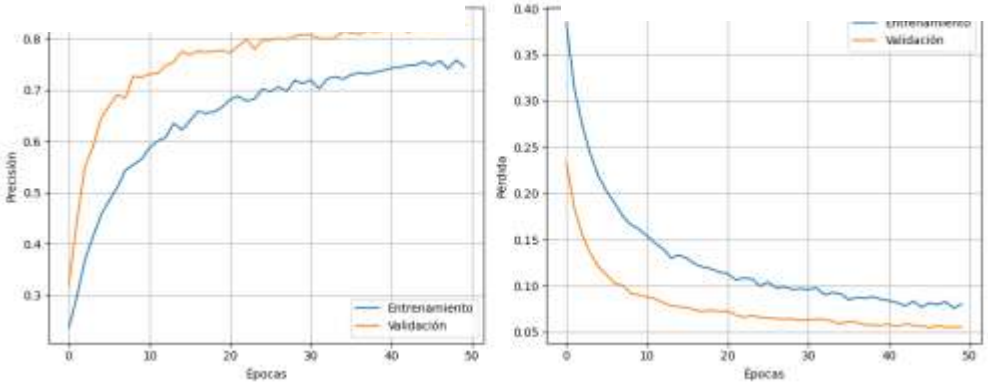


Figura 50 Curva de entrenamiento, validación y perdida versión 5 MobileNetV2

En la Versión 5 se obtuvo accuracy = 0.82 (macro F1 = 0.81, weighted F1 = 0.82, *n*=798). Por clase, Rust fue la más sólida (F1 = 0.87, *recall* = 0.92), seguida de Mosaic, Saludable y Yellow (F1 ≈ 0.81), mientras Red_rot quedó rezagada (F1 = 0.76). La tabla 28 muestra las métricas de análisis para la predicción de las diferentes clases

Tabla 29 métricas de predicción V5

class	precision	recall	f1_score	support
Mosaic	0.87	0.76	0.81	184
Red_rot	0.76	0.76	0.76	103
Rust	0.82	0.92	0.87	205
Saludable	0.79	0.85	0.81	104
Yellow	0.83	0.8	0.81	202
accuracy			0.82	798
macro avg	0.81	0.82	0.81	798
weighted avg	0.82	0.82	0.82	798

La matriz de confusión (Figura 46) confirma estos patrones, muestra aciertos altos en Rust y Yellow; Mosaic logra 140 aciertos, pero se confunde sobre todo con Yellow y Saludable; Red_rot presenta su mayor fuga hacia Rust; Saludable registra 88 aciertos con desvíos menores a Mosaic (5) y Yellow (6). En términos operativos, el recall (sensibilidad) —*proporción de verdaderos positivos detectados*— explica los frentes de mejora: Mosaic y Red_rot (ambos *recall* = 0.76) aún omiten ~24% de sus casos, por lo que conviene reforzar la augmentación específica y el *fine-tuning* dirigido a sus patrones visualmente confusos.

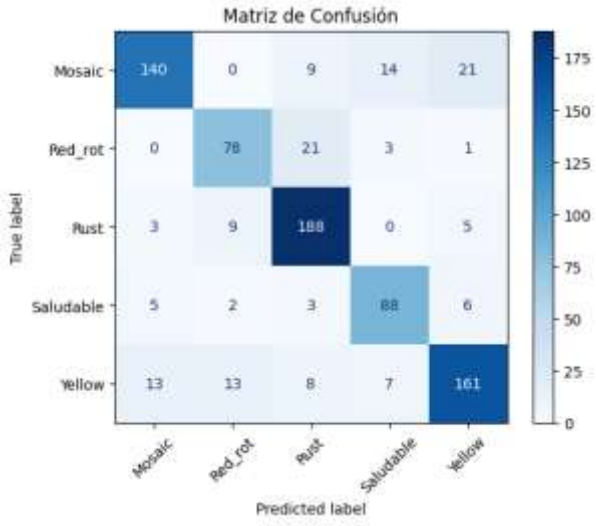


Figura 51 Matriz de confusión V5

La tabla 29 resume la evolución de los modelos a través de iteraciones sucesivas. V1 opera como línea base (~55%) sin técnicas avanzadas. Con V2 (EfficientNetB0 + CLAHE/filtros) no se logró generalización (~26%), evidenciando desajuste entre capacidad y datos. Al migrar a MobileNetV2 (V3) y

activar Focal Loss con preprocesamiento orientado a bordes, la precisión sube a ~69%. Finalmente, V5 integra aumentos focalizados + Focal Loss sobre MobileNetV2 y alcanza 82%, con mejor equilibrio entre clases.

Tabla 30 Resumen de los modelos V1-V5

Versión	Arquitectura	Preprocesamiento	Focal Loss	Accuracy	Observaciones
V1	CNN personalizada	Ninguno	No	~55%	Modelo base sin técnicas avanzadas
V2	EfficientNetB0	CLAHE + filtros	No	~26%	Modelo sobreajustado y poco generalizable
V3	MobileNetV2	CLAHE + bordes	Sí	~69%	Mejora considerable
V5	MobileNetV2	Aumentos focalizados	Sí	82%	Modelo óptimo y balanceado pero aun con rendimiento bajo

versión 6: Ajuste de optimización

La Versión 6 se entrenó sobre MobileNetV2 con una cabeza adicional (*Dropout* + *Dense*), incorporando preprocesamiento de realce (CLAHE y suavizado) especialmente en clases problemáticas (Mosaic, Rust) y normalización de imágenes. El aumento de datos combinó rotación, traslación y zoom, con augmentación focalizada en las clases de menor desempeño. La optimización se realizó con Adam y *callbacks* de EarlyStopping y ReduceLROnPlateau. Con este pipeline, la validación alcanzó ~88–89% de precisión y ECM ≈ 0.12–0.14, respaldado por la matriz de confusión por clase que se presenta a continuación.

Alcanza buen desempeño final, las curvas (figura 47 y 48) evidencian un episodio atípico de inestabilidad: en las primeras ~10 épocas el *accuracy* de entrenamiento y validación crece, pero al iniciar el *fine-tuning* (épocas ~12–14) la validación colapsa y la val_loss se dispara, mientras la pérdida de entrenamiento sigue bajando. Más que un sobreajuste clásico, esto sugiere desajuste de optimización al descongelar capas con una tasa de aprendizaje elevada o sin *warm-up*.

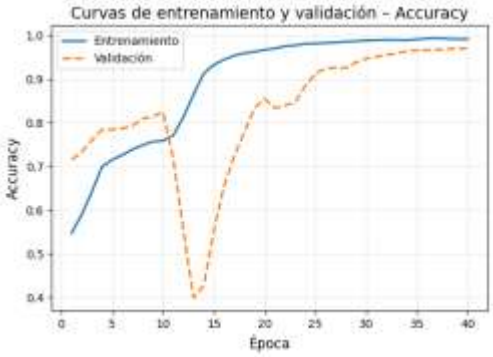


Figura 52 Curvas de entrenamiento y validación V6, desajuste en la optimización

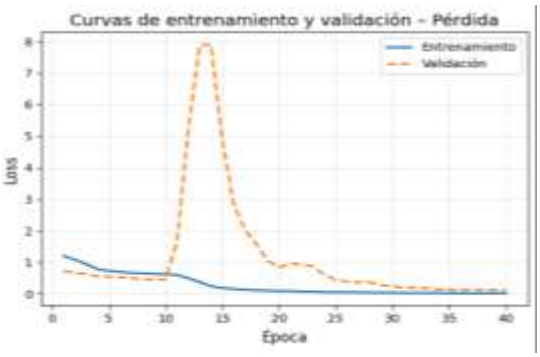


Figura 53 Curvas función perdida

La figura 49 muestra los conteos por clase (eje vertical: etiqueta real; horizontal: predicción). Predominan los aciertos en la diagonal: *Mosaic* (88), *Red_Rot* (101), *Rust* (102), *Saludable* (104) y *Yellow* (95). Los errores fuera de la diagonal son reducidos y coherentes con similitudes visuales: *Mosaic* → *Yellow/Saludable* (3 y 2), *Red_Rot* → *Rust* (2), *Rust* → *Yellow* (1), *Saludable* → *Mosaic* (1) y desvíos menores en *Yellow* (2→Saludable, 2→Mosaic, 1→Red_Rot, 1→Rust). En conjunto, la matriz de confusión respalda el alto recall por clase observado en V6 y una distribución de errores acotada.

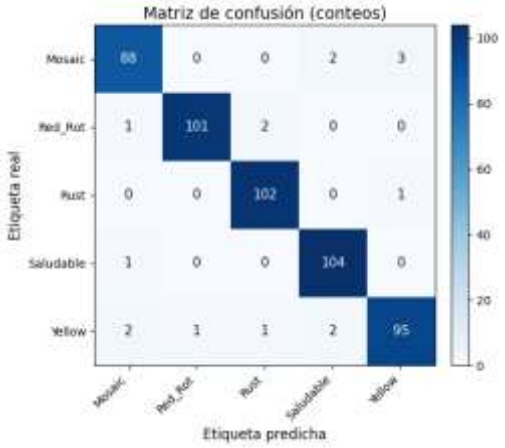


Figura 54 Matriz de confusión versión 6

Versión 7: elección del mejor modelo de clasificación

La Versión 7 se diseñó para superar las limitaciones observadas en la V6, la divergencia temporal entre precisión y pérdida mediante tres ajustes clave: (i)

Focal Loss, para ponderar mejor los errores en clases difíciles o menos representadas (*Mosaic*, *Rust*, *Yellow*); (ii) augmentación focalizada por clase, incrementando la variabilidad allí donde el desempeño era más bajo; y (iii) Grad-CAM, que aporta interpretabilidad al evidenciar las regiones foliares que sustentan cada predicción. En conjunto, estos cambios producen un entrenamiento más estable, con curvas de precisión y pérdida mejor alineadas y un incremento en la confiabilidad del modelo. Las características principales se resumen en la tabla siguiente.

Tabla 31 características principales de la versión 7

Componente	Descripción
Arquitectura	MobileNetV2 con ajuste fino (*fine-tuning*) en capas superiores
Preprocesamiento	CLAHE, filtros de realce y normalización 0,10,1
Aumento de datos	Aumentación estándar (rotación, zoom, traslación) + focalizada en clases difíciles (Mosaic, Rust, Yellow)
Función de pérdida	Focal Loss para balancear clases desiguales y mejorar *recall*
Optimización	Optimizador Adam con tasa de aprendizaje adaptativa; *callbacks* : EarlyStopping, ReduceLROnPlateau, ModelCheckpoint
Métricas	Precisión general > 90% en validación; reducción del error cuadrático medio (ECM ≈ 0.09–0.11)
Interpretabilidad	Implementación de Grad-CAM para visualizar regiones clave en las hojas

En las siguientes figuras presentan las curvas de aprendizaje de la V7.2 Stable: la figura 50, la evolución del *accuracy* en entrenamiento (línea continua) y validación (línea discontinua); figura 51, las curvas de pérdida correspondientes. La línea vertical punteada marca el inicio del *fine-tuning*. Se observa un incremento sostenido de la precisión en ambos conjuntos y una disminución monótona de la pérdida, con trayectorias alineadas y sin picos de inestabilidad como los vistos en V6. La brecha entre entrenamiento y validación permanece acotada, lo que indica entrenamiento estable y buena capacidad de generalización;

el punto operativo puede seleccionarse en el tramo final (cuando las curvas se estabilizan).

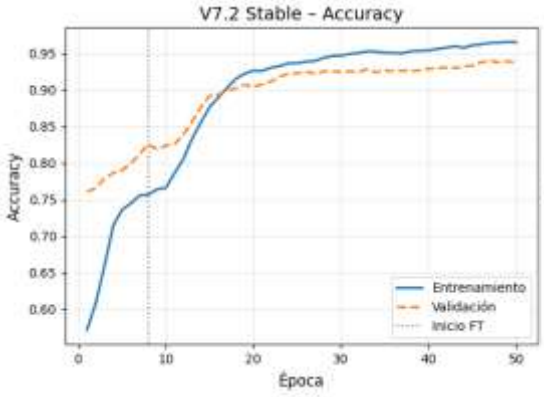


Figura 55 Curvas de entrenamiento y validación V7

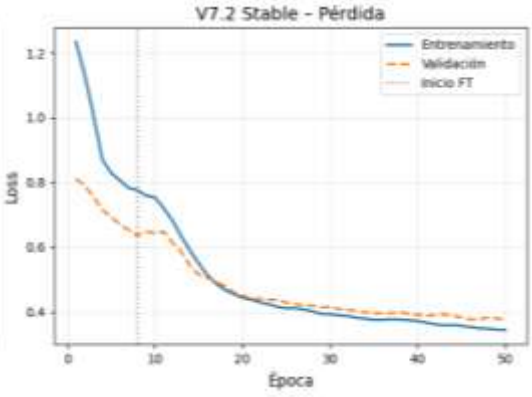


Figura 56 Curva función de perdida V7

El fine-tuning inicia alrededor de la época 8–9 (línea punteada). Hasta ese punto, el *accuracy* sube de ≈0.57 → 0.76 en entrenamiento y de ≈0.76 → 0.82 en validación; en paralelo, la pérdida baja de ≈1.24 → 0.75 (train) y de ≈0.80 → 0.63 (val). Tras el *fine-tuning*, entre época 15–20 el *accuracy* converge a ≈0.90–0.92 en ambos conjuntos, con pérdidas ≈0.47–0.45. En el último tercio (épocas 30–50) persiste una ganancia lenta pero sostenida: *accuracy* de validación ≈0.92 → 0.94 y de entrenamiento ≈0.95 → 0.965, con brecha estable de 0.01–0.03; la val_loss desciende de ≈0.42 → 0.37. El checkpoint óptimo puede fijarse hacia épocas 45–50 (mínima pérdida de validación ≈0.37 y *accuracy* ≈0.94), evidenciando estabilidad y buena generalización sin picos de inestabilidad.

Esta versión alcanza un accuracy global de 0.9447 (≈478 aciertos de 506), con macro F1 = 0.9445 y weighted F1 = 0.9448. La cercanía entre macro y weighted indica desempeño homogéneo entre clases y un conjunto de prueba razonablemente balanceado (supports: 93–105 por clase). Con n=506n=506n=506, el margen de error (aprox. binomial) del *accuracy* es del orden de ±2 pp, lo que respalda la estabilidad del resultado. Tabla 31.

Tabla 32 métricas de evaluación del modelo

Clase	Precision	Recall	F1-score	Support
Mosaic	0.9659	0.914	0.9392	93
Red_Rot	0.9709	0.9615	0.9662	104
Rust	0.9423	0.9515	0.9469	103
Saludable	0.9524	0.9524	0.9524	105
Yellow	0.8962	0.9406	0.9179	101
accuracy			0.9447	506
macro avg	0.9455	0.944	0.9445	506
weighted avg	0.9454	0.9447	0.9448	506

El modelo distribuye los 28 errores totales de forma acotada: los FP (falsos positivos) se concentran sobre todo en Yellow (≈11) y, en menor medida, en Rust (≈6); las omisiones (FN) son bajas en todas las clases (≈4–8). Esto se traduce en un sistema conservador para detectar enfermedades (recalls altos), con margen específico para elevar la precisión de Yellow (p. ej., augmentación dirigida, regularización ligera de la cabeza, y/o umbrales post-*softmax* clase-dependientes). La concordancia entre *accuracy*, *macro/weighted F1* y la cercanía de los *supports* confirma un desempeño estable y equilibrado, coherente con las mejoras introducidas en V7 (Focal Loss, augmentación focalizada, Grad-CAM). En conjunto, la V7.2 ofrece alto poder discriminante y generalización consistente para Mosaic, Red_Rot, Rust, Yellow y Saludable.

De acuerdo con la matriz de confusión (figura 52) predominan los aciertos en la diagonal (Mosaic = 85, Red_Rot = 100, Rust = 98, Saludable = 100, Yellow = 95), lo que refleja recalls altos por clase. Los errores se concentran en pares visualmente próximos: Mosaic → Yellow (5) y → Saludable (3); Red_Rot ↔ Rust (2 y 3); Yellow → Rust/Saludable (3 y 2); y Saludable → Mosaic/Yellow (2/2). Este patrón es consistente con el reporte de métricas (recall ≈ 0.91–0.96 y precision elevada, con ligera caída en Yellow por más FP), confirmando un desempeño estable y balanceado del modelo.

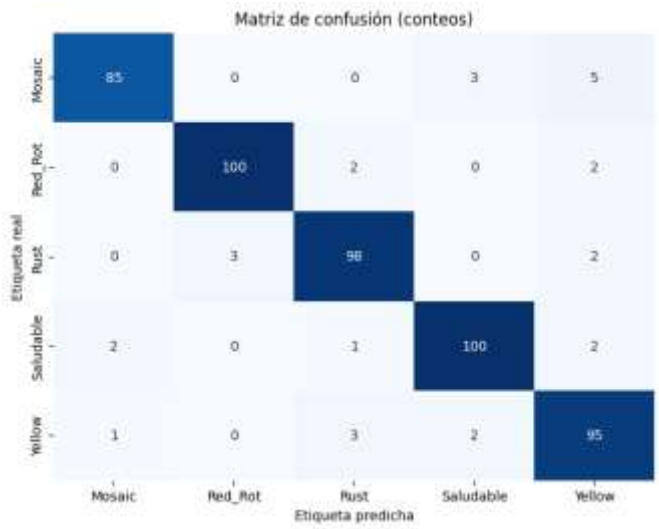


Figura 57 Matriz de confusión versión 7

La figura 53 muestra la matriz de confusión normalizada por filas (cada clase real suma 1), por lo que los valores de la diagonal equivalen al *recall* por clase: Mosaic 0.91, Red_Rot 0.96, Rust 0.95, Saludable 0.95 y Yellow 0.94. Las confusiones relativas más notables son: Mosaic → Yellow 0.05 y → Saludable 0.03; Rust → Red_Rot 0.03; Red_Rot → Rust 0.02; Yellow → Rust 0.03 (y → Saludable 0.02, → Mosaic 0.01); Saludable → Mosaic 0.02 (y → Yellow 0.02, → Rust 0.01). El resto de las celdas se mantiene en 0.00–0.02. En conjunto, todas las clases presentan sensibilidad alta (≥0.94, salvo Mosaic 0.91) y los errores se concentran en pares visualmente próximos, confirmando un modelo estable y balanceado;

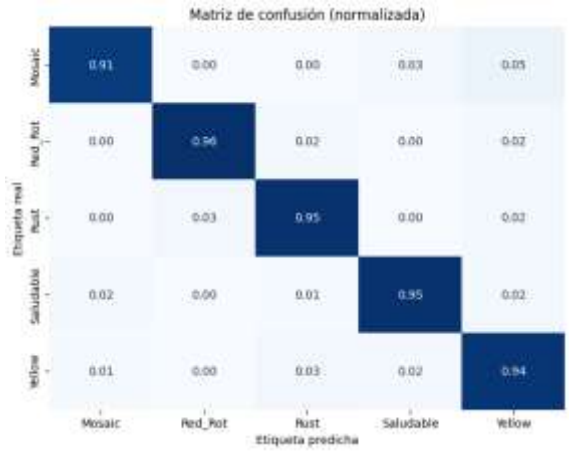


Figura 58 Matriz de confusión normalizada

Para validar el desempeño en condiciones reales, se presentan ejemplos por clase donde la predicción del modelo (título superior) coincide con la etiqueta real (título inferior), con probabilidades altas (≈0.99–1.00). Los casos ilustran variaciones de iluminación, textura y ángulo; aun así, el modelo discrimina de forma consistente entre Saludable, Rust, Mosaic, Yellow y Red_Rot, en línea con las métricas reportadas (accuracy ≈0.94 y F1 macro ≈0.94). Estas evidencias visuales complementan la matriz de confusión y confirman la capacidad de generalización del clasificador. (Figura 54)



Figura 59 Predicciones del modelo de clasificación entrenado

4.4 Resultados del modelo de riesgo por enfermedad en caña de azúcar

Las enfermedades de la caña de azúcar constituyen un factor crítico en la determinación del riesgo agrícola, ya que interactúan directamente con las

condiciones climáticas y la productividad del cultivo. Entre las más relevantes se encuentran la roya (rust), la podredumbre roja (red rot), la enfermedad de la hoja amarilla (yellow leaf disease) y el mosaico (mosaic virus), todas ellas responsables de pérdidas económicas significativas a nivel global y regional.

