



Subsecretaría de Educación Superior  
Tecnológico Nacional de México  
Instituto Tecnológico de Orizaba

Instituto Tecnológico de Orizaba

División de Estudios de Posgrado e Investigación

## **Doctorado en Ciencias de la Ingeniería**

Tesis Doctoral

**“Evaluación de vulnerabilidad y riesgo agrícola ante el cambio climático a través de un sistema multi-agentes”**

Presenta

**M.I. Alina Evelyn Badillo Márquez**

Asesor

---

**Dr. Alberto Alfonso Aguilar Lasserre**

Co Asesor

**Dr. Marco Augusto Miranda Ackerman**

Diciembre 2021



**EDUCACIÓN**  
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO

Instituto Tecnológico de Orizaba  
División de Estudios de Posgrado e Investigación

**"2021: Año de la Independencia"**

Orizaba, Veracruz, 03/12/2021  
Dependencia: División de Estudios de  
Posgrado e Investigación  
Asunto: Autorización de Impresión  
OPCION: I

C. ALINA EVELYN BADILLO MÁRQUEZ  
Candidato a Grado de Doctor en:  
CIENCIAS DE LA INGENIERÍA  
P R E S E N T E -

De acuerdo con el Reglamento de Titulación vigente de los Centros de Enseñanza Técnica Superior, dependiente de la Dirección General de Institutos Tecnológicos 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:

**"EVALUACIÓN DE VULNERABILIDAD Y RIESGO AGRÍCOLA ANTE CAMBIO CLIMÁTICO A TRAVÉS DE UN SISTEMA MULTI-AGENTES"**

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

**ATENTAMENTE**  
Excelencia en Educación Tecnológica®  
CIENCIA - TÉCNICA - CULTURA®

**DR. MARIO LEONCIO ARRIOLA RODRÍGUEZ**  
JEFE DE LA DIVISIÓN DE ESTUDIOS  
DE POSGRADO E INVESTIGACIÓN



Avenida Oriente 9 No. 852  
Col. Emiliano Zapata, C.P. 94320  
Orizaba, Veracruz, México.  
Teléfono: 272-110-53-60  
Email: [depi\\_orizaba@tecnm.mx](mailto:depi_orizaba@tecnm.mx)  
[www.orizaba.tecnm.mx](http://www.orizaba.tecnm.mx)





"2021: Año de la Independencia"

Orizaba, Veracruz, Noviembre 01 de 2021  
Asunto: Revisión de trabajo escrito

C. MARIO LEONCIO ARRIOLA RODRÍGUEZ  
JEFE DE LA DIVISIÓN DE ESTUDIOS  
DE POSGRADO E INVESTIGACIÓN  
PRESENTE.

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (ja) C.  
**ALINA EVELYN BADILLO MÁRQUEZ**

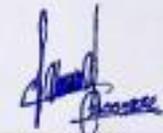
La cual lleva el título de:

**Evaluación de vulnerabilidad y riesgo agrícola ante cambio climático a través de un sistema multi-  
agentes**

Y concluyen que se acepta.

**ATENTAMENTE**  
Escuela en Educación Tecnológica  
CIENCIA - TÉCNICA - CULTURAS

PRESIDENTE:	DR. ALBERTO ALFONSO AGUILAR LASSERRE
SECRETARIO:	DR. RUBÉN POSADA GÓMEZ
VOCAL:	DR. ULISES JUÁREZ MARTÍNEZ
VOCAL:	DR. OSCAR OSVALDO SANDOVAL CONZÁLEZ
VOCAL:	DR. JUAN MANUEL MÉNDEZ CONTRERAS
VOCAL SUP.:	DR. MARCO AUGUSTO MIRANDA ACKERMAN