La roya marrón o Rust (Puccinia melanocephala) es una enfermedad foliar favorecida por ambientes cálidos y húmedos, con temperaturas de 20–28 °C y alta humedad relativa. Bajo estas condiciones, la esporulación del hongo se incrementa, afectando la fotosíntesis y reduciendo el contenido de sacarosa. Se han reportado pérdidas superiores al 20 % en caña susceptible durante epidemias severas (Chatenet et al., 2001).

Por su parte, la red rot (Colletotrichum falcatum) es considerada una de las enfermedades más destructivas, estrechamente asociada a periodos de exceso de humedad y altas temperaturas. Esta patología invade el tallo, ocasionando marchitez, pudrición interna y disminución de la calidad industrial del jugo. En brotes epidémicos, se han documentado reducciones de rendimiento superiores al 30 % (Viswanathan & Samiyappan, 2002).

Yellow leaf disease, causada por el *Sugarcane yellow leaf virus* (ScYLV), es transmitida por áfidos cuya proliferación se ve intensificada en climas cálidos y con estrés hídrico moderado. Esta enfermedad provoca clorosis en la nervadura central, reducción de la capacidad fotosintética y disminución del rendimiento de sacarosa, con pérdidas estimadas de entre 10 y 20 % en plantaciones comerciales (Vega et al., 2015).

Finalmente, el virus del mosaico de la caña de azúcar (Sugarcane mosaic virus, SCMV) es una enfermedad viral cuya severidad está influenciada por la variabilidad climática, especialmente por la interacción entre estrés térmico y sequía. Los síntomas se manifiestan en forma de franjas cloróticas y necrosis foliar, comprometiendo la productividad del cultivo. En variedades altamente susceptibles, se han registrado pérdidas de hasta el 50 % en rendimiento (Scagliusi & Lockhart, 2000)

La interacción entre estas enfermedades y el clima resalta la vulnerabilidad del cultivo de caña de azúcar frente al cambio climático. Escenarios con mayor variabilidad térmica, incremento de humedad relativa y eventos extremos como lluvias intensas o sequías prolongadas, tienden a favorecer la propagación y severidad de patógenos.

Diferentes variables son determinantes para que el riesgo aumente o disminuya ante alguna de las enfermedades de caña de azúcar entes mencionado. El vigor de la planta (VIG) es un indicador fisiológico que refleja el crecimiento, la densidad foliar y la capacidad fotosintética del cultivo. Plantas con alto vigor suelen presentar mayor tolerancia a condiciones de estrés y menor susceptibilidad a enfermedades foliares, dado que su mayor biomasa y área fotosintética compensan parcialmente los daños ocasionados por patógenos, valores bajos de VIG se asocian a plantas debilitadas, con menor cobertura foliar y mayor predisposición al ataque de enfermedades, (Bailey, 2019).

Por otro lado, el índice de nutrición potasio-nitrógeno (NKI) es una medida de equilibrio nutricional fundamental en caña de azúcar. El potasio (K) desempeña un papel clave en la regulación osmótica, la apertura estomática y la resistencia frente a patógenos, mientras que el nitrógeno (N) favorece el crecimiento vegetativo, pero, en exceso, puede generar tejidos más suculentos y predispuestos a infecciones. Un NKI balanceado (relación adecuada K/N) reduce el riesgo de enfermedades como red rot y rust, ya que promueve un metabolismo equilibrado y tejidos más resistentes (Shukla et al., 2017). En contraste, un NKI desequilibrado, ya sea por deficiencia de potasio o exceso de nitrógeno, eleva el riesgo agrícola al incrementar la susceptibilidad de la planta frente a hongos y virus, además de limitar la acumulación de sacarosa en los tallos.

En síntesis, tanto el VIG como el NKI constituyen variables críticas en la evaluación del riesgo agrícola de la caña de azúcar. Un bajo vigor y un desequilibrio nutricional actúan como factores predisponentes que, combinados con condiciones climáticas favorables al patógeno (alta humedad, temperaturas

intermedias y exceso de lluvias), intensifican el impacto de enfermedades y reducen la calidad industrial del cultivo.

4.4.1 Superficie de respuesta modelo difuso de riesgo

El sistema difuso planteado (primer nivel), se generaron las superficies de respuesta que permiten visualizar la interacción entre los factores climáticos, fisiológicos y nutricionales frente al riesgo agrícola con cada una de las enfermedades identificadas por la red neuronal de clasificación de enfermedades del cultivo de caña de azúcar.

Red Rot

La Figura 60, muestra la interacción entre la variable AGE (edad del cultivo) y P (Fosforo), en relación con el riesgo de incidencia de Red Rot. El riesgo se mantiene bajo en la mayoría de los escenarios, cuando la edad es temprana o cuando los valores de P son intermedios. Sin embargo, existen dos zonas críticas donde la superficie se eleva abruptamente (≈0.48–0.5), el riesgo aumenta de forma marcada cuando el cultivo se encuentra en extremos de edad, muy joven (AGE < 5) o maduro/entrado en soca (AGE > 15) y coincide con condiciones desfavorables de fosforo (p. ej., deficiencia nutricional y/o ambientes húmedo-cálidos). En plántulas, la menor lignificación y el estrés inicial facilitan la entrada del patógeno; en caña madura o socas viejas, el debilitamiento fisiológico y la acumulación de lesiones predisponen a pudriciones internas del tallo.

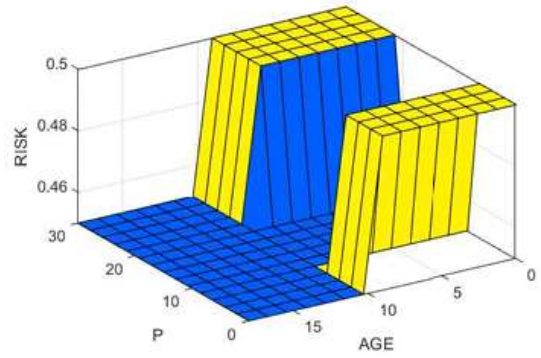


Figura 60 Superficie de respuesta para Red Rot en caña de azúcar, considerando la interacción entre la edad del cultivo (AGE) y la variable P

Por su parte, la interacción de VIG y P (Figura 61) muestra que, un tejido vigoroso (mejor área fotosintética y pared celular más robusta) y una nutrición balanceada sostienen tolerancia frente a patógenos de tallo/hoja, mientras que desequilibrios nutricionales (deficiencia o exceso de P y, por lo general, desbalances con K y N) predisponen a la infección. En caña, la literatura destaca que el equilibrio de macronutrientes (especialmente K, N y P) mejora la integridad de tejidos, la homeostasis hídrica y la resistencia a enfermedades; por el contrario, excesos o carencias aumentan la susceptibilidad y el riesgo productivo (Figura 62). El exceso de N o deficiencia de K (NKI negativo) y desbalances por P incrementan el riesgo del cultivo, aun cuando otras variables del cultivo sean favorables. Este patrón concuerda con evidencia que vincula la nutrición mineral balanceada (K–N–P) con menor incidencia y severidad de enfermedades en caña de azúcar (Shukla et al., 2017).

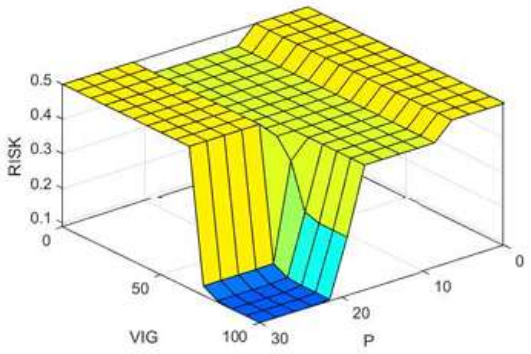


Figura 61 Superficie de respuesta del modelo difuso (RISK) en función de VIG y P

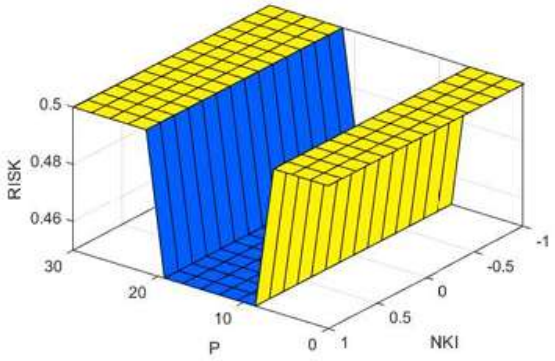


Figura 62 Superficie de respuesta del modelo difuso (RISK) en función de NKI y P

Por su parte, la figura 62 muestra la relación entre SM (soil measure) y P (fósforo), a medida que SM aumenta hacia condiciones de saturación/charqueo, el riesgo se incrementa aun con P adecuado, lo cual es consistente con la mayor disponibilidad hídrica para patógenos y el estrés por hipoxia radicular que debilita tejidos. Además, con P bajo aparece una meseta de riesgo alto en casi todo el rango de SM, indicando que la deficiencia de fósforo intensifica el riesgo del cultivo; en cambio, P intermedio–óptimo amortigua el riesgo. La superficie evidencia un valle de riesgo mínimo cuando la humedad del suelo (SM) se mantiene baja–moderada (≈0–15) y el fósforo (P) está cercano a su rango óptimo (≈30)

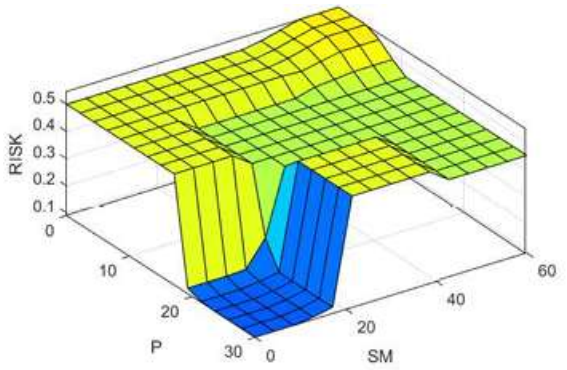


Figura 63 Superficie de respuesta del modelo difuso (RISK) en función de SM y P

Rust

La roya marrón de la caña (Puccinia melanocephala) es una de las enfermedades foliares más extendidas y su desarrollo se ve favorecido por ventanas térmicas templadas y períodos prolongados de hoja mojada; en ensayos controlados y modelos predictivos, la infección y la severidad aumentan en torno a 17–20 °C y con ≥ 7–13 h de mojado foliar, condiciones típicas de escenarios cálido-húmedos (Barrera et al., 2012a). En campo, la enfermedad ha mostrado pérdidas de rendimiento medibles en cultivares susceptibles, lo que justifica intervenciones de manejo y mejora genética (Hoy & Hollier, 2009a). Además, la nutrición mineral modula la severidad: se han descrito asociaciones entre mayor intensidad de roya y desequilibrios nutricionales (p. ej., exceso de N y desbalances de K/P), por lo que mantener un NKI cercano al balance y ajustar fertilización/agua al riesgo resulta clave (Anderson, 1986)

De acuerdo con el modelo difuso desarrollado para el riesgo de la caña de azúcar con esta patología la interacción humedad del suelo (SM) y edad del cultivo (AGE) está dominada por SM (Figura 64): con SM alta el riesgo se eleva en casi todas las edades; con SM baja–moderada aparece un canal de riesgo reducido, más marcado en edades intermedias–altas. En etapas muy tempranas, pequeños incrementos de SM disparan el riesgo (susceptibilidad inicial); en edades avanzadas, el riesgo repunta si SM se aproxima a saturación (hipoxia radicular y mayor permanencia de humedad en el dosel). Además, la figura 65 evidencia un pico de riesgo concentrado en edades intermedias (≈5–15) cuando el VIG es bajo–medio; fuera de esa ventana, el riesgo disminuye. El VIG alto (≈80–100) aplana la superficie y suprime el pico a lo largo de todas las edades, sugiere que el vigor funciona como factor amortiguador de la susceptibilidad etaria (canopia más densa, mayor integridad de tejidos)

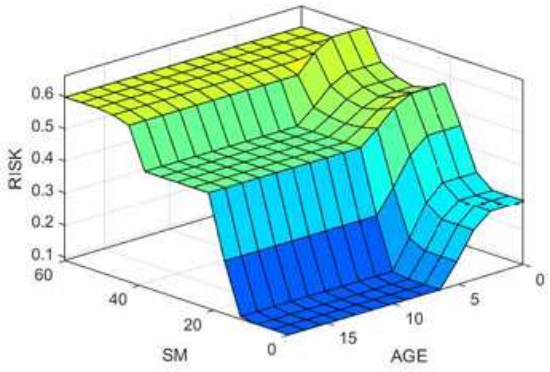


Figura 64 Superficie del modelo RISK respecto a las variables SM y AGE

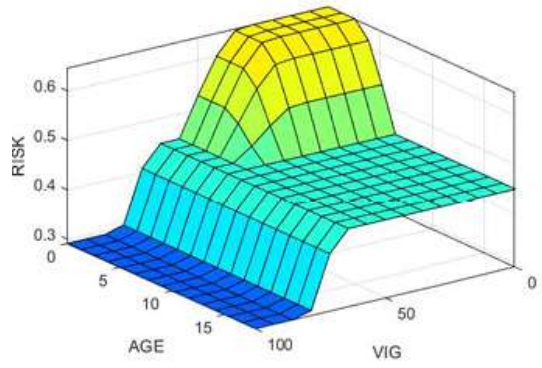


Figura 65 Superficie del modelo RISK con respecto a las variables AGE y VIG

La superficie representada por el balance entre nutrientes como Nitrógeno y Potasio muestra un valle profundo de riesgo mínimo cuando el balance K/N es cercano a cero (NKI≈0) y el vigor (VIG) es medio–alto. Al desviarse NKI (positivo o negativo), el riesgo aumenta hasta una meseta alta casi independiente de VIG; con VIG bajo, el sistema permanece en zona de riesgo elevado aun con NKI moderado (figura 66).

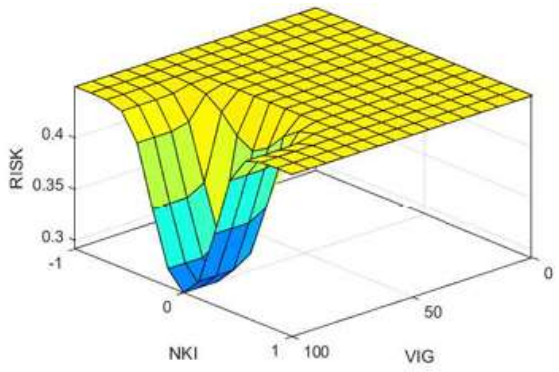


Figura 66 Superficie del modelo RISK con respecto a las variables NKI y VIG

En la figura 67 la superficie exhibe una respuesta unimodal al mojado foliar (LWH): el riesgo se maximiza en una ventana intermedia (≈4–8 h) y disminuye tanto con LWH muy bajo (agua libre insuficiente para germinación y penetración) como con LWH muy alto (posibles efectos de lavado/enfriamiento y alejamiento del óptimo térmico). El VIG alto (≈80–100) actúa como factor amortiguador: desplaza globalmente la superficie hacia riesgos bajos y aplana el pico en la ventana crítica, mientras que con VIG bajo el pico se acentúa y se ensancha, reflejando una mayor susceptibilidad fisiológica del cultivo.

En términos operativos, la figura sugiere acortar la ventana efectiva de LWH mediante manejo del dosel (ventilación entre surcos, control del acolchado que prolonga la humedad sobre hoja), programación de riego (evitar riegos vespertinos/nocturnos que prolongan el mojado) y drenaje en zonas con rocío persistente; a la par, sostener VIG alto, la nutrición balanceada y control de estrés reduce la amplitud del pico de riesgo y, por ende, la probabilidad de episodios epidémicos en condiciones cálido-húmedas (Barrera et al., 2012).

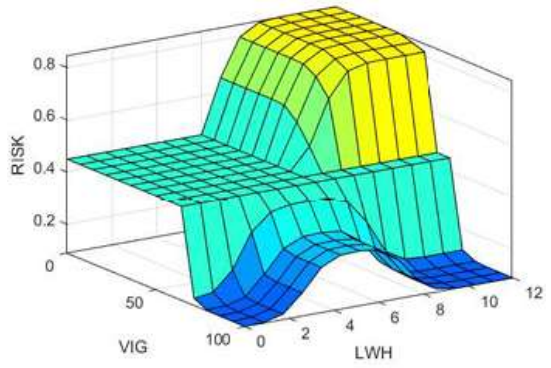


Figura 67 Figura 66 Superficie del modelo RISK con respecto a las variables VIG y LWH

Mosaic

Las infecciones tempranas de Mosaic en el cultivo de caña de azúcar (por semilla vegetativa infectada o por áfidos vectores) suelen traducirse en pérdidas de rendimiento más severas, y la variabilidad climática que favorece al vector incrementa la presión de inóculo; adicionalmente, el estrés hídrico y la nutrición desbalanceada tienden a exacerbar la expresión de síntomas y la caída de sacarosa, mientras que un estado de vigor alto y manejo hídrico adecuado mitigan el impacto.(Addy et al., 2017)

En la superficie AGE–VIG → RISK (Figura 68) se observa un máximo de riesgo concentrado en edades tempranas–intermedias (una "ventana crítica" alrededor del tramo central del eje AGE), que se intensifica cuando el vigor (VIG) es bajo–medio: la cresta asciende rápidamente hasta valores altos de *RISK* y se mantiene mientras la canopia no alcance un estado fisiológico robusto. A medida que VIG aumenta (≈ 80–100), la superficie se aplana y el riesgo desciende en todo el rango etario, sugiriendo un efecto amortiguador del vigor (mayor área fotosintética efectiva, tejidos más integrales y mejor capacidad de compensación). En cuanto a los parámetros nutricionales relacionados con la edad del cultivo (figura 69) el riesgo es mínimo cuando el índice de balance K/N (NKI) es cercano a 0 y la edad se sitúa en la zona media del ciclo; en contraste, el riesgo se eleva al desviarse NKI hacia valores positivos o negativos (desequilibrios por exceso de N o déficit de K), y esta elevación es más notoria en las primeras etapas del cultivo. En conjunto, ambas superficies indican que la susceptibilidad asociada a la edad se

potencia si el vigor es insuficiente o si el balance nutricional se rompe, mientras que un VIG alto y un NKI cercano al equilibrio tienden a desplazar la respuesta hacia escenarios de riesgo bajo.