  
FIRMA

  
FIRMA

  
FIRMA

  
FIRMA

  
FIRMA

  
FIRMA

FTI-TI-013



## Índice

Índice de figuras.....	i
Índice de tablas.....	iii
Abstract.....	v
Resumen.....	vi
Introducción.....	vii
Capítulo 1. Generalidades.....	1
1.1.Planteamiento del problema.....	1
1.2. Objetivos.....	2
1.2.1.    Objetivo General.....	2
1.2.2.    Objetivos Específicos.....	2
1.3.Justificación.....	3
1.4.Hipótesis.....	3
Capítulo 2. Marco Teórico.....	4
2.1.La vulnerabilidad ante el cambio climático.....	4
2.1.1.    Vulnerabilidad Social.....	4
2.1.2.    Vulnerabilidad del capital natural y de los servicios ambientales.....	5
2.2.Estimación de vulnerabilidad.....	6
2.2.1.    Elementos para evaluar la vulnerabilidad.....	8
2.3.Historia y tendencias de la vulnerabilidad.....	9
2.3.1.    Indicadores de vulnerabilidad.....	10
2.3.2.    Clasificación de indicadores de vulnerabilidad.....	11
2.3.3.    Selección de indicadores de vulnerabilidad.....	12
2.3.4.    Dominio del objeto de estudio.....	13
2.3.5.    Estrategias de evaluación de la vulnerabilidad.....	13
2.4.Escenarios de impacto.....	14
2.5.Riesgo e incertidumbre ante cambio climático.....	16
2.5.1.    Riesgo y desastres.....	17
2.5.2.    Incertidumbre.....	19
2.6.México ante los riesgos del Cambio Climático.....	19
2.6.1.    Incremento de la temperatura de México en los últimos cincuenta años.....	21

2.7. Inteligencia artificial como herramienta para la toma de decisiones .....	21
2.7.1. Sistemas Expertos .....	22
2.7.1.1. Arquitectura de un Sistema Experto .....	23
2.7.1.2. Características de los Sistemas Expertos .....	24
2.7.2. Lógica Difusa .....	25
2.7.2.1. Conjuntos difusos .....	26
2.7.2.2. Funciones de pertenencia .....	27
2.7.2.3. Variables lingüísticas .....	27
2.7.2.4. Reglas de inferencia .....	27
2.7.2.5. Proceso de difusificación y desdifusificación .....	28
2.7.2.6. Método de centro de gravedad y de centro máximo .....	29
2.7.3. Dinámica de Sistemas .....	30
2.7.3.1. Enfoque sistémico .....	31
2.7.3.2. Análisis causal .....	32
2.7.3.3. Componentes básicos de un modelo de Dinámica de Sistemas .....	33
2.7.4. Sistemas basados en Agentes Inteligentes .....	34
2.7.4.1. Modelo agente actor .....	34
2.7.4.2. Características de los agentes inteligentes .....	35
2.7.4.3. Sistemas multi-agente .....	36
2.7.5. Procesamiento de imágenes .....	36
2.7.5.1. Binarización .....	37
2.7.5.2. Difuminado .....	38
2.7.5.3. Histograma de gradientes .....	39
Capítulo 3. Estado del arte .....	40
3.1. Panorama de la agricultura ante cambio climático .....	40
3.2. Estudio de la vulnerabilidad y riesgo en sistemas agrícolas .....	40
3.3. Estudio de vulnerabilidad y riesgo agrícola a través de técnicas de procesamiento de imágenes .....	45
Capítulo 4. Metodología .....	51
4.1. Diagnóstico .....	52
4.1.1. Determinación de factores que causan desastres .....	53
4.1.2. Caracterización de factores (bases de datos) .....	53