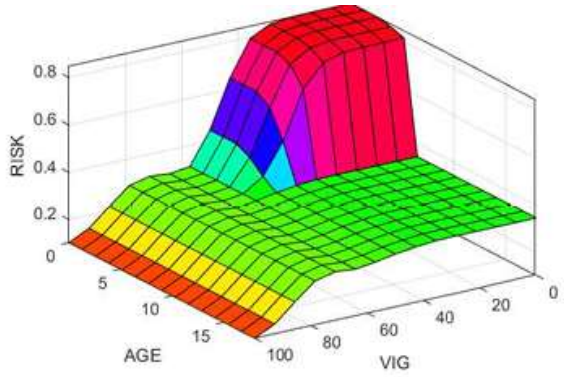


Figura 68 Superficie de respuesta del modelo difuso (Mosaic): edad del cultivo (AGE) vs. vigor (VIG)

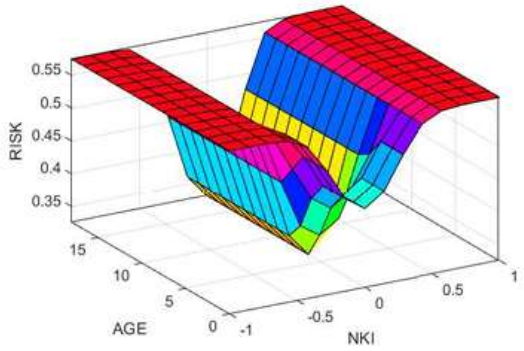


Figura 69 Superficie de respuesta del modelo difuso (Mosaic): edad del cultivo (AGE) vs. balance K/N (NKI)

Por otro lado, el riesgo es mínimo cuando el balance K/N (NKI) es cercano a 0 y el vigor (VIG) es alto; al desviarse NKI hacia positivos o negativos (desequilibrio por exceso de N o déficit de K), el riesgo aumenta de manera marcada, y este incremento es más sensible cuando el VIG es bajo–medio (Figura 70). La figura 71 muestra un gradiente ascendente del riesgo conforme P (Fósforo) se aproxima al rango alto (≈20–30) si el VIG es bajo; en cambio, VIG alto (≈80–100) aplana la respuesta y mantiene riesgo bajo a lo largo de todo el eje de P. El modelo sugiere que la susceptibilidad del mosaico se amplifica bajo desbalance K/N o fósforo elevado cuando la planta no alcanza buen vigor, mientras que VIG alto + NKI≈0 desplaza la superficie hacia zonas seguras.

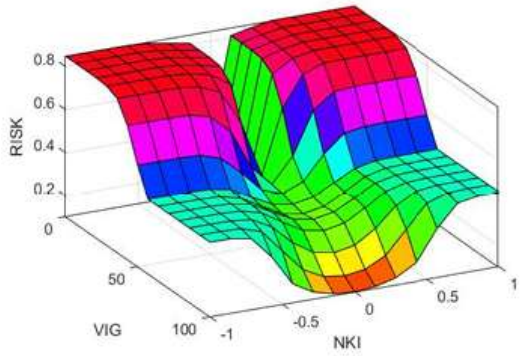


Figura 70 Superficie de respuesta del modelo difuso (Mosaic): vigor (VIG) vs. balance K/N (NKI)

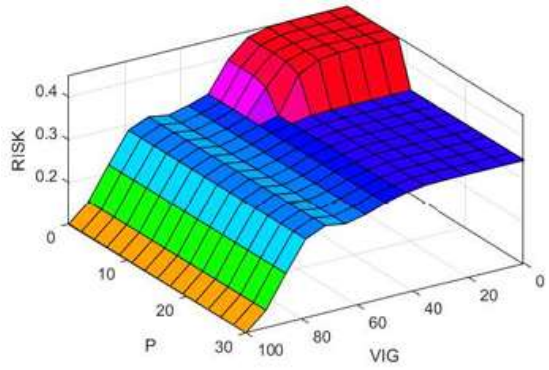


Figura 71 Superficie de respuesta del modelo difuso (Mosaic): fósforo (P) vs. vigor (VIG)

El exceso de N y desbalances de K aumentan la predisposición a patógenos, mientras que balances cercanos al óptimo tienden a atenuar síntomas (incluidos los virales) y a sostener el vigor de la planta. En caña, se ha documentado que la nutrición influye en la severidad del mosaico y en su impacto sobre fotosíntesis y crecimiento, es decir, un cultivo vigoroso y con K/N balanceado mantiene el cultivo en zonas de riesgo bajo (Sun et al., 2020).

Yellow

La yellow leaf de la caña (ScYLV) es una virosis que provoca clorosis de la nervadura central y amarillamiento progresivo, con merma de fotosíntesis, sacarosa y rendimiento; puede permanecer latente y expresarse con mayor fuerza bajo estrés térmico o hídrico. Su diseminación ocurre por propágulos vegetativos y áfidos vectores, y la severidad se modula por el estado fisiológico del cultivo (vigor), el balance nutricional (p. ej., K/N).

El estado nutricional del cultivo modula la severidad de virosis en caña: balances adecuados de K y Mg mejoran la integridad de tejidos y la eficiencia fotosintética, atenuando síntomas y pérdidas, mientras que excesos de N o desequilibrios K/Mg incrementan la predisposición (Datnoff et al., 2023). Para ScYLV, se ha documentado que la severidad y la pérdida de sacarosa aumentan bajo estrés fisiológico y nutricional, y que el vigor del cultivo condiciona la expresión de síntomas y el impacto productivo (Holkar et al., 2020).

En la superficie que se observa en la figura 72 el riesgo es mínimo cuando la relación potasio/magnesio (KMg) se sitúa en su rango alto-óptimo (≈ ≥1.5–2) y el balance K/N (NKI) es cercano a cero. El riesgo aumenta en cuanto KMg cae (indicio de déficit relativo de K o exceso de Mg) y/o NKI se desvía hacia valores positivos o negativos (desequilibrio por exceso de N o déficit de K), con una meseta superior más marcada cuando ambos desbalances coinciden. La segunda superficie (Figura 73), confirma ese patrón: con VIG bajo–medio el riesgo escala a medida que KMg se aleja del óptimo; en cambio, VIG alto (≈ 80–100) aplana la respuesta y mantiene el sistema en zonas de riesgo bajo incluso ante variaciones moderadas de KMg. En conjunto, los resultados indican que la expresión de Yellow se amplifica bajo desbalances K–Mg y K–N, especialmente si el cultivo no alcanza buen vigor, mientras que KMg elevado (K adecuado respecto a Mg), NKI≈0 y VIG alto desplazan la superficie hacia escenarios seguros (menor pérdida de fotosíntesis y sacarosa).

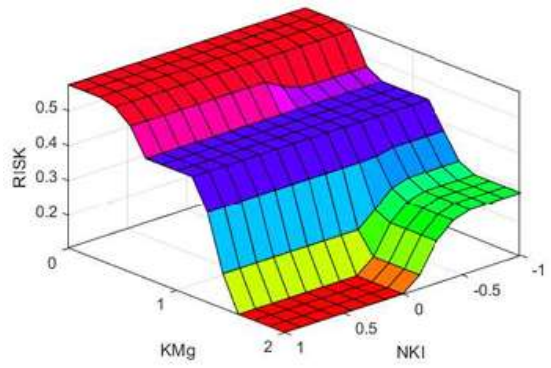


Figura 72 Superficie de respuesta (Yellow leaf): relación (KMg) vs. balance (NKI).

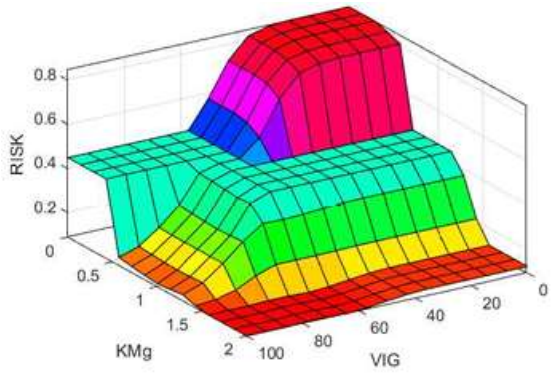


Figura 73 Superficie de respuesta (Yellow leaf): relación K/Mg vs. vigor del cultivo (VIG).

4.4.2 Resultados del modelo productivo de caña de azúcar

El análisis de los modelos difusos y de los escenarios simulados permite identificar cómo cada enfermedad de la caña de azúcar afecta de manera diferenciada tanto al rendimiento agrícola (t/ha) como a la calidad industrial medida en azúcares totales recuperables (ATR). Los resultados muestran que, si bien todas las enfermedades consideradas generan una disminución en la productividad y en el contenido de sacarosa, la magnitud de las pérdidas varía según el agente causal y las condiciones climáticas que favorecen su desarrollo.

Estos hallazgos permiten establecer un orden de prioridad en la atención fitosanitaria y, al mismo tiempo, constituyen la base para el diseño de esquemas de adaptación orientados a mitigar los impactos más severos sobre la producción y la calidad de la caña de azúcar en condiciones de cambio climático

A continuación de presentas las superficies de respuesta para cada una de las enfermedades y el impacto que tienen en el rendimiento y la calidad del cultivo de caña de azúcar.

4.4.2.1 impacto de Yellow en la producción y calidad

Superficies de Respuesta

La Figura 74 muestra la superficie de respuesta del rendimiento (t/ha) en función de la severidad de la enfermedad Yellow Leaf y el nivel de humedad relativa. Se observa que, conforme aumenta la severidad de la enfermedad, el rendimiento presenta una caída pronunciada, especialmente en condiciones de baja humedad.

En contraste, cuando la humedad es elevada y la severidad se mantiene baja, el cultivo conserva valores altos de productividad cercanos a 90 t/ha. Esta relación evidencia la sensibilidad del cultivo a la interacción entre factores fitosanitarios y ambientales, resaltando la importancia de considerar conjuntamente el manejo de la enfermedad y las condiciones climáticas para mitigar pérdidas de producción.

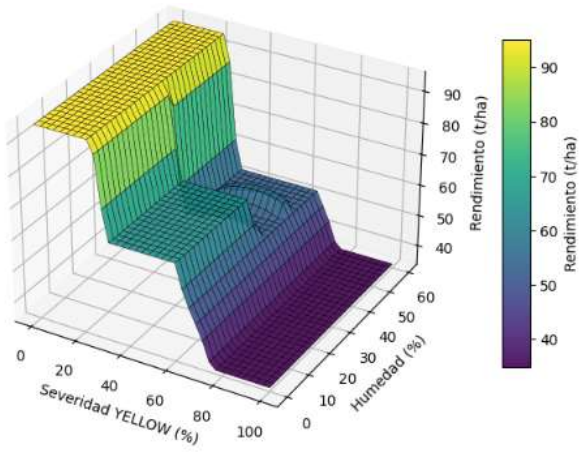


Figura 74 Superficie de respuesta del rendimiento de caña de azúcar (t/ha) en función de la severidad de Yellow Leaf y la humedad relativa (%)

Por su parte, el indicador de calidad ATR (kg/t) en función de la severidad de Yellow Leaf y la amplitud térmica. Se aprecia que el incremento en la severidad de la enfermedad reduce de manera notable la concentración de azúcares recuperables, especialmente cuando se combina con amplitudes térmicas extremas. En condiciones de baja severidad y amplitud térmica moderada, el ATR alcanza valores superiores a 135 kg/t, mientras que, en escenarios de alta severidad y variabilidad térmica, los valores caen por debajo de 105 kg/t, es decir la infección viral limita el transporte de sacarosa, y el estrés térmico adicional agrava la pérdida de calidad industrial de la caña (Figura 75).

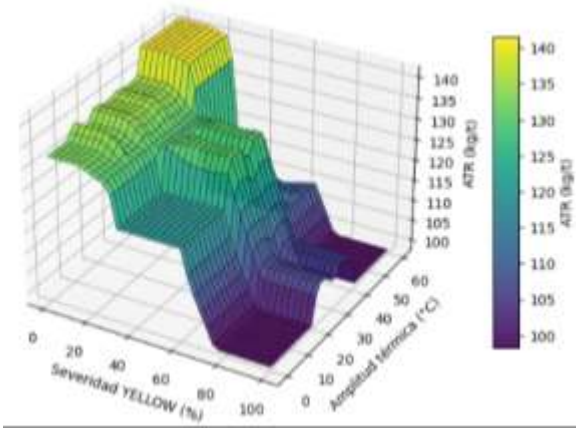


Figura 75 Superficie de respuesta del ATR (kg/t) en función de la severidad de Yellow Leaf y la amplitud térmica (°C)

La figura 76 muestra el impacto de yellow en el rendimiento y la calidad de la caña para cada uno de los niveles, En condiciones de baja severidad y clima favorable, los valores de rendimiento superan las 80 t/ha y el ATR se mantiene por encima de 135 kg/t. Conforme la severidad aumenta hacia niveles medios y altos, los rendimientos descienden hasta ~35 t/ha y el ATR cae por debajo de 110 kg/t. Esto confirma el efecto combinado de la infección viral y el ambiente sobre el metabolismo de la sacarosa.

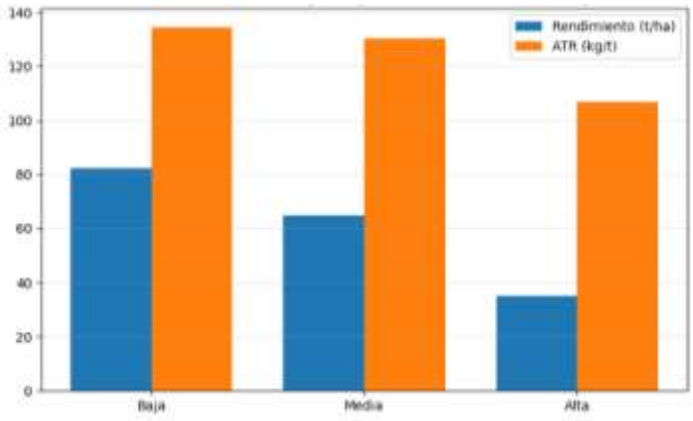


Figura 76 Rendimiento y ATR de caña de azúcar bajo distintos niveles de severidad de Yellow Leaf (condiciones fijas).

Análisis de sensibilidad de Variables

Para cuantificar la contribución de las variables al rendimiento (R) y al ATR, se realizó un análisis de sensibilidad. La Tabla 33 resume los cambios absolutos (Δ)

y relativos (ε) en las salidas ante variaciones controladas en las entradas del modelo.

Tabla 33 Sensibilidad del rendimiento (R) y ATR a variables climáticas y fitosanitarias en el modelo Yellow Leaf.

Variable	ΔR	ΔATR	εR	εATR
Humedad	0.138	0.145	0.048	0.023
Viento	0.182	0	0.057	0
Amplitud térmica	0.197	0.54	0.062	0.09
Edad	0.104	0.035	0.023	0.005
Yellow (severidad)	1.132	0.797	0.402	0.14

Los resultados evidencian que la severidad de la enfermedad (Yellow) es la variable de mayor peso sobre el rendimiento y la calidad, seguida por la amplitud térmica y, en menor medida, la humedad y el viento.

Los diagramas de tornado permiten visualizar el impacto absoluto de cada variable en el rendimiento y en el ATR.

- Para el rendimiento (t/ha), la severidad de la enfermedad domina el comportamiento del sistema, con un Δ promedio superior a 1 t/ha, muy por encima de las demás variables (Figura 77).
- Para el ATR (kg/t), la severidad mantiene el mayor efecto, seguida de la amplitud térmica, lo que sugiere que el estrés térmico agrava las pérdidas de calidad industrial (Figura 78).

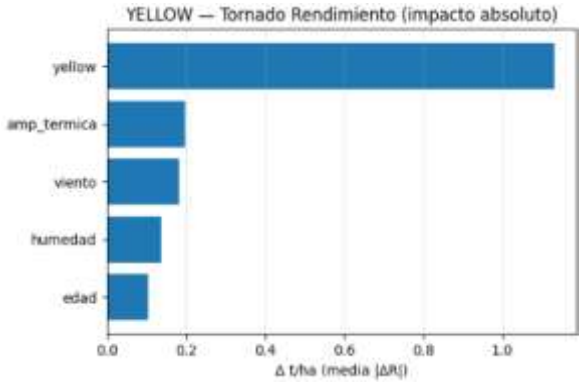


Figura 77 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en el modelo Yellow Leaf

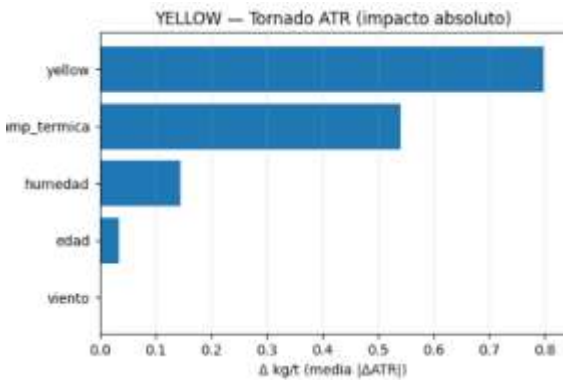


Figura 78 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en el modelo Yellow Leaf

4.4.2.2 Impacto de Red Rot en la producción y calidad

Superficies de respuesta

Los resultados obtenidos muestran que la severidad de Red Rot ejerce un impacto directo y marcado sobre el rendimiento de caña (t/ha) y sobre la calidad industrial expresada en ATR (kg/t).

En condiciones de baja severidad y con niveles de humedad favorables, el rendimiento supera las 85–90 t/ha. Sin embargo, a medida que la severidad de la enfermedad se incrementa, el rendimiento desciende de manera abrupta, llegando a valores por debajo de 20 t/ha cuando la infección alcanza niveles altos, independientemente de la humedad disponible, el carácter destructivo de Red Rot compromete el tejido del tallo y limita la capacidad fotosintética y de almacenamiento de sacarosa (Figura 79).

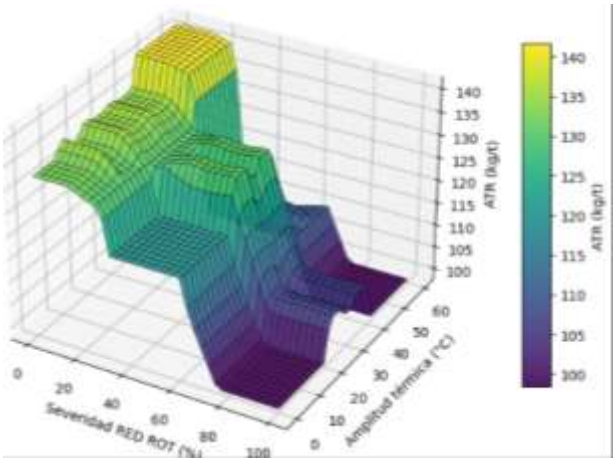


Figura 79 Superficie de respuesta del rendimiento de caña de azúcar (t/ha) en función de la severidad de Red Rot y la humedad relativa (%)

En la Figura 80, el comportamiento del ATR (kg/t) sigue la misma tendencia: valores superiores a 135 kg/t en condiciones de baja severidad y amplitud térmica moderada, pero con descensos marcados por debajo de 110 kg/t cuando la severidad aumenta, especialmente bajo condiciones de alta variabilidad térmica, confirmando que el estrés térmico intensifica la reducción de sacarosa, acentuando el impacto negativo de la enfermedad en la calidad de la caña.

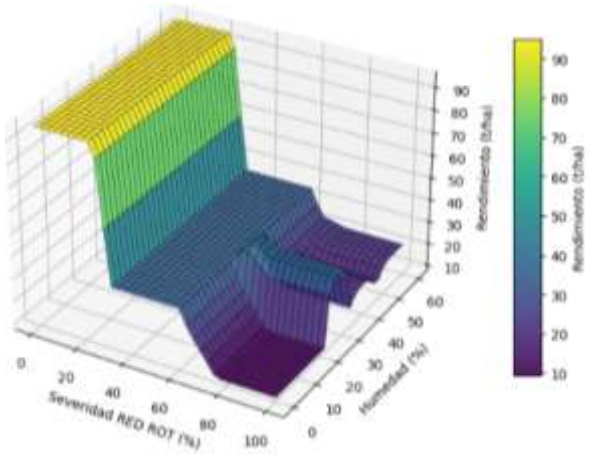


Figura 80 Superficie de respuesta del ATR (kg/t) en función de la severidad de Red Rot y la amplitud térmica (°C).

La figura 81 resume el efecto de la severidad sobre el rendimiento y el ATR bajo condiciones fijas. En el escenario de baja severidad se alcanzan rendimientos de más de 80 t/ha y ATR cercanos a 135 kg/t, mientras que en severidad media y alta el rendimiento se reduce a menos de la mitad, acompañado de una disminución progresiva en la calidad. Este resultado refuerza que la enfermedad no solo limita la producción de biomasa, sino también la recuperación industrial de azúcares.

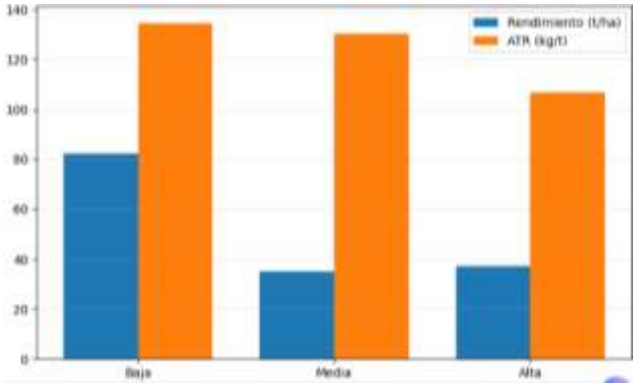


*Figura 81Rendimiento (t/ha) y ATR (kg/t) en función de la severidad de Red Rot bajo condiciones fija*s.

Análisis de sensibilidad

La sensibilidad (Tabla 34) nos dice que la severidad de Red Rot es el principal determinante tanto del rendimiento como del ATR; en segundo lugar, aparece la amplitud térmica, mientras que humedad y viento muestran efectos menores (y el viento prácticamente nulo sobre ATR).

Tabla 34 Sensibilidad del rendimiento (R) y ATR en Red Rot

Variable	ΔR	ΔATR	εR	εATR
Humedad	0.152	0.145	0.121	0.023
Viento	0.169	0	0.038	0
Amplitud térmica	0.244	0.54	0.218	0.09
Edad	0.08	0.035	0.018	0.005
Red Rot (sev.)	**1.296**	**0.797**	**0.655**	**0.14**

Los diagramas de tornado sintetizan el impacto absoluto medio (Δ). Para rendimiento (figura 82), la severidad de Red Rot domina ampliamente; para ATR (figura 83), la severidad sigue siendo el factor principal y la amplitud térmica ocupa el segundo lugar, lo que sugiere que el estrés térmico agrava la pérdida de calidad industrial.

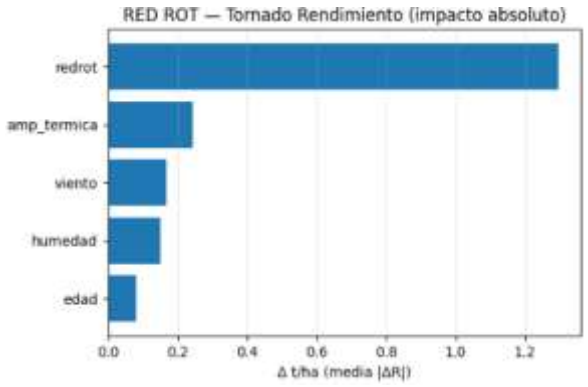


Figura 82 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en Red Rot.

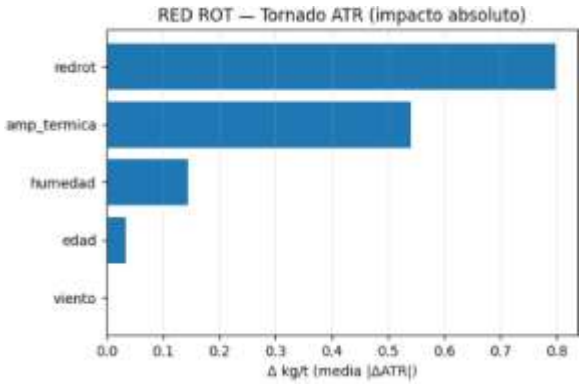


Figura 83 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en Red Rot.

Operativamente, estos resultados justifican: (i) priorizar semilla sana y saneamiento de setts; (ii) detección temprana y erradicación de focos; y (iii) manejo agronómico para mitigar estrés térmico (fechas de corte/siembra y cobertura del suelo).

4.4.2.3 Impacto de Mosaic en la producción y calidad

Superficies de respuesta

El ATR (kg/t) disminuye con el incremento de la severidad de Mosaic y se agrava con amplitudes térmicas amplias. En escenarios de severidad baja y amplitud moderada, el ATR alcanza valores >130–140 kg/t; bajo severidad alta y gran variabilidad térmica, desciende a ~95–110 kg/t, evidenciando el papel del estrés térmico en la pérdida de calidad industrial (Figura 84). En la figura 85 el ATR aumenta con la edad (madurez) cuando la severidad es baja, pero Mosaic desplaza ese beneficio: a severidades altas, el ATR se mantiene deprimido en todas las edades, con impacto mayor en estadios jóvenes. Esto sugiere que la infección reduce la acumulación de sacarosa y limita el potencial de madurez, aun cuando el cultivo avanza en edad.

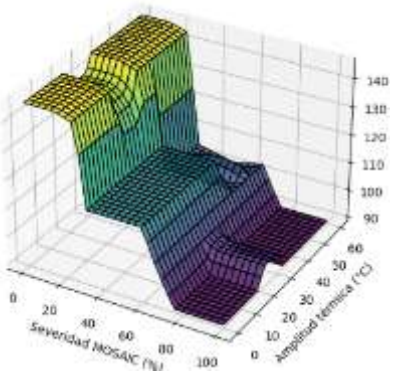


Figura 84 Superficie de respuesta del ATR (kg/t) en función de la severidad de Mosaic y la amplitud térmica (°C)

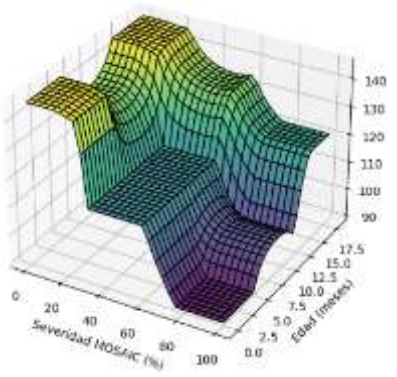


Figura 85 Superficie de respuesta del ATR (kg/t) en función de la severidad de Mosaic y la edad del cultivo (meses)

Análisis de sensibilidad de variables

La sensibilidad cuantifica la contribución de cada variable a las salidas del modelo. La severidad de Mosaic es el factor dominante tanto para Rendimiento como para ATR. La humedad tiene efecto relevante sobre Rendimiento (pero prácticamente nulo en ATR), mientras que la amplitud térmica es el segundo determinante en ATR. La edad muestra efectos modestos y viento impacta algo en Rendimiento, pero no en ATR.

Tabla 35 Sensibilidad del rendimiento (R) y ATR a variables climáticas y fitosanitarias en el modelo Mosaic.

Variable	ΔR	ΔATR	εR	εATR
Humedad	0.32	0.011	0.164	0.002
Viento	0.201	0	0.086	0
Amplitud térmica	0.174	0.672	0.041	0.12
Edad	0.066	0.092	0.015	0.015
Mosaic (sev.)	**1.24**	**1.106**	**0.469**	**0.199**

Los diagramas de tornado confirman el patrón de la tabla (Figura 86 y 87 respectivamente):

- Para Rendimiento, Mosaic (severidad) domina claramente, seguido por humedad; viento y amplitud térmica tienen impactos menores y edad es marginal.
- Para ATR, la mayor contribución proviene de Mosaic (severidad) y, en segundo lugar, de la amplitud térmica; edad es moderada y humedad/viento son prácticamente nulos.

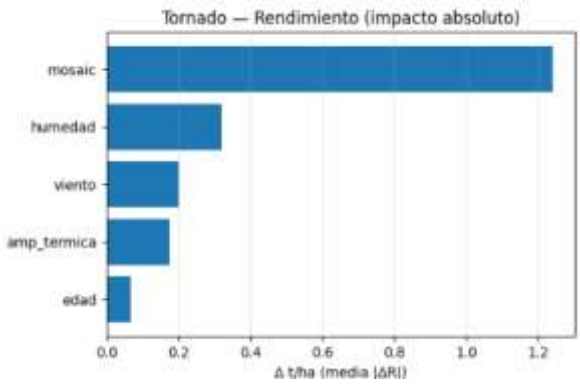


Figura 86 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en Mosaic

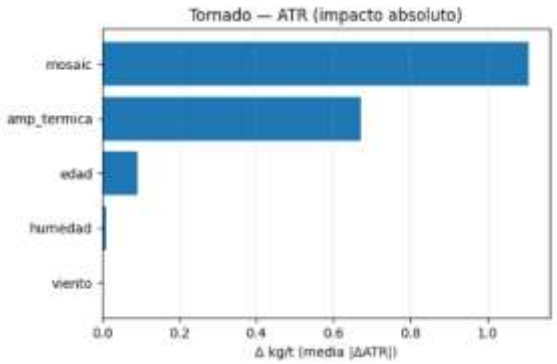


Figura 87 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en Mosaic.

4.4.2.4 Impacto de Rust (Roya) en el rendimiento y calidad

Superficies de respuesta

La superficie evidencia que el rendimiento (t/ha) decrece conforme aumenta la severidad de Rust, con descensos más marcados en condiciones de humedad baja–media. Con severidad baja y humedad alta el cultivo mantiene productividades elevadas (>80–90 t/ha), pero a severidad media–alta el rendimiento cae a rangos cercanos a 35–45 t/ha aun cuando la humedad es favorable, mostrando que el daño foliar limita fuertemente la producción de biomasa (Figura 88). El ATR (kg/t) también disminuye con el incremento de la severidad, y la amplitud térmica actúa como modulador: amplitudes moderadas permiten valores altos de ATR (>130–140 kg/t) cuando la severidad es baja, mientras que amplitudes amplias y severidad alta conducen a un escalón de valores bajos (~100–110 kg/t). Esto indica que el estrés térmico potencia la pérdida de calidad industrial asociada a la roya (figura 89).

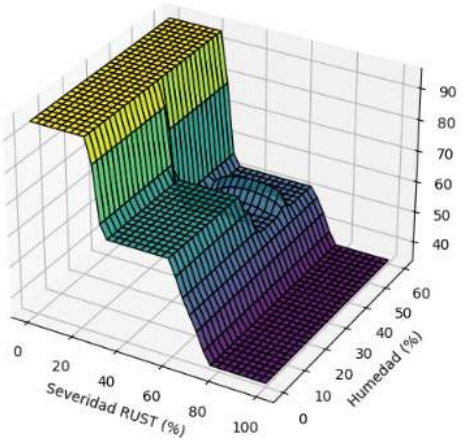


Figura 88 Superficie de respuesta del rendimiento (t/ha) en función de la severidad de Rust y la humedad relativa (%).

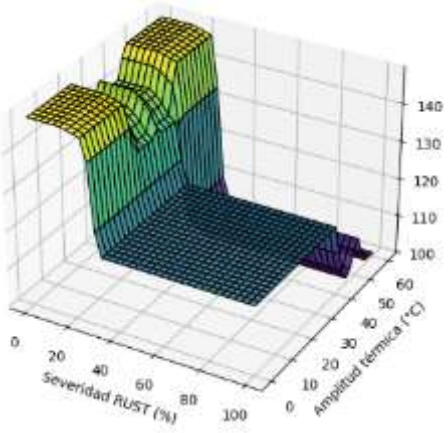


Figura 89 Superficie de respuesta del ATR (kg/t) en función de la severidad de Rust y la amplitud térmica (°C)

Análisis de sensibilidad de variables

Para rendimiento, la severidad de Rust es el factor dominante, seguida por humedad y amplitud térmica; viento y edad tienen impactos menores. Para ATR, la amplitud térmica es el principal modulador, seguida por la severidad y, a distancia, la humedad (tabla 36).

Tabla 36 Sensibilidad del rendimiento (R) y ATR a variables climáticas y fitosanitarias en el modelo Mosaic.

Variable	ΔR	ΔATR	εR	εATR
Humedad	0.247	0.235	0.125	0.038
Viento	0.153	0.042	0.068	0.008
Amplitud térmica	0.203	**0.928**	0.053	**0.163**
Edad	0.092	0.03	0.02	0.004
Rust (severidad)	**1.128**	0.529	**0.419**	0.084

Los diagramas de tornado muestran que, para el rendimiento, el mayor impacto absoluto corresponde a la severidad de la roya (ΔR = 1.128), seguida a distancia por humedad (0.247) y amplitud térmica (0.203); viento y edad tienen efectos secundarios (figura 90). En ATR, el factor dominante es la amplitud térmica (ΔATR = 0.928), seguida por la severidad de la roya (0.529); la humedad aporta de forma moderada y viento/edad resultan marginales (Figura 91).

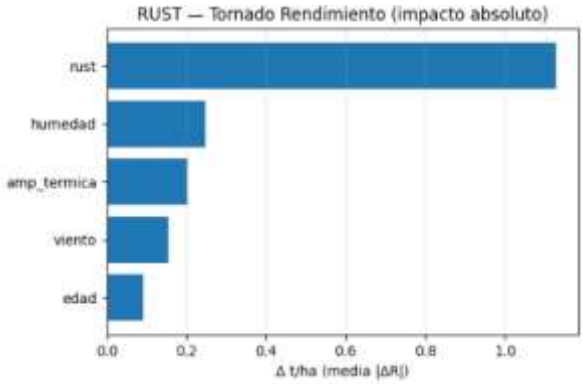


Figura 90 Diagrama de tornado del impacto de variables sobre el rendimiento (t/ha) en Rust.

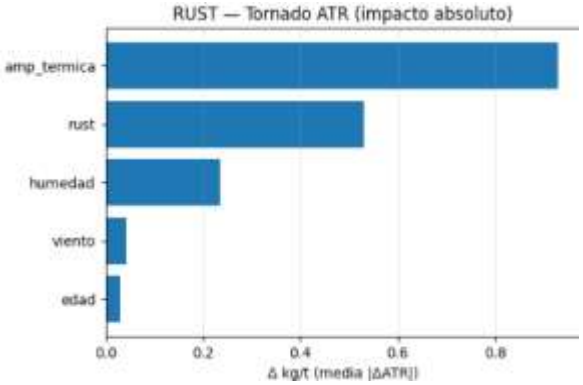


Figura 91 Diagrama de tornado del impacto de variables sobre el ATR (kg/t) en Rust

4.4.3 Jerarquización de enfermedades

Este apartado integra, en un índice comparativo, que refleje el efecto de cada enfermedad sobre la producción (R, t/ha) y la calidad industrial (ATR, kg/t). A partir de las superficies de respuesta y del análisis de sensibilidad, se calculan los impactos medios por severidad (ΔR y ΔATR).

$$I = 0.6\, R_{nom} + 0.4\, ATR_{norm}$$

Ponderando ligeramente más el rendimiento por su efecto directo en ingresos por hectárea. Este índice permite ordenar la prioridad de intervención y, a la vez, distinguir qué patógenos comprometen más la biomasa o la recuperación de azúcares. Los resultados muestran una jerarquía consistente con los patrones observados: Mosaic y Red Rot encabezan la prioridad por su daño combinado en R y ATR; Yellow presenta impacto intermedio y Rust el menor dentro del conjunto analizado. Se incluye además la comparación desagregada (ΔR y ΔATR) para transparentar el aporte de cada componente y los moduladores climáticos (especialmente amplitud térmica para ATR y humedad para R), que orientan las medidas de manejo y adaptación descritas en la sección siguiente.

La figura 92 sintetiza el daño medio por severidad separando la pérdida de rendimiento (izquierda) y la merma de calidad ATR (derecha). En rendimiento, Red Rot presenta la mayor caída (ΔR = 1.296 t/ha), seguida de Mosaic (1.240), con Yellow (1.132) y Rust (1.128) muy próximos. En ATR, Mosaic es el más perjudicial (ΔATR = 1.106 kg/t), luego Red Rot y Yellow (0.797), y Rust muestra el menor compromiso (0.529). En conjunto, si la prioridad es biomasa, debe atenderse primero Red Rot; si la meta es calidad industrial, la atención primaria corresponde a Mosaic, mientras Rust queda como el de menor impacto global.

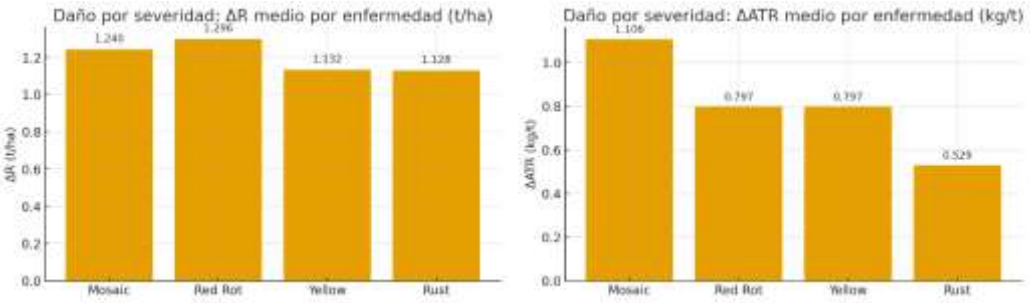


Figura 92 Comparativo del daño por severidad en rendimiento (ΔR, t/ha) y calidad (ΔATR, kg/t) por enfermedad.

La figura Panorama del daño por severidad (figura 93): ΔR vs ΔATR es un diagrama de dispersión que resume, para cada enfermedad, su pérdida media por severidad en dos dimensiones: el eje X muestra la caída de rendimiento (ΔR, t/ha) y el eje Y la merma de calidad (ΔATR, kg/t). Su lectura es directa: cuanto más a

la derecha, mayor pérdida de biomasa; cuanto más arriba, mayor pérdida de azúcares recuperables.