4.1.3.	Clasificación de indicadores de vulnerabilidad. Definición de variables .....	55
4.1.4.	Construcción de indicadores de vulnerabilidad y obtención de índice de vulnerabilidad	62
4.2.	Etapa 1. Desarrollo del modelo de vulnerabilidad a través de un sistema multi-agente .....	63
4.2.1.	Aplicación de dinámica de sistemas en Anylogic .....	64
4.2.1.1.	Conceptualización.....	65
4.2.1.2.	Formulación.....	69
4.2.1.3.	Implementación .....	72
4.3.	Etapa 2. Desarrollo del modelo de cultivo: Caña de Azúcar (Caso de estudio) .....	75
4.3.1.	Aplicación de lógica difusa en MatLab .....	80
4.3.1.1.	Modelo rendimiento de cultivo .....	83
4.3.1.2.	Modelo de parámetros inciertos para predecir el riesgo de cosecha.....	85
4.3.1.3.	Modelo para predecir la vulnerabilidad del cultivo de caña de azúcar .....	88
4.3.1.4.	Modelo de eficiencia del uso de suelo (agente reactivo) .....	91
4.4.	Etapa 3. Desarrollo del modelo de riesgo agrícola a través de procesamiento de imágenes ...	93
4.4.1.	Selección de variables a evaluar .....	93
4.4.2.	Recopilación de imágenes .....	94
4.4.3.	Procesamiento de imágenes .....	98
4.4.3.1.	Captura de imágenes en negativo.....	99
4.4.3.2.	Aplicación de filtro .....	105
4.4.3.3.	Aplicación de Thershold mask.....	107
4.4.3.4.	Resolución de mejora de imagen .....	109
4.4.3.5.	Proceso de detección.....	110
4.4.4.	Desarrollo de la red neuronal convolucional (CNN).....	111
4.4.4.1.	Etiquetado de variables .....	112
4.4.4.2.	Prueba de la CNN .....	116
Capítulo 5. Resultados .....		117
5.1.	Perfil de cambio climático .....	117
5.2.	Resultados obtenidos en los modelos dinámicos.....	118
5.2.1.	Análisis de sensibilidad .....	118
5.3.	Resultados obtenidos en los modelos difusos.....	127
5.4.	Determinación de vulnerabilidad agrícola del sistema multi-agente .....	140
5.5.	Resultados obtenidos del modelo de riesgo agrícola a través de procesamiento de imágenes .....	142

5.6. Esquemas de trabajo.....	149
5.7. Discusión de resultados.....	153
Conclusiones .....	157
Referencias.....	161

## Índice de figuras

Figura 1 Elementos para el manejo de riesgos (Elaboración propia).....	7
Figura 2 Índice de vulnerabilidad a Cambio Climático, basado en consideraciones de pobreza y desarrollo, considerando eventos extremos (Verisk Maplecroft, 2017).....	7
Figura 3 Nivel de agregación de la información para la construcción de índices a partir de indicadores y datos crudos (Magaña, 2012).....	12
Figura 4 Aproximación de “arriba hacia abajo” para la formulación de escenarios de impacto ante cambio climático (Magaña, 2012).....	15
Figura 5 Aproximación de “abajo hacia arriba” para la formulación de escenarios de impacto ante cambio climático (Magaña, 2012).....	16
Figura 6 Diagrama de la estructura del riesgo bajo cambio climático (Ippc, 2007).....	17
Figura 7 Costos ocasionados por desastres en México hasta el 2015.....	18
Figura 8 Grado de peligro por sequías (CENAPRED, 2018).....	20
Figura 9 Distribución espacial de las zonas susceptibles a inundaciones (INECC, 2018).....	20
Figura 10 Arquitectura de un sistema experto basado en conocimiento (Pino et al., 2010).....	24
Figura 11 Proceso de Lógica Difusa (Zadeh, 2013).....	29
Figura 12 Análisis a través de la dinámica de sistemas complejos (Cedillo-Campos, 2008).....	31
Figura 13 Fases del modelado de Dinámica de Sistemas.....	34
Figura 14 Conversión de una imagen a escala de grises.....	37
Figura 15 Valores de los pixeles de una imagen convertida a escala de grises.....	37
Figura 16 Representación de una imagen binarizada.....	38
Figura 17 Imagen suavizada mediante la distribución Gaussiana.....	38
Figura 18 Histograma de color en los canales RGB de una imagen.....	39
Figura 19 Metodología general.....	51
Figura 20 Metodología para determinar la vulnerabilidad total del sistema basado en un sistema multi-agente.....	63
Figura 21 Diagrama causal del modelo agente de indicadores de vulnerabilidad.....	68
Figura 22 Diagrama de flujo de la red <i>Rendimiento de tierras agrícolas</i> .....	73
Figura 23 Diagrama de flujo de la red <i>Valor de la agricultura</i> .....	74
Figura 24 Diagrama de flujo de la red <i>Eficiencia de los recursos hídricos en la agricultura</i> .....	74
Figura 25 Diagrama de flujo de la red <i>Contingencia ambiental</i> .....	75
Figura 26 Valor de la producción de la caña de azúcar en el estado de Veracruz.....	77
Figura 27 Metodología del modelo de agente de vulnerabilidad de cultivo.....	79
Figura 28 Representación gráfica del modelo difuso Rendimiento de cultivo.....	84
Figura 29 Matriz de inferencia del modelo Rendimiento de cultivo.....	85
Figura 30 Representación gráfica del modelo Parámetros inciertos.....	87
Figura 31 Matriz de inferencia del modelo Parámetros inciertos.....	88
Figura 32 Matriz de inferencia del modelo Vulnerabilidad de cultivo.....	89
Figura 33 Representación gráfica del modelo Vulnerabilidad de cultivo.....	90
Figura 34 Representación gráfica del modelo difuso Desordenes no nutrimentales.....	92
Figura 35 Matriz de inferencia del modelo Desordenes no nutrimentales (Agente reactivo).....	93