Figura 93 Panorama del daño por severidad: ΔR (t/ha) vs ΔATR (kg/t) por enfermedad

Mosaic aparece en el cuadrante superior derecho (≈1.24, 1.11): es el que golpea simultáneamente rendimiento y ATR, por eso lidera la prioridad global. Red Rot se ubica más a la derecha (≈1.30, 0.80): es el que más reduce rendimiento, con un impacto intermedio en ATR. Yellow queda en una posición intermedia (≈1.13, 0.80), con daño balanceado en ambas métricas. Rust está más abajo (≈1.13, 0.53): su impacto en ATR es el menor del grupo, aunque en rendimiento es similar a Yellow.

Para sintetizar la priorización, se comparan las pérdidas normalizadas por severidad en rendimiento (R) y calidad (ATR) junto con el índice compuesto $I = 0.6\, R_{nom} + 0.4\, ATR_{norm}$). La figura muestra que Mosaic lidera la severidad combinada (por su alto impacto en ATR y un efecto elevado en R), Red Rot ocupa el segundo lugar (máxima caída relativa de R con ATR intermedio), Yellow queda en posición intermedia y Rust presenta la menor severidad global por su menor efecto sobre ATR. Esta lectura respalda intervenir primero en Mosaic y Red Rot, dejando Yellow y Rust en prioridades subsecuentes (Figura 94).

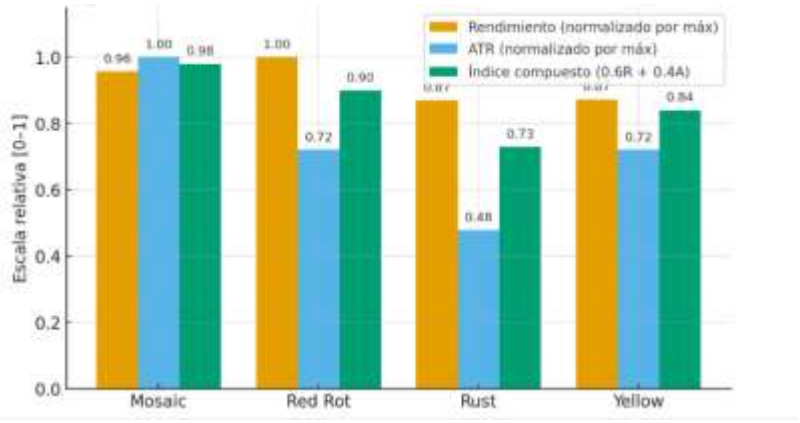


Figura 94 Ranking comparativo: Rendimiento + ATR (normalizados por máximo) e índice compuesto (0.6R + 0.4A)

En cierre, la priorización derivada del índice combinado $I = 0.6\,R_{nom} + 0.4\,ATR_{norm}$). confirma que Mosaic y Red Rot deben atenderse primero, según otros autores, el mosaico reduce la fotosíntesis y la sacarosa del tallo, con caídas significativas de TCH (Toneladas de caña por hectárea) y de azúcar recuperable (Lu et al., 2021). Red Rot provoca deterioro simultáneo de rendimiento y calidad; en contextos epidémicos se han documentado mermas altas (≈29–83% en distintos reportes), lo que justifica su segunda posición en la jerarquía (Viswanathan, 2021). Yellow leaf (SCYLV) suele causar pérdidas moderadas en condiciones típicas (≈10% de caña y azúcar), acordes con su lugar intermedio (Ramouthar et al., 2013) Por su parte, Rust presenta el menor compromiso del ATR y un impacto de rendimiento por debajo de los anteriores; en Louisiana, el efecto promedio se estimó en −16% de caña y −14% de sucrosa total (Hoy & Hollier, 2009b.

4.5 Esquemas de adaptación

En esta sección se presentan los esquemas de adaptación elaborados para el sector agropecuario, derivados del análisis de vulnerabilidad realizado tanto en el cultivo de caña de azúcar como en la producción pecuaria. Estos esquemas sintetizan acciones concretas de manejo y estrategias de mitigación que responden a los escenarios de riesgo identificados a partir de la dinámica climática y productiva.

Para el sector pecuario, los esquemas se construyen a partir de riesgos asociados a la variabilidad climática, como el estrés calórico, el déficit hídrico y las afectaciones respiratorias derivadas de nortes o frentes fríos. En este sentido, las medidas de adaptación comprenden desde la gestión del confort animal (sombra,

ventilación, acceso a agua) hasta ajustes en la alimentación y el uso de suplementos estratégicos que mejoran la resiliencia productiva.

En el caso de la caña de azúcar, los esquemas consideran la incidencia de enfermedades como *Yellow, Rust, Red Rot* y *Mosaic*, cuya severidad impacta de manera diferenciada el rendimiento, la calidad industrial (ATR) y el valor económico de la cosecha. Las acciones de adaptación propuestas incluyen mejoras en el manejo de suelos, la aplicación oportuna de insumos fitosanitarios y la incorporación de prácticas preventivas orientadas a reducir la vulnerabilidad frente a condiciones climáticas adversas, como humedad elevada, amplitud térmica extrema o vientos intensos.

En conjunto, estos esquemas de adaptación buscan ofrecer un marco práctico para disminuir la vulnerabilidad y reforzar la resiliencia del sector agropecuario. Su propósito es orientar la toma de decisiones hacia una mayor sostenibilidad y competitividad, considerando tanto los impactos directos del cambio climático como los posibles beneficios derivados de una mejor gestión de los recursos y del fortalecimiento de las prácticas productivas.

4.5.1 Esquemas de adaptación para el sector pecuario

Un esquema de adaptación pecuaria que integre manejo de microclima y agua, nutrición y manejo productivo, así como salud y bioseguridad, se alinea con los mecanismos mediante los cuales el calor y la humedad afectan el desempeño y la sanidad del ganado: reducción de la ingestión y de la eficiencia alimenticia, alteraciones fisiológicas e inmunológicas y aumento de la transmisión de patógenos. El esquema de adaptación se articula en cinco frentes relacionados entre sí: temperatura, disponibilidad de agua, alimentación, manejo de estiércol y emisiones de GEI.

De acuerdo con la síntesis del IPCC AR6, cuando los animales operan fuera de su "zona de confort", el consumo disminuye (≈3–5 % por cada °C adicional), se deterioran la productividad y la fertilidad, y el estrés térmico deprime la función inmune, lo que eleva la susceptibilidad a enfermedades. En este marco, las intervenciones que reduzcan la carga térmica o la exposición sanitaria se asocian

con mejoras directas en el desempeño productivo y en los indicadores de salud (Intergovernmental Panel on Climate Change (IPCC), 2023)

En temperatura, el objetivo es recortar el estrés térmico durante las horas críticas. La combinación de sombra (natural o artificial, 70–80% y altura ≥3 m), ventilación dirigida (velocidades efectivas del aire en el rango de 2–3 m/s a nivel del animal) y enfriamiento evaporativo (rociadores/nebulización en modo intermitente, 5–10 L/h·100 m^2) reduce la acumulación de calor, estabiliza la respiración y ayuda a sostener el comportamiento alimentario. Estas acciones se refuerzan con un reajuste de horarios (actividad y suministro en las horas más frescas), estrategia que evita picos térmicos postprandiales y modera la caída de consumo

El segundo frente es la disponibilidad de agua, probablemente la palanca más crítica en escenarios cálidos. El diagrama enfatiza flujo continuo con bebederos automáticos, dotaciones por especie y etapa (a modo referencial: bovino 60–150 L/animal·día, porcino 5–30 L, aves 0.2–0.5 L/ave·día, variando con producción y clima) y calidad (pH, salinidad, contaminantes), además de cosecha/almacenamiento para estiajes. El suministro de agua fresca y limpia mejora la termorregulación y la ingestión, y su insuficiencia es una de las causas más frecuentes de caídas productivas en olas de calor según NRC/NASEM, 2001/2016; IPCC, 2022; FAO, 2020. El tercer bloque, alimentación, persigue un doble beneficio: sostener el desempeño en calor y contribuir a la mitigación. En lineamientos prácticos, una base forrajera (p. ej., 50–60% con forrajes jóvenes/leguminosas/ensilados) complementada con concentrados (30–40%; granos, melazas, subproductos como pulpa cítrica) permite mantener la densidad de nutrientes cuando baja la ingestión; y, en picos de calor, conviene incrementar la densidad energética (≈+5–10%) y moderar la fibra efectiva (−2–3 puntos porcentuales), siempre bajo formulación técnica. Según sistema y especie, la inclusión moderada de aceites vegetales (≈2–3%) y de aditivos con efecto anti-metanogénico (p. ej., taninos, nitratos controlados o algas marinas) puede reducir el calor metabólico y la emisión entérica sin comprometer la salud ruminal (FAO, 2020; NASEM, 2016).

El cuarto elemento es el manejo de estiércol, clave tanto para sanidad ambiental como para clima. Tres rutas aparecen en el diagrama: compostaje, biodigestores (con producción de biogás/energía) e incorporación al suelo (referencia agronómica: 20–30 t/ha, siempre con análisis y plan de fertilización). Estas prácticas reducen emisiones fugitivas y vectores en periodos de humedad elevada, a la vez que reciclan nutrientes y mejoran la estructura del suelo (WOAH, 2023; FAO, 2020). El quinto frente, emisiones de GEI, no es un módulo aislado, sino el resultado de articular los anteriores: dietas mejor formuladas y manejo de estiércol bien ejecutado disminuyen pérdidas de metano y óxido nitroso, de modo que la adaptación (menos estrés y menos mermas) y la mitigación (menor huella) avanzan juntas. Este "co-beneficio" es particularmente valioso en sistemas sujetos a calor y humedad, donde la mejora del microclima y del agua reduce el riesgo sanitario y, por la misma vía, evita pérdidas de eficiencia (IPCC, 2022). La figura 95 muestra el esquema de adaptación para el sector pecuario.

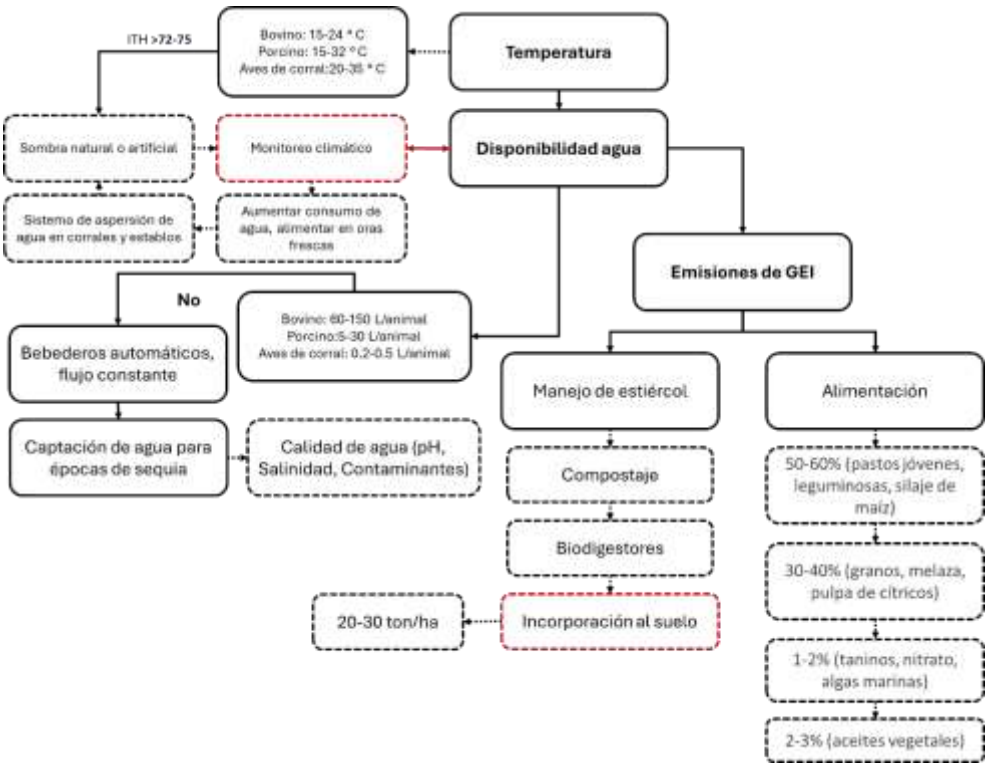


Figura 95 Esquema integral de adaptación para el sector pecuario

El flujo vincula control de temperatura (sombra, ventilación, enfriamiento), disponibilidad y calidad de agua (dotaciones por especie, cosecha y monitoreo), ajustes nutricionales (composición de dieta y aditivos), y manejo de estiércol (compost, biodigestor e incorporación al suelo), con co-beneficios en emisiones de GEI. Todas las acciones se activan mediante el índice difuso de riesgo R_m

4.5.1.2 Interfaz interactiva para sector pecuario

La interfaz interactiva desarrollada para el sector pecuario integra, en un solo panel, la evaluación rápida del riesgo por estrés térmico y la recomendación de acciones de adaptación específicas por especie (bovino, porcino y avícola). El dashboard presenta semáforos visuales, escenarios rápidos (presets ambientales) y controles deslizables para ajustar temperatura, humedad, viento, sombra, ventilación y dotación de agua. Con estos insumos, el sistema calcula un índice térmico aproximado (THI) y un nivel de riesgo 0–1, y despliega paquetes de adaptación con cantidades y ciclos orientativos (alimentación, vitaminas/minerales, manejo del agua y control de vectores). La interfaz es responsiva, usa tooltips para aclarar abreviaturas (p. ej., PV y MS) y muestra medidas escalonadas según el color del semáforo (amarillo/rojo), favoreciendo decisiones rápidas en campo. A continuación, se da a conocer las secciones.

Escenarios rápidos y selector de especie

Permite aplicar "presets" ambientales con un clic —Día templado, Ola de calor y Norte húmedo. Estos escenarios ajustan automáticamente los parámetros del modelo (temperatura, humedad, viento, sombra, ventilación y agua) solo para la especie del tab activo. En la figura 96, el tab Avícola está seleccionado (oscuro), por lo que cualquier "preset" afectará exclusivamente esa especie. Esto agiliza pruebas "qué pasaría si…" y estandariza comparaciones entre especies sin mezclar configuraciones.



Figura 96 Panel escenarios rápidos y selección de especie

Panel de ajuste de parámetros

Esta sección permite configurar las condiciones ambientales y de manejo de la especie activa (temperatura, HR, viento, sombra, ventilación y agua). Con esos datos, el sistema calcula el THI y el nivel de riesgo, actualiza el semáforo y genera las acciones de adaptación pertinentes (figura 97).



Figura 97 Ajuste de parámetros

Panel de adaptación

La sección de recomendaciones (Figura 98) convierte el riesgo en acciones específicas por especie y cubre: ventilación, enfriamiento y sombra; agua y electrolitos (dotación/flujo); alimentación (horarios y densidad energética); vitaminas y minerales (A-D-E, Zn/Se); control de vectores (mosca, garrapatas/ácaros, rotación de IA); rutinas de manejo y densidad (ajustes 10–20% en rojo, evitar traslados/estrés); y escalamiento según semáforo (medidas para amarillo y rojo).

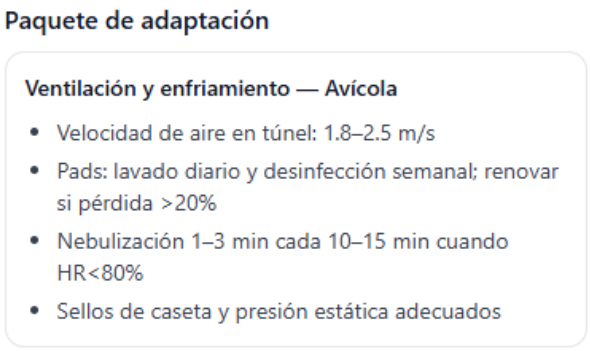


Figura 98 Recomendaciones según parámetros

4.5.2 Esquemas de adaptación para el sector agrícola (cultivo de caña de azúcar)

El cultivo de caña de azúcar enfrenta condiciones ambientales que requieren estrategias de adaptación integradas, donde el manejo del clima, el agua, el suelo y la nutrición desempeñan un papel fundamental. En relación con el microclima, la caña como especie alcanza su mayor eficiencia fotosintética entre 27 y 35 °C, aunque por arriba de 34–36 °C se reduce el crecimiento y se destina más carbono a fibra en detrimento de la sacarosa (Inman-Bamber & Smith, 2005) En germinación, el rango óptimo es de 20–30 °C.

Por su parte, el drenaje resulta esencial, ya que el encharcamiento promueve pérdidas de nitrógeno, mayor incidencia de enfermedades como la red rot y toxicidades asociadas a la anaerobiosis, de modo que los drenajes parcelarios y la nivelación de suelos son prácticas recomendadas (Gomathi et al., 2015) A ello se suma la conservación hídrica mediante cobertura de residuos, que reduce la evapotranspiración y la erosión; ensayos del SASRI reportan hasta 90 % menos pérdida de agua respecto a suelos desnudos, además de mayor resiliencia frente a olas de calor (Thorburn et al., 2011)

El manejo del suelo complementa la adaptación climática. El rango de pH 5.5–7.5 es el más adecuado para la caña, por debajo de 5.5 se reduce la disponibilidad de nutrientes y se recomienda encalar para mejorar la absorción de P y N (de Camargo Santos et al., 2022) La incorporación de materia orgánica a través de compost, “filter cake” o el rastrojo de cosecha mejora la capacidad de intercambio catiónico, la infiltración y el aporte de nutrientes, y se asocia con mayor productividad y estabilidad de los sistemas cañeros (Thorburn et al., 2011)

La fertilización debe ajustarse a análisis de suelo y hoja y fraccionarse en ambientes de alta lixiviación, equilibrando N con K para mejorar productividad y reducir pérdidas (Silva et al., 2022) .

La Figura 99 presenta un esquema integral de adaptación para el cultivo de caña de azúcar, en el que se articulan prácticas relacionadas con el manejo del agua, la temperatura, el suelo, la nutrición y el control sanitario. El bloque inicial

contempla la regulación de la humedad del suelo, mediante sistemas de riego, mulching y uso de retenedores, así como medidas para el exceso de humedad, como la reducción del riego, el mejoramiento de drenajes y la labranza. En cuanto al microclima, se enfatiza la importancia de mantener la temperatura en el rango óptimo (25–30 °C) a través de riego adicional, protectores foliares y la instalación de mallas de sombra cuando se superan los 40 °C, estrategias que reducen el impacto del estrés térmico y sostienen la eficiencia fotosintética.

El rendimiento también se vincula al acondicionamiento del suelo y la fertilización. Se incluyen prácticas como la aplicación de materia orgánica (compost, estiércol, residuos de cosecha), el control de pH mediante cal agrícola o yeso según el tipo de limitante, y la fertilización balanceada con N, P, K y micronutrientes esenciales, en combinación con rotación de cultivos y el uso de leguminosas para mejorar la fijación biológica de nitrógeno. Estas medidas se complementan con la aplicación de fertilizantes foliares y bioestimulantes, que favorecen el metabolismo de la planta bajo condiciones adversas.