Figura 36 Clasificación de satélites de teledetección más comunes (Seminis, 2016; SIAP, 2016a; Vázquez et al., 2015).....	95
Figura 37 Imagen satelital en el umbral RGB del Sistema Nacional Meteorológico (SNM).....	95
Figura 38 Imagen satelital para la variable temperatura .....	96
Figura 39 Imagen satelital para la variable precipitación .....	96
Figura 40 Canal $L*a*b$ .....	97
Figura 41 Canal $L*a*b$ de la variable temperatura .....	98
Figura 42 Canal $L*a*b$ de la variable precipitación .....	98
Figura 43 Metodología empleada en el procesamiento de imágenes .....	99
Figura 44 Codificación de pixeles de la zona de interés de la variable temperatura .....	100
Figura 45 Codificación de pixeles de la zona de interés de la variable temperatura .....	100
Figura 46 Canal RGB para la variable temperatura .....	101
Figura 47 Canal RGB para la variable precipitación .....	102
Figura 48 Captura de imagen en negativo para la variable temperatura .....	103
Figura 49 Captura de imagen en negativo para la variable precipitación .....	104
Figura 50 Aplicación de filtros en la imagen de la variable temperatura .....	106
Figura 51 Aplicación de filtros en la imagen de la variable precipitación .....	106
Figura 52 Implementación de Thershold Mask en la imagen de la variable temperatura .....	108
Figura 53 Imagen procesada de la variable temperatura.....	109
Figura 54 Imagen procesada de la variable precipitación .....	110
Figura 55 Comparativa de las etapas del procesamiento de imágenes para la variable temperatura .....	111
Figura 56 Definición de etiqueta para las variables (ejemplo variable temperatura) .....	113
Figura 57 Asignación de etiquetas para la variable “Temperatura” .....	114
Figura 58 Asignación de etiquetas para la variable “Precipitación” .....	114
Figura 59 Exportación de la variable “Temperatura” .....	115
Figura 60 Sequías futuras. Fuente: (Greenpeace, 2017). .....	118
Figura 61 Análisis de sensibilidad para la variable crítica: Eficiencia de recursos hídricos en la agricultura. ....	120
Figura 62 Proyección de las variables: Volumen de agua disponible para actividades agrícolas y Eficiencia de recursos hídricos en la agricultura. ....	121
Figura 63 Análisis de sensibilidad para la variable crítica: Disponibilidad de tierras agrícolas.....	122
Figura 64 Proyección de las variables: Disponibilidad de tierra agrícola, Rendimiento de tierras agrícolas y Valor de la agricultura.....	123
Figura 65 Análisis de sensibilidad para la variable crítica: Emisiones de gases de efecto invernadero (GEI).....	124
Figura 66 Análisis de sensibilidad de la variable crítica: Situación de emergencia o riesgo.....	124
Figura 67 Proyección de las variables: Emisión de GEI y Situación de emergencia o riesgo.....	125
Figura 68 Rendimiento de la caña de azúcar: Datos históricos vs Resultados del modelo difuso...127	127
Figura 69 Variables de impacto:”Sistema de irrigación”-“Nitrógeno” del modelo: Rendimiento de cultivo .....	129
Figura 70 Variables de impacto: “Sistema de irrigación”-“Fósforo” del modelo: Rendimiento de cultivo .....	129

Figura 71 Variables de impacto: “Sistema de irrigación”-“Potasio” del modelo: Rendimiento de cultivo .....	129
Figura 72 Variables de impacto: “Vientos” - “Temperatura” del modelo: Parámetros inciertos ....	131
Figura 73 Variables de impacto: “Sequías”-“Precipitaciones” del modelo: Parámetros inciertos ..	131
Figura 74 Variables de impacto: “Precipitaciones”-“Eventos meteorológicos” del modelo: Parámetros inciertos .....	132
Figura 75 Número de eventos meteorológicos reportados en México en el periodo 2001-2016.....	133
Figura 76 Variables de impacto: “Rendimiento de cultivo”-“Riesgo de cosecha” del modelo: Vulnerabilidad del cultivo .....	135
Figura 77 Variables de impacto: “Superficie cosechada”-“Rendimiento de cultivo” del modelo: Vulnerabilidad del cultivo .....	135
Figura 78 Variables de impacto: “Valor de producción”-“Rendimiento de cultivo” del modelo: Vulnerabilidad de cultivo .....	136
Figura 79 Variables de impacto:”Materia orgánica”-“pH” del modelo: Eficiencia de suelo .....	138
Figura 80 Variables de impacto:”pH”-“Conductividad eléctrica” del modelo: Eficiencia del suelo .....	138
Figura 81 Variables de impacto: “Materia orgánica”-“Conductividad eléctrica” del modelo: Eficiencia del suelo .....	139
Figura 82 Comparación de los escenarios: Vulnerabilidad de cultivo vs Agente Reactivo .....	140
Figura 83 Metodología para la detección por Deep Learning .....	142
Figura 84 Primer entrenamiento de la CNN (variable Temperatura) .....	143
Figura 85 Segundo entrenamiento de la CNN (variable Temperatura) .....	143
Figura 86 Primer entrenamiento de la CNN (variable Precipitación). .....	144
Figura 87 Segundo entrenamiento de la CNN (variable Precipitación). .....	144
Figura 88 Tercer entrenamiento de la CNN (variable Precipitación). .....	145
Figura 89 Cuarto entrenamiento de la CNN (variable Precipitación). .....	145
Figura 90 Quinto entrenamiento de la CNN (variable Precipitación). .....	146
Figura 91 Nivel de confianza de la CNN de la variable Temperatura. ....	147
Figura 92 Nivel de confianza de la CNN de la variable Precipitación. ....	147
Figura 93 Probabilidad de detección de la variable Temperatura. ....	148
Figura 94 Probabilidad de detección de la variable Precipitación. ....	148
Figura 95 Esquema simplificado de los componentes del sistema de producción (PRONAC, 2009) .....	149
Figura 96 Primer esquema de adaptación para el cultivo de caña de azúcar .....	151
Figura 97 Segundo esquema de adaptación para el cultivo de caña de azúcar .....	152
Figura 98 Tercer esquema de adaptación para el cultivo de caña de azúcar .....	153

## Índice de tablas

Tabla 1 Características y algunos elementos a considerar en la construcción de los indicadores (Magaña, 2012). .....	14
Tabla 2 Costos originados por desastres naturales en México (El Economista, 2015). .....	18

Tabla 3 Características de los Agentes Inteligentes (Yancato Gurmán, 2012) .....	35
Tabla 4 Principales aportaciones del estudio de vulnerabilidad ante el cambio climático. ....	48
Tabla 5 Principales aportaciones del estudio de vulnerabilidad ante el cambio climático (Uso de tratamiento de imágenes). ....	50
Tabla 6 Organismos consultados para la recolección de información .....	54
Tabla 7 Indicadores de Exposición.....	56
Tabla 8 Indicadores de Sensibilidad .....	59
Tabla 9 Indicadores de Capacidad Adaptativa.....	61
Tabla 10 Clasificación de agentes .....	64
Tabla 11 Variables del agente de indicadores de vulnerabilidad .....	66
Tabla 12 Análisis de tendencias del modelo agente de indicadores de vulnerabilidad .....	69
Tabla 13 Clasificación por regiones .....	75
Tabla 14 Principales cultivos de la región 1 .....	76
Tabla 15. Producción de caña de azúcar en el estado de Veracruz .....	76
Tabla 16 Resultados del índice de Simpson .....	78
Tabla 17 Variables del modelo Caña de azúcar .....	82
Tabla 18 Modelo <i>Rendimiento de cultivo</i> : conjuntos difusos e intervalos de operación .....	83
Tabla 19 Modelo Parámetros inciertos: conjuntos difusos e intervalos de operación .....	86
Tabla 20 Modelo Vulnerabilidad de cultivo: conjuntos difusos e intervalos de operación .....	89
Tabla 21 Modelo Desordenes no nutrimentales: conjuntos difusos e intervalos de operación .....	91
Tabla 22 Codificación de la escala de color en el canal RGB .....	99
Tabla 23 Variables de interés para cada escenario .....	119
Tabla 24 Variables de interés para cada ciclo de simulación .....	126
Tabla 25 Parámetros de entrada del modelo difuso: Rendimiento de cultivo .....	127
Tabla 26 Parámetros de entrada del modelo difuso: Parámetros inciertos .....	130
Tabla 27 Parámetros de entrada del modelo difuso: Vulnerabilidad de cultivo .....	133
Tabla 28 Producción de toneladas de azúcar por hectárea en México .....	134
Tabla 29 Parámetros de entrada del modelo difuso: Eficiencia del suelo (Agente Reactivo) .....	137
Tabla 30 Resultados los escenarios de la vulnerabilidad de cultivo .....	139
Tabla 31 Escala de vulnerabilidad de las redes .....	141
Tabla 32 Resultados de vulnerabilidad .....	141