La sanidad del cultivo constituye otro eje del esquema, donde se integran el monitoreo constante de enfermedades, el control biológico de plagas y las prácticas agrícolas de limpieza. El bloque final, referido al tratamiento digital de imágenes, representa la conexión entre las prácticas agronómicas y el análisis tecnológico. Este componente se vincula directamente con la detección y seguimiento de las principales enfermedades de la caña (mosaic, rust, yellow y red rot), a través de modelos de procesamiento digital que permiten generar diagnósticos tempranos y fortalecer las decisiones de manejo. El esquema sintetiza un enfoque adaptativo que combina medidas agronómicas tradicionales con innovaciones tecnológicas, asegurando mayor resiliencia del sistema cañero frente a escenarios de cambio climático y a la presión de factores bióticos y abióticos.

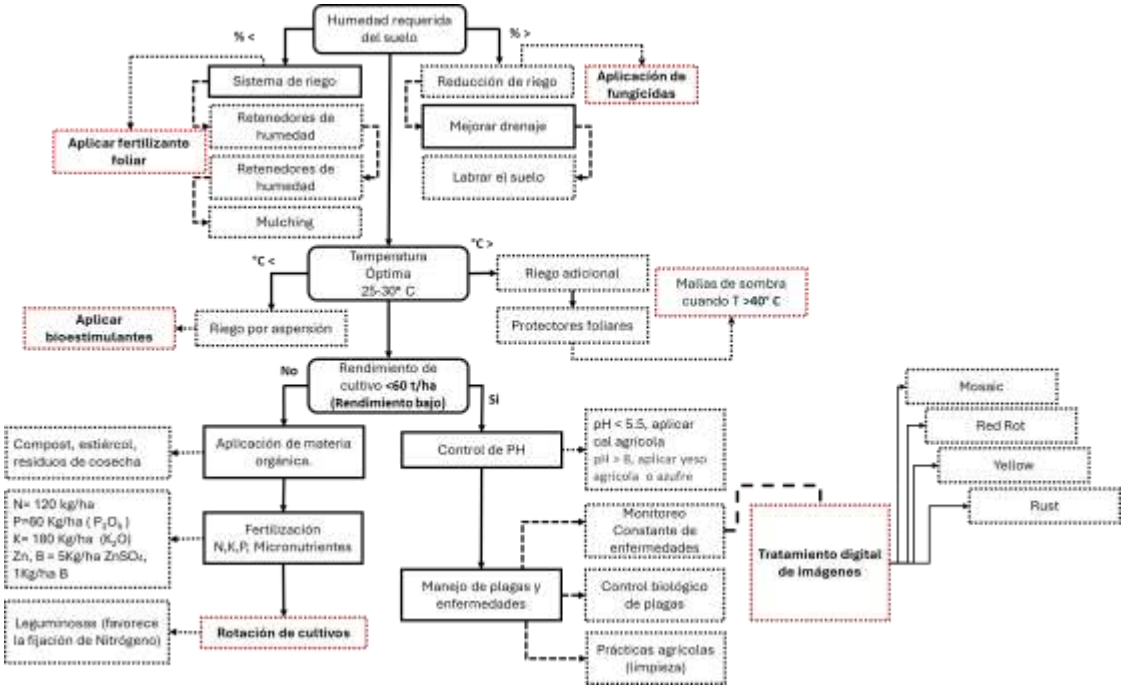


Figura 99 Esquema integral de adaptación para el cultivo de caña de azúcar

Las enfermedades detectadas por la red neuronal de tratamiento de imágenes, requiere un paquete específico de acción para contrarrestar los efectos en el cultivo, las tablas 37-40 muestran las acciones requeridas por severidad de infección y cantidades recomendadas según sea el caso.

A. Mosaic (SCMV/SCSMV, viral), *prioridad 1 en calidad (ATR)*

Tabla 37 Planes de acción por severidad para MOSAIC

Severidad	Gatillo típico	Objetivo	Acción / Producto	Dosis / Intervalo	Observaciones
Baja	Incidencia ≤2%	Contener focos	Rogueo de plantas sintomáticas	Inmediato	Enterrar/quema controlada fuera de lote
		Bajar presión de vector	Aceite mineral hortícola 0.5–1%	2–4 L/ha en 200–400 L de agua, cada 10–14 d si hay áfidos	Mejora sobrecolonización del vector
Media	Incidencia 3–10% o brotes localizados	Cortar transmisión	Flupyradifurone 200 g/L (200–400 mL/ha) o Sulfoxaflor 50% (80–160 g p/ha)	10–14 d, rotar MoA	Priorizar bordes y focos
		Robustecer planta	Bioestimulante (algas 1–2 L/ha)	1–2 aplicaciones	En horas frescas
Alta / Muy alta	Incidencia >10% y caída de ATR	Renovar material y evitar penalización	Semilla certificada libre de virus; corte anticipado y segregación de caña	3–7 d	Monitoreo vector diario; reestablecer semillero

B. Red Rot (Colletotrichum falcatum, fúngica); *prioridad 1 en rendimiento (TCH)*

Tabla 38 Planes de acción por severidad para RED ROT

Severidad	Gatillo típico	Objetivo	Acción / Producto	Dosis / Intervalo	Observaciones
Baja	Tallos aislados con síntomas	Remediar focos y semilla	Tratamiento de setts: agua caliente 50 °C × 120 min (o 52 °C × 30–45 min)	Pre-siembra	Complementar con saneamiento de herramientas
		Biocontrol	*Trichoderma spp.* 10^7 UFC/mL (inmersión setts 10–15 min)	Pre-siembra	Alternativa: polvo 2–4 kg/ha al surco
Media	Manchas internas en varios surcos	Contener y proteger follaje	Propiconazole 250 g/L (0.25–0.5 L/ha) *o* Azoxystrobin 200–250 g/L (0.3–0.5 L/ha)	14–21 d, máx. 2 aplicaciones	Volumen 200–300 L/ha
		Reducir predisposición	Drenaje (0.2–0.3%); N:K = 1:1–1:1.5	–	Evitar exceso de N
Alta / Muy alta	Síntomas generalizados y caída de R	Renovar y aislar	Erradicación de surcos + corte temprano en 7–14 d		Reestablecer con semilla tratada

C. Yellow leaf (SCYLV, viral); *prioridad intermedia*

Tabla 39 Planes de acción por severidad para YELLOW

Severidad	Gatillo típico	Objetivo	Acción / Producto	Dosis / Intervalo	Observaciones
Baja	Plantas aisladas con amarillamiento	Verificar y contener	Test ELISA/RT-PCR en 10% del semillero	–	Mapear focos
		Reducir vector	Aceite mineral 0.5–1%	2–4 L/ha en 200–400 L, cada 10–14 d	Si áfidos activos
Media	Incidencia 3–10%	Cortar transmisión	Flupyradifurone 200–400 mL/ha *o* Sulfoxaflor 80–160 g/ha	10–14 d	Rotar MoA
		Proteger ATR	Riego de alivio y K en rango alto (≥180–200 kg K_2O/ha)	–	Minimiza caída de azúcares
Alta / Muy alta	Incidencia >10% + caída de ATR	Renovar y segregar	Rogueo masivo + corte anticipado y segregación	3–7 d	Semilla certificada para reposición

D. Rust – Roya parda (Puccinia melanocephala, fúngica)

Tabla 40 Planes de acción por severidad para RUST

Severidad	Gatillo típico	Objetivo	Acción / Producto	Dosis / Intervalo	Observaciones
Baja	Pústulas esporádicas (<1%)	Contener y monitorear	Vigilancia semanal + nutrición con K alto; Si 200–400 kg/ha (opcional)	–	Retirar residuos muy infectados
Media	>1–5% plantas con pústulas y clima predisponente (HR>70%, 20–28 °C)	Romper ciclo	Propiconazole 0.25–0.5 L/ha *o* Azoxystrobin 0.3–0.5 L/ha	14–21 d	200–300 L/ha; alternar triazol/estrobilurina
Alta / Muy alta	>5–10% y avance rápido	Contener y proteger ATR	2ª aplicación a 14–21 d; evaluar corte temprano si ATR cae	–	Integrar variedades moderadamente resistentes en reposición

4.5.2.1 Interfaz interactiva para sector agrícola (Cultivo de caña de azúcar)

La interfaz diseñada para el sector agrícola, específicamente orientada al cultivo de caña de azúcar, constituye una herramienta interactiva que permite analizar los

escenarios de pérdida asociados a la presencia de enfermedades y a las condiciones climáticas que favorecen su propagación. Este dashboard integra los resultados de los modelos de predicción en un formato visual y dinámico, facilitando la comprensión de la relación entre factores ambientales —como temperatura, amplitud térmica, humedad y viento, y el riesgo de afectación en el rendimiento y calidad del cultivo. El objetivo de esta plataforma es ofrecer un espacio intuitivo para la interpretación de los resultados, donde los usuarios puedan identificar de manera rápida los niveles de riesgo, anticipar posibles brotes y evaluar medidas de manejo adaptativo. Con ello, se busca fortalecer la toma de decisiones en el ámbito agrícola y aportar una visión clara sobre las implicaciones productivas de las enfermedades de la caña de azúcar bajo distintos escenarios de cambio climático.

Selección de enfermedad y parámetros iniciales

En este apartado de la interfaz se establece la enfermedad principal que se utilizará para el cálculo de los escenarios de pérdida. El usuario puede elegir entre las diferentes opciones disponibles (Red Rot, Rust, Yellow, Mosaic) y definir la severidad del brote mediante categorías predefinidas (Baja, Media, Alta o Muy Alta). Adicionalmente, se introducen los valores potenciales de rendimiento (TCH en t caña/ha) y calidad (ATR en kg/t), que representan los rendimientos esperados bajo condiciones ideales. Esta configuración inicial constituye la base sobre la cual se simulan los impactos de cada enfermedad y se generan los resultados comparativos en las tablas posteriores (Figura 100).

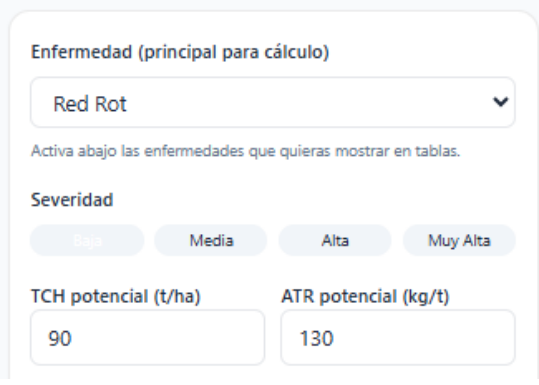


Figura 100 Selección de enfermedad y parámetros iniciales

Riesgo y condiciones edafoclimáticas

En esta sección se visualiza el Índice de Riesgo (FIS), que integra la severidad de la enfermedad seleccionada con las condiciones ambientales registradas. El valor obtenido (en este caso 0.62) se clasifica en un semáforo de colores que orienta la urgencia de intervención, además de sugerir periodos aproximados de acción correctiva.

Asimismo, se muestran variables críticas para el cultivo: la temperatura (°C), acompañada de su impacto relativo; la humedad (%), con metas de referencia (60–80% de capacidad de campo); y el pH del suelo, con intervalos óptimos (5.8–7.0). Finalmente, el usuario puede activar la visualización de tablas específicas para cada enfermedad (Mosaic, Red Rot, Yellow, Rust), lo que permite un análisis comparativo más detallado (Figura 101).



Figura 101Parámetros de riesgo y condiciones edafoclimáticas

A partir de la definición de la enfermedad y los parámetros iniciales, así como de la estimación del índice de riesgo y las condiciones edafoclimáticas asociadas la interfaz genera automáticamente las estimaciones productivas del cultivo de caña de azúcar. En este nivel de la interfaz se integran los resultados en términos de rendimiento, calidad y azúcar recuperable, lo que permite al usuario visualizar de manera cuantitativa las pérdidas ocasionadas bajo los escenarios planteados (Figura 102).



Figura 102 Estimaciones de rendimiento, calidad y azúcar

Estimaciones de rendimiento y calidad

Comparando los valores potenciales con los estimados bajo la influencia de la enfermedad y las condiciones ambientales. El tablero muestra tres indicadores clave:

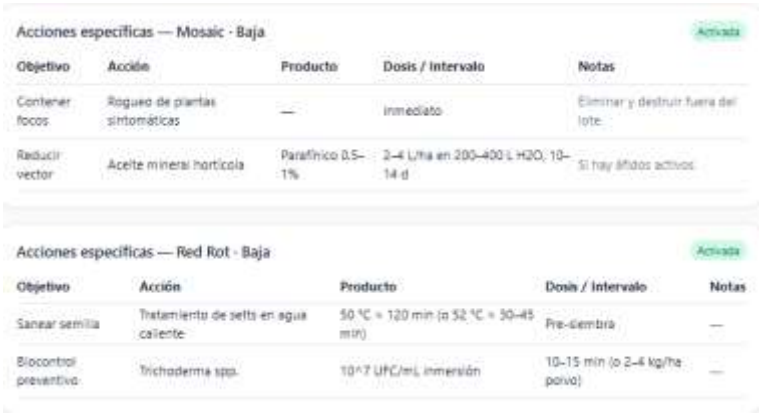
1) Rendimiento estimado (t/ha): refleja la producción de caña en campo, señalando la pérdida porcentual respecto al potencial inicial
2) Calidad estimada (kg ATR/t): indica la concentración de azúcares en la caña, expresada como ATR, junto con la pérdida asociada (%).
3) Azúcar estimada (t/ha): representa la cantidad total de azúcar recuperable por hectárea, calculada a partir del rendimiento y la calidad, con la base de referencia correspondiente.

Acciones de manejo por enfermedad

Es donde la interfaz despliega las recomendaciones de manejo específicas para cada enfermedad seleccionada y de acuerdo con su nivel de severidad (Figura 103). El sistema organiza la información en tablas que nos dice:

- Objetivo de la acción (ej. contener focos, reducir vector, sanear semilla, biocontrol preventivo).
- Acción sugerida, que puede incluir prácticas culturales como el roguedo de plantas sintomáticas o tratamientos de semilla.
- Producto recomendado, ya sea un insumo químico (aceite mineral hortícola) o biológico (Trichoderma spp.).

- Dosis e intervalo de aplicación, con rangos adaptados a la práctica correspondiente.
- Notas complementarias, que indican consideraciones técnicas, como la eliminación de residuos fuera del lote o condiciones de aplicación.



Acciones específicas — Mosaic · Baja

Activada

Objetivo	Acción	Producto	Dosis / intervalo	Notas
Contener focos	Rogueo de plantas sintomáticas	—	inmediato	Eliminar y destruir fuera del lote
Reducir vector	Aceite mineral hortícola	Parafínico 0.5–1%	2–4 L/ha en 200–400 L H2O, 10–14 d	Si hay áfidos activos

Acciones específicas — Red Rot · Baja

Activada

Objetivo	Acción	Producto	Dosis / intervalo	Notas
Sanear semilla	Tratamiento de setts en agua caliente	50 °C × 120 min (o 52 °C × 30–45 min)	Pre-siembra	—
Biocontrol preventivo	Trichoderma spp.	10^7 UFC/mL inmersión	10–15 min (o 2–4 kg/ha polvo)	—

Figura 103Acciones específicas de manejo para enfermedades

4.5.3 impacto en las cadenas de suministro

Los resultados obtenidos y el desarrollo de la interfaz para cada sector no solamente tienen impacto en la estimación de riesgos productivos, sino que también permiten visualizar las implicaciones en la logística agroalimentaria y la seguridad alimentaria regional. Al integrar los módulos agrícola y pecuario dentro de un marco común, se observa que las reducciones en rendimiento de caña de azúcar y los incrementos en riesgos sanitarios pecuarios trascienden el ámbito productivo para manifestarse en presiones sobre la cadena de suministro. La Tabla 41. resume esta articulación, mostrando cómo los choques climáticos y sanitarios detectados por el modelo se traducen en efectos logísticos concretos y, a su vez, en consecuencias sobre la disponibilidad y el acceso a alimentos. Esta perspectiva refuerza la idea de que la resiliencia agropecuaria no puede limitarse al manejo en campo, sino que debe extenderse hacia los nodos críticos de transporte, almacenamiento y distribución, donde se define la capacidad del sistema para sostener la seguridad alimentaria bajo escenarios adversos.

Tabla 41 Relación entre impactos productivos, efectos logísticos y seguridad alimentaria

Impacto productivo (modelo IA + FIS)	Efecto en la logística agroalimentaria	Consecuencia en seguridad alimentaria
Reducción de 12–15% en rendimiento de caña de azúcar (ΔR = –1.5 t/ha; ΔATR = –8 kg/t)	Menor disponibilidad de materia prima para ingenios azucareros; incremento en costos de almacenamiento y transporte de insumos alternativos	Incremento en precios del azúcar y derivados; menor acceso a productos básicos en mercados locales
Incremento del 35% en riesgo sanitario bovino bajo alta humedad y amplitud térmica	Mayor necesidad de transporte especializado (cadena de frío, bioseguridad); incremento en tiempos de distribución por controles sanitarios	Disminución en disponibilidad de carne y leche; riesgo de encarecimiento de proteínas animales
Brotes de enfermedades en caña (Yellow Leaf, Red Rot) con propagación rápida en climas húmedos-ventosos	Necesidad de redirigir flujos de transporte hacia zonas no afectadas; mayores inventarios de seguridad para industrias agroalimentarias	Desabasto regional temporal; vulnerabilidad de cadenas de valor agroindustriales (azúcar, bioetanol)
Estrés hídrico y reducción de disponibilidad de agua para riego y ganado	Aumento en costos de transporte de agua y forraje; disrupción en la logística de abastecimiento pecuario	Riesgo de pérdida de peso y productividad animal; menor calidad nutricional en la dieta de la población
Escenarios inerciales (sin adaptación) con pérdidas acumuladas al 2030 (–15% agrícola; –12% pecuario)	Desajustes estructurales en la cadena logística (oferta inestable, sobrecostos en transporte y almacenamiento)	Vulnerabilidad de mercados locales y regionales; mayor dependencia de importaciones; reducción de la resiliencia alimentaria

4.6 Conclusión del capitulo

Este capítulo presenta de manera integrada los resultados derivados de los distintos modelos aplicados al sector agropecuario, combinando análisis de sensibilidad, simulaciones multi escenario y técnicas avanzadas de redes neuronales y lógica difusa. Los hallazgos evidencian cómo las variaciones en la disponibilidad de recursos hídricos, la extensión de tierras agrícolas y pecuarias, y las emisiones de gases de efecto invernadero inciden directamente en la vulnerabilidad del sistema productivo, destacando la necesidad de implementar medidas de adaptación oportunas.

En el componente de modelado satelital y redes neuronales, logran un desempeño sólido en la identificación de patrones climáticos y enfermedades foliares en caña de azúcar, alcanzando niveles de precisión superiores al 90 %, lo que respalda su utilidad como herramienta de apoyo para la gestión agroclimática. Por su parte, los sistemas difusos permiten estimar riesgos tanto para la salud pecuaria como para la probabilidad de enfermedades en caña, confirmando la influencia conjunta de factores climáticos, fisiológicos y nutricionales.

En conjunto, estos resultados proporcionan una base empírica y metodológica para priorizar acciones de mitigación y adaptación en el sector agropecuario,

fortaleciendo la resiliencia productiva ante escenarios de cambio climático y contribuyendo a la toma de decisiones estratégicas en la gestión sostenible de recursos y la protección de la producción agrícola y pecuaria.