## **Abstract**

At the present time, there have been significant changes in weather patterns caused mainly by drastic increases in temperature, increased carbon dioxide and variation in precipitation levels, causing negative impacts on agricultural production.

Agricultural sector, on a global scale, is vulnerable by factors such as the loss of biodiversity, increased deforestation, pollution and soil degradation, the impact generated by the use of fossil fuels. The agro-environmental vulnerability to climate change is a result of variation of biophysical and socioeconomic factors and variables in agricultural activities.

This research presents a model based on agents to evaluate the agricultural sector of sugar cane in Veracruz to determine the degree of vulnerability existing through dynamic assessment of agricultural risk.

The agent model (ABM) allows us to propose different scenarios with active entities to analyze and study the behavior of the system. With the development of the ABM, a greater impact was determined from the environmental contingency due to increases in greenhouse gas (GHG) emissions and the exponential growth in the incidence of extreme meteorological phenomena that put the agricultural harvest at risk, making the agricultural sector more vulnerable and decreasing crop yields.

## Resumen

En la actualidad, se han presentado cambios significativos en los estándares climáticos como resultado de aumentos drásticos de temperatura, bióxido de carbono, variación en niveles de precipitación; originando impactos negativos en la producción agrícola.

El sector agrícola, a escala global, es vulnerable por factores tales como la disminución de biodiversidad, aumento en la deforestación, contaminación y degradación de suelos; así como el impacto generado por la explotación de combustibles fósiles. La vulnerabilidad en los sistemas agrícolas frente a cambio climático es una combinación de factores biofísicos y socioeconómicos que intervienen en actividades agrícolas.

Esta investigación 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.

El modelo de agentes (ABM) permite plantear distintos escenarios con entidades activas para analizar y estudiar el comportamiento del sistema. Con el desarrollo del ABM, se determinó un mayor impacto proveniente de la contingencia ambiental por incrementos en las emisiones de gases de efecto invernadero (GEI) y el crecimiento exponencial en la incidencia de fenómenos meteorológicos extremos que ponen en riesgo la cosecha agrícola haciendo más vulnerable al sector agrícola disminuyendo el rendimiento de la cosecha.

## Introducción

Actualmente, las actividades agropecuarias en México tienen un alto impacto tanto para los medios rurales e industriales mediante el suministro de alimentos gracias al aprovechamiento y explotación de recursos naturales; de igual modo la agricultura se ha posicionado como la principal fuente de ingreso al ofrecer vías de empleo para la población del medio rural (SAGARPA, 2012).

La sensibilidad de la agricultura frente a las condiciones climáticas radica en alteraciones en el comportamiento de factores como temperatura, precipitaciones, velocidad de vientos y disponibilidad de recursos. Por lo que, la eficiencia de los sistemas agrícolas está relacionada intrínsecamente con las variaciones climáticas (Torres Lima et al., 2011), de este modo es fundamental el desarrollo de investigaciones que involucren metodologías y estrategias para minimizar niveles de vulnerabilidad que pongan en riesgo las cosechas.

Las emisiones GEI derivadas del sector agropecuario equivalen al 17-32% de las emisiones a escala mundial. Estudios desarrollados por la Organización de las Naciones Unidas para la Alimentación y la Agricultura (IFAD, 2010), señalan que los niveles de emisiones de GEI en el sector agrícola han aumentado en un 32% en las últimas tres décadas.

La vulnerabilidad de los agricultores en México se relaciona con la disponibilidad y suministro de recursos físicos y materiales, los cuales permiten una evaluación sistémica de vulnerabilidad que incluya factores sociales, ambientales, económicos e institucionales que intervienen en los procesos agrícolas. A su vez, se deben considerar los diversos niveles de comprensión teórica y metodológica necesarios para abordar y comprender las relaciones humano-ambientales. Siguiendo dicho enfoque, la vulnerabilidad agroambiental, se entiende como una función en la variación de variables socioeconómicas y biofísicas (Magaña et al., 2012; SAGARPA, 2013).

En la presente investigación, se aborda la evaluación de vulnerabilidad frente el cambio climático aplicado al sector agrícola mediante un modelo de vulnerabilidad basado en agentes y riesgo agrícola a través de escenarios de impactos cuantitativos generados por cambios climáticos.

La metodología propuesta permite estimar la vulnerabilidad agrícola de la caña de azúcar cultivada en el sureste de Veracruz mediante el análisis de componentes que causan desastres, disponibilidad de recursos (agua, tierras, apoyos en el campo, etc.), emisiones GEI, buen manejo de prácticas agrícolas, nutrición del suelo agrícola, evaluación del rendimiento de cultivo y determinación de riesgo.

Posteriormente, se determinó el riesgo de cosecha a través de la predicción de las variables de impacto (Precipitación y Temperatura).

La metodología de investigación comprende las fases de diagnóstico, modelo de vulnerabilidad multi-agente, modelo de cultivo aplicado a un caso de estudio y modelo de riesgo agrícola a través del procesamiento de imágenes.

# Capítulo 1. Generalidades

## 1.1. Planteamiento del problema

Para México, las actividades del sector agropecuario representan una de las principales fuentes de ingresos y alimentos, tanto para el medio rural e industrial.

Dado que la producción agrícola tiene un alto grado de sensibilidad frente al cambio climático por la presencia de impactos ambientales previstos como variaciones en los niveles promedios de temperatura derivando estrés climático repercutiendo en el desarrollo de cultivos. Además existen otros factores como el aumento de plagas y enfermedades, fuegos devastadores, disminución de recursos hídricos y problemas en la calidad del agua (SAGARPA, 2012).

Dentro de los fenómenos extremos, se encuentran las sequías, lluvias extremas, granizadas y ciclones; originando disminución de cosecha, degradación de suelos, infertilidad en las tierras de cultivo por efectos adversos originados por disminución de agua y/o estrés hídrico y aumento en la mortalidad de ganado, entre otros (Fowler et al., 2003).

Bajo este enfoque, la vulnerabilidad y la capacidad de respuesta para afrontar ésta problemática se consideran fenómenos complejos, multidimensionales de observación directa; razón por la cual es difícil su evaluación. Debido a ésta complejidad, se han desarrollado estudios para minimizar ésta problemática desde diferentes enfoques, tales como (Gay et al., 2004):

- Evaluación de vulnerabilidad frente a un determinado estresor físico (sequía, tormentas tropicales, ciclón, etc.).
- Evaluación de efectos adversos originados por cambios en el comportamiento climático.
- Analizar el estrés generado por impactos y la capacidad de respuesta del sistema frente cambio climático.

En la presente investigación, se aborda el estudio de vulnerabilidad del sector agrícola frente a cambio climático. Para obtener una mejor comprensión del sistema se evaluó bajo un enfoque de agentes, englobando desde aspectos generales a particulares.

En primer plano, se identifican las variables con mayor impacto en el sistema, tanto variables físicas, ambientales y socioeconómicas para establecer un panorama global aún en

presencia de incertidumbre y proponer esquemas que ayuden a minimizar vulnerabilidad y riesgo agrícola.

Con la información obtenida, se desarrolla un modelo basado en agentes capaz de evaluar la vulnerabilidad agrícola del cultivo de caña de azúcar el cuál sirva como apoyo a la decisión para el desarrollo de investigaciones futuras ante dicha problemática.