4.7 Discusión de resultados

Los resultados obtenidos en esta investigación permiten realizar una comparación crítica con diversos estudios previos, destacando tanto coincidencias como diferencias sustanciales. En concordancia con lo planteado por (Monterroso et al., 2007) se confirma que el estado de Veracruz presenta alta sensibilidad climática, particularmente en cultivos estratégicos como el maíz y la caña de azúcar, debido a la reducción de lluvias y al incremento de temperaturas. Sin embargo, su trabajo se sustenta en escenarios de proyección climática a través de metodologías IPCC, el presente estudio incorpora herramientas de inteligencia artificial (CNN y lógica difusa) y procesamiento de imágenes satelitales, lo que permite obtener un análisis dinámico y con mayor granularidad espacial.

En relación con el modelo multiagente propuesto por (A. E. Badillo, 2021), centrado en la valoración de riesgos agrícolas en caña, la presente investigación amplía el alcance al integrar también el sector pecuario y un módulo de proyección económica, lo que refuerza la aplicabilidad de los resultados en la toma de decisiones productivas. De manera adicional, la inclusión de algoritmos de clasificación basados en redes neuronales convolucionales demuestra una capacidad predictiva con precisiones superiores al 90%, lo que representa un avance respecto otros enfoques. Asimismo, si bien Altieri y Nicholls (2018) subrayan que la adaptación agropecuaria debe orientarse hacia la agroecología y la reducción de dependencia de insumos externos, este estudio aporta una visión complementaria al demostrar que la resiliencia puede fortalecerse también a partir de herramientas digitales y de monitoreo en tiempo real, sin excluir la pertinencia de prácticas agroecológicas. En contraste con los reportes de la FAO (2019, 2023), que proyectan reducciones globales de entre 10% y 25% hacia 2050, las proyecciones de este estudio para Veracruz estiman pérdidas del 12–15% en caña y del 12% en producción pecuaria hacia 2030, lo cual revela que en ciertas regiones tropicales el impacto puede manifestarse de forma más acelerada.

En esta investigación podemos denotar la relación entre la vulnerabilidad productiva y la logística agroalimentaria. La reducción estimada en rendimientos agrícolas y el aumento en riesgos pecuarios no solo afectan la estabilidad de los productores, sino que también generan presiones sobre los sistemas de transporte, almacenamiento y distribución. Esto se traduce en la necesidad de mayor capacidad en cadenas de frío, incremento de costos logísticos, riesgos de desabasto y reconfiguración de rutas de abasto. Este hallazgo coincide con los planteamientos de estudios de seguridad alimentaria global (HLPE, 2020; FAO, 2021), que señalan que los impactos del cambio climático se amplifican al trasladarse a los eslabones logísticos de las cadenas agroalimentarias. En este sentido, el modelo propuesto no solo aporta a la estimación de riesgos productivos, sino que también ofrece insumos para la gestión del riesgo en las cadenas de suministro, fortaleciendo la resiliencia alimentaria a nivel regional.

CONCLUSIONES

El presente trabajo de investigación permite demostrar que el sector agropecuario, y en particular el estado de Veracruz enfrenta una vulnerabilidad creciente ante los efectos del cambio climático, lo cual compromete la seguridad alimentaria, la estabilidad económica regional y la sostenibilidad de los sistemas productivos. A partir del diseño de un modelo integral de vulnerabilidad y riesgo que combina metodologías de inteligencia artificial, lógica difusa, procesamiento digital de imágenes y simulación multiagente, se logra alcanzar el objetivo de proponer esquemas de adaptación que fortalezcan la resiliencia de la agricultura y la ganadería. La integración de estas herramientas demostró que es posible anticipar escenarios, cuantificar riesgos y generar alternativas de manejo que superan las aproximaciones tradicionales basadas únicamente en estadísticas históricas o proyecciones climáticas.

En primera instancia, la construcción de indicadores de vulnerabilidad a partir de variables biofísicas y socioeconómicas permitió generar un diagnóstico sólido de la exposición y sensibilidad del sector agropecuario. Se comprobó que el incremento de temperatura y la disminución de la precipitación constituyen los principales factores de presión, cuya interacción puede reducir la disponibilidad hídrica hasta en un 20% y afectar directamente la capacidad productiva de los suelos agrícolas. Este hallazgo se vincula con el objetivo específico de desarrollar indicadores de vulnerabilidad para alimentar el modelo multiagente, el cual, mediante simulaciones dinámicas, confirma que la combinación de sequías prolongadas y emisiones de gases de efecto invernadero conduce a pérdidas acumuladas en el rendimiento de cultivos de caña de azúcar superiores al 15% hacia 2030 en escenarios de alto riesgo.

En relación con la validación histórica del modelo, se evidencia que las proyecciones obtenidas guardan coherencia con las tendencias empíricas observadas en la última década en Veracruz, donde los registros de producción cañera y pecuaria han mostrado fluctuaciones estrechamente ligadas a la variabilidad climática.

La dinámica de sistemas implementada en AnyLogic permite comprobar que la resiliencia del sector depende en gran medida de la capacidad de anticipar y gestionar estos impactos. Bajo escenarios inerciales, el modelo proyecta caídas sostenidas en la producción, mientras que la incorporación de esquemas de adaptación temprana permite mitigar las pérdidas en un rango del 8 al 12%, lo que representa una diferencia sustancial en términos de seguridad alimentaria y rentabilidad económica.

En el ámbito metodológico, la aplicación de procesamiento digital de imágenes satelitales del producto *Tope de Nubes* constituye un aporte relevante, al permitir la extracción automática de variables climáticas derivadas de segmentaciones cromáticas. Estas variables se integran con éxito en un sistema de clasificación basado en redes neuronales convolucionales, alcanzando niveles de precisión superiores al 90% en la detección de enfermedades de caña de azúcar. Es importante destacar que enfermedades como *Yellow Leaf* y *Red Rot* mostraron impactos más significativos en el rendimiento y la calidad, reduciendo el rendimiento en –1.5 t/ha y el ATR en –8 kg/t en escenarios de severidad alta, mientras que *Mosaic* y *Rust* presentaron efectos más dispersos, pero con potencial de propagación rápida bajo condiciones ambientales favorables. Con ello se cumplió el objetivo de desarrollar un modelo predictivo de enfermedades agrícolas que supera el enfoque exclusivamente descriptivo, incorporando un componente de inteligencia artificial robusto y cuantificable.

El uso de sistemas difusos fortalece la capacidad de interpretar la información climática y productiva bajo condiciones de incertidumbre. En el sector pecuario, se verifica que la combinación de amplitud térmica elevada y humedad relativa alta incrementa en hasta un 35% la probabilidad de riesgos sanitarios, especialmente enfermedades respiratorias en bovinos. Este resultado valida la pertinencia de la lógica difusa como herramienta para traducir datos satelitales y climáticos en estimaciones prácticas de riesgo, lo que representa un valor agregado frente a metodologías convencionales que no logran capturar la complejidad no lineal de los sistemas agropecuarios.

A nivel sistémico, la integración del modelo multiagente con los módulos de CNN y lógica difusa permitie visualizar la vulnerabilidad agropecuaria como un fenómeno interconectado, donde los factores climáticos no solo afectan directamente a los cultivos y al ganado, sino que también repercuten en la economía local y en la seguridad de los productores. El modelo proyecta que, en ausencia de estrategias de adaptación, los efectos combinados del cambio climático podrían reducir la rentabilidad de la producción pecuaria en un 12% hacia 2030, al tiempo que comprometen la calidad del azúcar producido en caña, lo cual genera efectos en cascada en las cadenas de valor agroindustriales.

La reducción proyectada de 12–15% en el rendimiento de caña de azúcar y el incremento de 35% en el riesgo sanitario pecuario no solo comprometen la estabilidad de los productores, sino que repercuten directamente en la logística agroalimentaria, al tensionar los eslabones de abasto, transporte, almacenamiento y distribución. En el caso agrícola, una menor disponibilidad de caña impacta la programación de zafra e inventarios de materia prima en ingenios, incrementa la variabilidad del flujo hacia plantas de molienda y eleva los costos unitarios por tiempos ociosos y reconfiguración de rutas cuando hay que abastecerse desde zonas menos afectadas. En el ámbito pecuario, el mayor riesgo sanitario eleva la demanda de cadena de frío (transporte refrigerado y almacenamiento a temperatura controlada), añade tiempos de inspección y bioseguridad en centros de acopio y rastros, y obliga a incrementar inventarios de seguridad para sostener niveles de servicio ante picos de morbilidad. En conjunto, esto se traduce en mayores costos logísticos (combustible, mantenimiento, arrendamiento de frío, merma por caducidad), mayores “lead times” (por controles y desvíos) y riesgos de desabasto en mercados locales y regionales.

La articulación entre vulnerabilidad productiva y desempeño logístico demuestra que la resiliencia debe abordarse también en los nodos y flujos de transporte, almacenamiento y distribución: (i) dimensionando capacidad de cadena de frío ante escenarios sanitarios adversos, (ii) rediseñando rutas con orígenes alternativos cuando el riesgo agrícola concentra mermas en ciertas cuencas, (iii) ajustando políticas de inventario (p. ej., mayores stocks de seguridad de azúcar

crudo y productos cárnicos/lácteos en temporada crítica) y (iv) estableciendo umbrales de alerta en el dashboard que conecten directamente indicadores de riesgo (SCDP en caña; LSHR en pecuario) con KPI logísticos (fill rate, días de inventario, utilización de frío, OTIF). En este contexto, los resultados de proyección de valor de producción y ajustes por riesgo (Figuras 37–41), así como con las superficies y tornados por enfermedad (Sección 4.4), permiten priorizar cuellos de botella logísticos según el tipo de choque (merma en caña por Yellow/Red Rot; presión de frío por riesgo pecuario). De ese modo, el marco IA–FIS–ABM opera como sistema de soporte logístico para planear capacidad, rutas e inventarios en escenarios climáticos y sanitarios adversos.

En contraste, la aplicación de esquemas de adaptación basados en la optimización del riego, ajustes en la fertilización, incorporación de tecnologías digitales de monitoreo y control fitosanitario permite contener parte de estas pérdidas, aportando una visión estratégica para la gestión futura del sector.

En conjunto, las conclusiones alcanzadas en este trabajo reflejan no solo la pertinencia del marco metodológico empleado, sino también la urgencia de avanzar hacia una agricultura y ganadería sustentadas en herramientas tecnológicas capaces de anticipar escenarios, cuantificar impactos y orientar decisiones bajo condiciones de alta incertidumbre. La combinación de inteligencia artificial, lógica difusa y simulación multiagente representa un aporte innovador en el análisis de la vulnerabilidad agropecuaria, al permitir no solo describir tendencias, sino generar propuestas concretas de adaptación. Así, esta tesis contribuye a la generación de conocimiento científico aplicable y de relevancia práctica, que puede ser replicado y escalado a otros contextos regionales, fortaleciendo el papel de la investigación interdisciplinaria en la construcción de sistemas productivos más resilientes frente al cambio climático.

- ***Evolución del estado del arte***

i. Se amplía la literatura sobre vulnerabilidad agropecuaria en México integrando de manera simultánea el sector agrícola (caña de azúcar) y el sector pecuario, bajo un mismo marco metodológico.

ii. Se introduce un enfoque interdisciplinario que articula procesamiento satelital, redes neuronales convolucionales, lógica difusa y modelos multiagente, superando estudios fragmentados que se limitan a una sola dimensión.

iii. Se generan proyecciones específicas y cuantificables para Veracruz, región poco abordada en la literatura con esta combinación metodológica.

- ***Aportaciones tecnológicas y prácticas***

i. Desarrollo de un sistema de clasificación basado en CNN capaz de identificar enfermedades en caña de azúcar con precisiones >90%, lo que representa un avance frente a enfoques convencionales.

ii. Creación de un sistema difuso que traduce parámetros climáticos obtenidos por segmentación cromática en estimaciones de riesgo agrícola y pecuario, constituyendo un puente entre la teledetección y la toma de decisiones en campo.

iii. Propuesta de un marco metodológico que combina técnicas de inteligencia artificial con modelos de simulación y sistemas de inferencia, aportando un ejemplo replicable para otros cultivos y regiones.

iv. Diseño de esquemas de adaptación diferenciados para caña y ganado, incluyendo desde planes de manejo fitosanitario hasta ajustes en prácticas de alimentación y uso eficiente del agua.

v. Desarrollo de interfaces interactivas que facilitan la interpretación de escenarios de riesgo y la identificación de acciones específicas por parte de los productores y tomadores de decisiones.

- ***Limitaciones***
  i. El tamaño reducido en algunas clases de enfermedades (especialmente Mosaic y Rust), lo que afecta la capacidad de generalización del modelo CNN.
  ii. La dependencia de la calibración de funciones de pertenencia en los sistemas difusos, que, aunque basada en criterios expertos y literatura científica, introduce cierto grado de subjetividad.
  iii. La proyección económica se construyó bajo supuestos determinísticos, sin incorporar aún la volatilidad de precios internacionales, los choques de mercado o la variabilidad en políticas agrícolas.
- ***Recomendaciones***
  i. Incrementar el número de imágenes de clases con desempeño menor en la CNN, como Mosaic y Rust, explorando arquitecturas más complejas como EfficientNet o ResNet y técnicas de explainable AI para mejorar la interpretabilidad.
  ii. Validar los sistemas difusos en interacción directa con productores locales, ajustando reglas y funciones de pertenencia con base en conocimiento empírico, reduciendo así la subjetividad en la calibración.
  iii. Fortalecer la integración con modelos estocásticos y econométricos para proyectar impactos financieros a mediano y largo plazo en cadenas agroindustriales.
  iv. Creación de base de datos de enfermedades pecuarias por especie para tratamiento de imágenes y creación de un sistema similar al modelo de enfermedades de caña

Bibliografía

Addy, H. S., Nurmalasari, Wahyudi, A. H. S., Sholeh, A., Anugrah, C., Iriyanto, F. E. S., Darmanto, W., & Sugiharto, B. (2017). Detection and response of sugarcane against the infection of sugarcane mosaic virus (SCMV) in Indonesia. *Agronomy, 7*(3), 50.

Acevedo M., E., & Serna A., A. (2017). Principios y características de las redes neuronales artificiales. En E. Serna M. (Ed.), *Desarrollo e innovación en ingeniería* (pp. 173–182). Medellín: Editorial IAI.

Agudelo Otálora, L., Moscoso Barrera, W., Paipa-Galeano, L., & Mesa Sciarrotta, C. (2020). Comparación de modelos físicos y de inteligencia artificial para predicción de niveles de inundación. *Tecnología y Ciencias del Agua*. (SciELO).

Alexander, E., Battikk, M., & Mendoza, A. (2015). Métodos numéricos para la predicción de inundaciones. *Journal of Undergraduate Research*, 28–33.

Altieri, M. A., & Nicholls, C. (2018). Agroecología y cambio climático: ¿Adaptación o transformación? *Revista de Ciencias Ambientales*, 52, 235–243.

Anderson, D. L. (1986). Relationship of rust severity and plant nutrients in sugarcane. *Phytopathology*.

Andrade, I. (2009). Aplicación de la TD en la obtención de datos para mitigar la incertidumbre en el riesgo hídrico. *Memoria Académica*.

Badillo, A. E. (2021). *Evaluación de vulnerabilidad y riesgo agrícola ante el cambio climático a través de un sistema multi-agentes*. Instituto Tecnológico Nacional de México.

Badillo, D. (2025). *Cosechando soberanía*.

Bailey, R. (2019). *Diseases of sugarcane* (Vol. 1). CRC Press.

Banco Mundial. (2022). *Lo que debe saber sobre la seguridad alimentaria y el cambio climático*.

Barrera, W., Hoy, J., & Li, B. (2012a). Effects of temperature and moisture variables on brown rust of sugarcane. *Journal of Phytopathology, 161*(2), 98–106.

Barrera, W., Hoy, J., & Li, B. (2012b). Temperature and leaf wetness effects on infection of sugarcane by *Puccinia melanocephala*. *Journal of Phytopathology, 160*(6), 294–298.

Belmonte, I., & Caamaño, S. (2009). Una aplicación basada en imágenes SAR para el monitoreo y prevención de inundaciones en Argentina. Córdoba,

Argentina: Facultad de Matemáticas, Astronomía y Física, Universidad Nacional de Córdoba.

Boden, M. (2017). *Inteligencia artificial*. Madrid: Turner.

Carrasco Fonseca, J. (2017). Aplicación de la logística humanitaria para atender la emergencia ocasionada por El Niño costero en Piura. Piura, Perú: Universidad de Piura.

CENAPRED. (2019). *Centro Nacional de Prevención de Desastres*.

Cervantes Osornio, R., & Arteaga Ramírez, R. (2010). *Redes neuronales artificiales para estimar y predecir variables climatológicas relacionadas con la evapotranspiración de referencia*. Universidad Autónoma de Chapingo.

Chatenet, M., Letourmy, P., Girard, J., & Feldmann, P. (2001). Impact of brown rust (*Puccinia melanocephala*) on sugarcane yield in Guadeloupe. *Crop Protection*, 301–305.

Comité Nacional para el Desarrollo Sustentable de la Caña de Azúcar. (2015). *Ficha técnica del cultivo de la caña*. SAGARPA.

Datnoff, L. E., Elmer, W. H., & Rodrigues, F. A. (2023). Front matter. In *Mineral nutrition and plant disease* (2nd ed., pp. i–iv).

de Camargo Santos, A., McCray, J. M., Daroub, S., Rowland, D., Ji, S., & Sandhu, H. (2022). Nitrogen management of shallow Florida histosols for sugarcane production. *Journal of Plant Nutrition, 45*(20), 3045–3056.

Díaz Cordero, G. (2012). El cambio climático. *Ciencia y Sociedad, 37*, 227–240.

Domínguez, A. (1996). Procesamiento digital de imágenes. *Perfiles Educativos*. Distrito Federal, México.

EALDE School. (2023, octubre 22). *Logística, emergencias y desastres*.

El Proyecto Esfera. (2011). *Carta humanitaria y normas mínimas para la respuesta humanitaria*. Practical Action Publishing.

Encuesta Nacional Agropecuaria (ENA). (2018). *Comunicado de prensa 304/18: Principales cultivos del país*.

Espinosa Oviedo, J. J., Vandewalle, J. P. L., & Wertz, V. (2005). *Fuzzy logic, identification and predictive control*.

FAO. (2019). *El trabajo de la FAO sobre el cambio climático*. Conferencia de las Naciones Unidas sobre el Cambio Climático.

FAO. (2023). *FAO publications catalogue 2023*.

Fischer, G., Shah, M., & van Velthuizen, H. (2002). *Climate change and agricultural vulnerability*.

Gomathi, R., Gururaja Rao, P. N., Chandran, K., & Selvi, A. (2015). Adaptive responses of sugarcane to waterlogging stress: An overview. *Sugar Tech, 17*(4), 325–338.

Gobierno de México – Secretaría de Gobernación. (2018, febrero 12). *Diario Oficial de la Federación*.

Graciela Magrín. (2007). Variabilidad climática, cambio climático y sector agropecuario. En INTA-Argentina, *ClimaLatino*.

Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC). (2012). *Gestión de los riesgos de fenómenos meteorológicos extremos y desastres para mejorar la adaptación al cambio climático*.

Guha, D. S., Vos, F., & Below, R. (2011). *Annual disaster statistical review 2011*. Brussels: CRED.

Guía Vulnerabilidad CambioClimático FAO. (s. f.). https://cambioclimatico.fao.org.co/guia_vulnerabilidad/ (consultado el 5 de junio de 2024)

Gutiérrez, O. (2022, mayo 20). *Sector agropecuario en México*. La Ciencia Económica. https://www.lacienciaeconomica.com/sector-agropecuario-en-mexico/

Hernández Uribe, R., Barrios Piña, H., & Ramírez, A. (2017). Flood risk analysis: Methodology and application to the Atemajac basin. *Tecnología y Ciencias del Agua*.

Holguín-Veras, J., Perez, N., Jaller, M., Van Wassenhove, L., & Aros-Vera, F. (2013). On the appropriate objective function for post-disaster humanitarian logistics. *Journal of Operations Management, 31*, 262–280.

Holkar, S. K., Balasubramaniam, P., Kumar, A., Kadirvel, N., Shingote, P. R., Chhabra, M. L., Kumar, S., Kumar, P., Viswanathan, R., Jain, R. K., & Pathak, A. D. (2020). Present status and future management strategies for sugarcane yellow leaf virus: A major constraint to the global sugarcane production. *The Plant Pathology Journal, 36*(6), 536.

Hoy, J. W., & Hollier, C. A. (2009a). Effect of brown rust on yield of sugarcane in Louisiana. *APS Online Publications*.

Hoy, J. W., & Hollier, C. A. (2009b). Effect of brown rust on yield of sugarcane in Louisiana. *Plant Disease, 93*(11), 1171–1174.

INEEC. (2021). *México ante el cambio climático*. https://cambioclimatico.gob.mx/impactos-del-cambio-climatico-en-mexico/

Inman-Bamber, N. G., & Smith, D. M. (2005). Water relations in sugarcane and response to water deficits. *Field Crops Research, 92*(2–3), 185–202.

Instituto Mexicano del Transporte. (2023, mayo 15). *Resumen boletines*. https://imt.mx/resumen-boletines.html?IdArticulo=444&IdBoletin=166

Instituto Mexicano de Tecnología del Agua. (2015). *Atlas de vulnerabilidad hídrica en México ante el cambio climático*.

Instituto Nacional de Ecología y Cambio Climático. (2018, mayo 18). *Efectos del cambio climático*.

IPCC. (2013). *Cambio climático: Bases físicas*.

IPCC. (2023). Food, fibre and other ecosystem products. In *Climate change 2022: Impacts, adaptation and vulnerability* (pp. 713–906).

Jiménez López, A. F. (2020). *Modelo basado en agentes inteligentes como soporte a la gestión del riego en cultivos agrícolas*. Universidad Nacional de Colombia.

Lobell, D. B., Burke, M. B., Tebaldi, C., Mastrandrea, M. D., Falcon, W. P., & Naylor, R. L. (2008). Prioritizing climate change adaptation needs for food security in 2030. *Science, 319*(5863), 607–610.

López, D. F., Nava, A. Y. S., Rojas, B. M., & González, T. D. I. (2022). *Guía de escenarios de cambio climático para tomadores de decisiones*.

López Ramírez, J. (2012). *Propuesta de planeación logística para la provisión de alojamiento en la atención de desastres por inundaciones* (Tesis). Pontificia Universidad Javeriana.

Lu, G., Wang, Z., Xu, F., Pan, Y.-B., Grisham, M. P., & Xu, L. (2021). Sugarcane mosaic disease: Characteristics, identification and control. *Microorganisms, 9*(9), 1984.

Martínez-Austria, P. F., & Patiño-Gómez, C. (2012). Efectos del cambio climático en la disponibilidad de agua en México. *Tecnología y Ciencias del Agua*, 5–20.

Montaño, J. M. (2002). *Redes neuronales artificiales aplicadas al análisis de datos*. Palma de Mallorca: Universidad de las Islas Baleares.

Monterroso Rivas, A. I., Conde Álvarez, A. C., Gómez Díaz, J. D., & López García, J. (2007). Vulnerabilidad y riesgo en agricultura por cambio climático en la región centro del estado de Veracruz, México. *Zonas Áridas, 11*, 47–60.

Mora, J., Ordaz, J. L., Ramírez, D., & Serna Hidalgo, B. (2010). *Costa Rica: Efectos del cambio climático sobre la agricultura*. CEPAL.

Mohd, S., Mertens, S., Dhondt, S., Inzé, D., Wuyts, N., & Scheunders, P. (2019). Analysis of hyperspectral images for detection of drought stress and recovery in maize plants in a high-throughput phenotyping platform. *ISPRS Journal of Photogrammetry and Remote Sensing, 162*.

Naciones Unidas. (2023, octubre 22). *¿Qué es el cambio climático?* https://www.un.org/es/climatechange/what-is-climate-change

Nardone, A., Ronchi, B., Lacetera, N., Ranieri, M. S., & Bernabucci, U. (2010). Effects of climate changes on animal production and sustainability of livestock systems. *Livestock Science, 130*(1–3), 57–69.

Narváez, A. B., Cruz, A., & Cruz, J. (2016). La complejidad y la ciudad: El uso de modelos basados en agentes autónomos (ABM) para la simulación de procesos en los imaginarios urbanos. *Revista de Urbanismo, 8*. (SciELO).

NASA. (2024, junio 9). *Los efectos del cambio climático*. https://ciencia.nasa.gov/cambio-climatico/los-efectos-del-cambio-climatico/

Office of the United Nations Disaster Relief Coordinator. (1980). *Natural disasters and vulnerability analysis: Report of Expert Group Meeting, 9–12 July 1979*. Geneva: United Nations.

Protección Civil del Estado de Veracruz. (2022). *Avenidas, desbordamientos de ríos e inundaciones*. Xalapa: Gobierno del Estado de Veracruz.

Ramouthar, P. V., Rutherford, R. S., & McFarlane, S. A. (2013). Yield loss due to sugarcane yellow leaf virus and its prevalence in the South African sugar industry. *Proceedings of the South African Sugar Technologists' Association, 86*, 244–254.

Ravinesh C. Deo, & Şahin, M. (2015). Aplicación del modelo de red neuronal artificial para la predicción del índice estandarizado de precipitación y evapotranspiración mensual utilizando parámetros hidrometeorológicos e índices climáticos en el este de Australia. *ScienceDirect*, 65–81.

Rodríguez Z., L. G., & Roggero, P. (2015). Modelos basados en agentes: Aportes epistemológicos y teóricos para la investigación social. *Revista de Metodología de Ciencias Sociales, 60*. (SciELO).

Ross, T. J. (2005). *Fuzzy logic with engineering applications*.

Salas Salinas, M. A., & Jiménez Espinosa, M. (2004). *Inundaciones*. CENAPRED.

Santillán, V. S. (2016). Emisiones de gases de efecto invernadero en sistemas agrícolas de México. *Terra Latinoamericana, 34*.

Scagliusi, S., & Lockhart, B. (2000). Transmission, characterization, and serology of sugarcane mosaic virus (SCMV) isolates from Brazil. *Plant Disease*, 622–626.

Secretaría de Agricultura y Desarrollo Rural (SADER). (2015, septiembre 26). *El cambio climático afecta al campo: ¿Cómo enfrentarlo?* https://www.gob.mx/agricultura/es/articulos/el-cambio-climatico-afecta-al-campo-como-enfrentarlo

Secretaría de Agricultura y Desarrollo Rural (SADER). (2021, marzo 13). *Caña de azúcar: Un cultivo de importancia para México*.

Secretaría de Agricultura y Desarrollo Rural (SADER). (2021, noviembre 9). *Regiones agroalimentarias de México*.

Sevillano Rodríguez, M., Bravo Peña, L., Alatorre Cejudo, L., & Salcedo Hurtado, E. (2020). Identificación de zonas de inundación a partir de imágenes SAR y de eventos históricos: Caso de estudio Santiago de Cali, Colombia. (CC BY-NC).

Sistema Estatal de Protección Civil. (2013). *Programa para la gestión y reducción de riesgo ante la temporada de lluvias y ciclones*. Xalapa: Secretaría de Protección Civil del Estado de Veracruz.

Shukla, S., Lal, M., & Singh, I. (2017). Nutrient management in sugarcane for improving yield and quality. *Indian Journal of Sugarcane Technology, 32*(1), 1–12.

Silva, M. de A., Germino, G. H., de Holanda, L. A., Oliveira, L. C., Santos, H. L., & Sartori, M. M. P. (2022). Sugarcane productivity as a function of zinc dose and application method. *Agriculture, 12*(11), 1843.

Simone Neset, T., Wiréhn, L., Opach, T., Glaas, E., & Linnér, B. O. (2019). Evaluation of indicators for agricultural vulnerability to climate change: The case of Swedish agriculture. *Ecological Indicators, 105*, 571–580.

Smith, C. (2017, noviembre 9). La intensificación de las precipitaciones provocará un aumento de la contaminación del agua en el futuro. *National Geographic*. https://www.nationalgeographic.es/medio-ambiente/2017/07/la-intensificacion-de-las-precipitaciones-provocara-un-aumento-de-la-contaminacion-del-agua-en-el-futuro

Snow, J. (2019). La inteligencia artificial podría ayudar a combatir el cambio climático. *National Geographic*.

Sterman, J. D. (2000). *Business dynamics: Systems thinking and modeling for a complex world*. Irwin/McGraw-Hill.

Sun, Y., Wang, M., Mur, L. A. J., Shen, Q., & Guo, S. (2020). Unravelling the roles of nitrogen nutrition in plant disease defences. *International Journal of Molecular Sciences, 21*(2), 572.

Thorburn, P. J., Biggs, J. S., Attard, S. J., & Kemei, J. (2011). Environmental impacts of irrigated sugarcane production: Nitrogen lost through runoff and leaching. *Agriculture, Ecosystems & Environment, 144*(1), 1–12.

UNESCO. (2012). *Glosario hidrológico internacional*.

Useros Fernández, J. (2013). El cambio climático: Sus causas y efectos medioambientales. *Real Academia de Medicina y Cirugía de Valladolid*, 71–98.

Valle, D. (2016). *Sistema electrónico de alerta temprana de incendios forestales mediante procesamiento digital de imágenes para la empresa municipal del Cuerpo de Bomberos Ambato*. Facultad de Ingeniería en Sistemas, Electrónica e Industrial.

Vega, J., Comstock, J., & Damaj, M. (2015). Sugarcane yellow leaf virus: An emerging disease. *Frontiers in Plant Science, 6*.

Viera, O., Tansini, L., & Moscatelli, S. (2012). Logística humanitaria y su aplicación en Uruguay. *GTI*, 47–56.

Viswanathan, R. (2021). Red rot of sugarcane (*Colletotrichum falcatum* Went). *CAB Reviews: Perspectives in Agriculture, Veterinary Science, Nutrition and Natural Resources, 16*(1).

Viswanathan, R., & Samiyappan, R. (2002). Biological control of red rot disease of sugarcane with antagonistic fungi *Trichoderma harzianum*. *Sugar Tech, 4*, 137–144.

Wallace, B. (2012, octubre 19). El impacto del calentamiento global en la distribución de las precipitaciones: Una perspectiva histórica. En W. Broecker, *Hay futuro: Visiones para un mundo mejor*. Madrid: BBVA. https://www.bbvaopenmind.com/articulos/el-impacto-del-calentamiento-global-en-la-distribucion-de-las-precipitaciones-una-perspectiva-historica/

Kerblat, Y., & Hill Kokoszka, M. (2024). *Sequías y déficits: Los impactos globales de las sequías en el crecimiento económico*. World Bank Group.

Zhao, Y., Sun, Y., Cai, X., Liu, H., & Schulze, P. (2012). Identify plant drought stress by 3D-based image. *Procedia Environmental Sciences, 11*(7), 1207–1211.

Lopez Ramirez , J. (2012). Propuesta de planeacion logistica para la provision de alojamiento, en la atencion de desastres por inundaciones, que pueda ser utilizada en el departamento del atlantico. Bogotá: PONTIFICIA UNIVERSIDAD JAVERIANA.

López, D. F., Nava, A. Y. S., Rojas, B. M., & González, T. D. I. (2022). Guía de Escenarios de Cambio Climático para Tomadores de Decisiones.

Martínez-Austria, P., & Patiño-Gómez, C. (Enero-Marzo de 2012). Efectos del cambio climático en la disponibilidad de agua en México. Tecnología y Ciencias del agua , págs. 5-20.

Martínez-Austria, P. F., & Patiño, C. (2012). Efectos del cambio climático en la disponibilidad de agua en México. Scielo, 3.

Mohd, S., Mertens, S., Dhondt, S., Inzé, D., Wuyts, N., & Scheunders, P. (2019). Analysis of hyperspectral images for detection of drought stress and recovery in maize plants in a high-throughput phenotyping platform. ELSEVIER, 162.

Monterroso Rivas Alejandro Ismael, Conde Álvarez Ana Cecilia, Gómez Díaz Jesús David, & López García José. (2007). Vulnerabilidad y Riesgo en Agricultura por cambio climático en la Región Centro del Estado de Veracruz, México. Zonas Áridas, 11, 47–60.

Montaño, J. M. (2002). Redes neuronales artificiales aplicada al análisis de datos. Palca de Mayorca: Universidad de las Islas Baleares.

Mora, J., Ordaz, J. L., Ramírez, D., & Serna Hidalgo, B. (2010). Costa Rica: Efectos del cambio climático sobre la agricultura. CEPAL

Naciones unidas . (22 de Octubre de 2023). Un.org. Obtenido de What es the climate change: https://www.un.org/es/climatechange/what-is-climate-change

Nardone, A., Ronchi, B., Lacetera, N., Ranieri, M. S., & Bernabucci, U. (2010). Effects of climate changes on animal production and sustainability of livestock systems. Livestock Science, 130(1–3), 57–69. https://doi.org/10.1016/J.LIVSCI.2010.02.011

Narváez, A. B., Cruz, A., & Cruz, J. (2016). La complejidad y la ciudad: el uso de modelos basados en agentes autónomos (ABM) para la simulación de procesos en los imaginarios urbanos. SciELO, 8.

NASA. (2024, June 9). Los efectos del cambio climático . Https://Ciencia.Nasa.Gov/Cambio-Climatico/Los-Efectos-Del-Cambio-Climatico/.

Office of the United Nations Disaster Relief Coordinator. (1980). Natural disasters and vulnerability analysis : report of Expert Group Meeting, 9-12 July 1979. Geneva, Suiza: Naciones unidas.

Organizacion de las Naciones Unidas para la Alimentacion y la Agricultura. (2019). El trabajo de la FAO sobre el cambio climatico. FAO.

Proteccion civil del estado de Veracruz. (2022). Avenidas, Desbordamientos de Ríos e inundaciones. Xalapa: Gobierno del estado de Veracruz.

Ravinesh C. Deo, & Mehmet Şahin . (2015). Aplicación del modelo de Red Neuronal Artificial para la predicción del Índice Estandarizado de Precipitación y Evapotranspiración mensual utilizando parámetros hidrometeorológicos e índices climáticos en el este de Australia. Scince Direct, 65-81.

Rodríguez Z, L. G., & Roggero, P. (2015). Modelos basados en agentes: aportes epistemológicos y teóricos para la investigación social. SciELO, 60.

Ross, T. J. . (2005). Fuzzy Logic with Engineering Applications. 652.

Rural, S. d. (09 de Noviembre de 2021). Gobierno de Mexico, Agrigultura. Obtenido de https://www.gob.mx/agricultura/articulos/regiones-agroalimentarias-de-mexico?idiom=es

Salas Salinas, M. A., & Jiménez Espinosa, M. (2004). Inundaciones. Centro Nacional de Prevención de Desastres.

Santillán, V. S. (2016). Emisiones de gases de efecto invernadero en sistemas agrícolas de México. Terra Latinoam vol.34.

Secretaría de Agricultura y Desarrollo Rural. (2015, September 26). El cambio climático afecta al campo ¿cómo enfrentarlo?

Secretaría de Agricultura y Desarrollo Rural. (2021, March 13). Caña de azúcar un cultivo de importancia para México.

Secretaria de Agricultura y Desarrollo Rural. (2021, November 9). Agricultura, Regiones agroalimentarias de Mexico.

Sevillano Rodriguez, M., Bravo Peña, L., Alatorre Cejudo, L., & Salcedo Hurtado, E. (2020). Identificación de zonas de inundacion a partir de imagenes (SAR) y de eventos historicos de inundacion: Caso de estudio Santiago de Cali, Colombia. CC by NC.

Simone Neset Tina, Wiréhn Lotten, Opach Tomasz, Glaas Erik, & Ola Linnér Björn. (2019). Evaluation of indicators for agricultural vulnerability to climate change: The case of Swedish agriculture. EL SEVIER, 105, 571–580.

Sistema estatal de protección civil. (2013). Programa para la gestion y reduccion de riesgo ante la temporada de lluvias y ciclones. Xalapa : Secretaria de proteccion civil del estado de Veracruz.

Smith, C. (09 de Noviembre de 2017). National Geographic.Es. Obtenido de Medio ambiente,Intensificacion de la precipitaciones: https://www.nationalgeographic.es/medio-ambiente/2017/07/la-intensificacion-de-las-precipitaciones-provocara-un-aumento-de-la-contaminacion-del-agua-en-el-futuro

Snow Jackie. (2019). La inteligencia artificial podría ayudar a combatir el cambio climático. National Geographic.

Sterman, J. D. (2000). Business Dynamics: Systems Thinking and Modeling for a Complex World (Irwin/McGraw-Hill, Ed.).

Thomas, & Kopczak. (2005). From logistics to supply chain management: the path forward in the humanitarian sector. Fritz Institute, 1-15.

UNESCO. (2012). Glosario hidrológico internacional.

Useros Fernández, J. (2013). El cambio climatico: Sus causas y efectos medioambientales . Real Academia de Medicina y Cirugía de Valladolid, 71-98.

Valle, D. (2016). Sistema electrónico de alerta temprana de Incendios Forestales mediante Procesamiento Digital de imágenes para la empresa municipal del cuerpo de bomberos Ambato. FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E INDUSTRIAL.

Viera , O., Tansini, L., & Moscatelli , S. (2012). Logistica humanitaria y su aplicacion en Uruguay. GTI, 47-56.

Wallace, B. (19 de Octubre de 2012). El impacto del calentamiento global en la distribución de las precipitaciones: una perspectiva histórica. En W. Broecker, Hay futuro: visiones para un mundo mejor. Madrid: BBVA. Obtenido de https://www.bbvaopenmind.com/articulos/el-impacto-del-calentamiento-global-en-la-distribucion-de-las-precipitaciones-una-perspectiva-historica/

Yann Kerblat, & Melody Hill Kokoszka. (2024). Sequías y Déficits; Los impactos globales de las sequías en el crecimiento Económico. World Bank Group.

ZHAO, Y., SUN, Y., CAI Xiang, LIU, H., & Schulze, P. (2012). Identify Plant Drought Stress by 3D-Based Image. ELSEVIER, 11(7), 1207–1211