## **1.2. Objetivos**

### **1.2.1. Objetivo General**

Desarrollar un modelo de vulnerabilidad y riesgo agrícola a través de escenarios de impactos cuantitativos generados por cambio climático para proponer esquemas de trabajo que conlleven a acciones de adaptación.

### **1.2.2. Objetivos Específicos**

- Definir el objeto de estudio y determinar los fenómenos climáticos del análisis de vulnerabilidad y riesgo agrícola para determinar las causas de desastre y su relación funcional con los impactos al sistema.
- Desarrollar indicadores de vulnerabilidad en base a la recolección de información para alimentar un modelo de vulnerabilidad a través de un sistema multi-agente basado en técnicas de inteligencia artificial para establecer una escala de referencia de vulnerabilidad.
- Validar el modelo de vulnerabilidad en base a la dinámica histórica del riesgo para proyectar tendencialmente los índices de vulnerabilidad aplicados a un caso de estudio.
- Desarrollar un agente reactivo capaz de obtener escenarios alternativos de vulnerabilidad a través análisis multicriterio que ayude al proceso de toma de decisiones.
- Desarrollar un modelo de riesgo ante el cambio climático a través de procesamiento de imágenes capaz de detectar áreas de interés que pudieran incrementar potencialmente el riesgo de cosecha.

### **1.3. Justificación**

Los efectos originados por estrés climático representan una amenaza potencial para los ecosistemas, principalmente en los sistemas agrícolas. Los cambios en el comportamiento climáticos actualmente han causado disminución en la producción agrícola poniendo en riesgo la seguridad alimentaria, no solo en México, sino a nivel mundial. En los últimos años, ha surgido un incremento en el interés por el desarrollo de medidas de adaptación para minimizar el impacto causado por cambio climático. Actualmente, el desarrollo de políticas agrícolas permite establecer medidas de adaptación que sirvan de soporte para enfrentar retos futuros.

En México, los productores agrícolas depende intrínsecamente del acceso y disponibilidad de recursos físicos y materiales que otorguen a los agricultores la capacidad de flexibilidad de adaptación ante un inestable contexto ambiental, económico e institucional (SAGARPA, 2012); por lo que, para lograr una evaluación integral en los sistemas agrícolas a menudo es necesario un análisis que incluya distintas escalas espacio-temporales bajo distintos enfoques metodológicos (Barr et al., 2010).

Siguiendo este enfoque, la vulnerabilidad agroambiental al cambio climático, es entendida como una función de la variación de factores y variables biofísicas y socioeconómicas en las actividades agrícolas. Por tal motivo, se requiere analizar la compleja interrelación entre parámetros políticos, ambientales y socioeconómicos que intervienen en el objeto de estudio para determinar el origen de impactos generados por cambio climático en los sistemas agrícolas (Wheeler, 2012).

En la actualidad, diversos países han desarrollado estudios sobre la vulnerabilidad de sistemas alimentarios ante el cambio climático (Universidad de Chile, 2006); sin embargo, en México son pocos los estudios desarrollados para la evaluación de vulnerabilidad y riesgo agrícola a través de escenarios de impactos cuantitativos (emisiones, absorciones o captura de gases y compuestos de efecto invernadero) generados por cambio climático que permitan proponer esquemas de trabajo que lleven a acciones de adaptación.

### **1.4. Hipótesis**

El desarrollo del modelo para evaluar la vulnerabilidad y riesgo agrícola a través de escenarios de impactos cuantitativos (emisiones, absorciones o captura de gases y compuestos de efecto invernadero) generados por cambio climático permitirá obtener esquemas de trabajo que lleven a acciones de adaptación.

## Capítulo 2. Marco Teórico

### 2.1. La vulnerabilidad ante el cambio climático

La vulnerabilidad puede definirse como *“el grado en que los sistemas pueden verse afectados adversamente por el cambio climático, dependiendo si éstos son capaces o incapaces de afrontar los impactos negativos del cambio climático, incluyendo en esta definición a la variabilidad climática y los eventos extremos”*(IFAD, 2010).

Con base a esta definición, el Grupo Intergubernamental de Expertos sobre el cambio Climático (IPCC, 2007) indica que *“la vulnerabilidad no sólo depende de las condiciones climáticas adversas, sino también de la capacidad de la sociedad de anticiparse, enfrentar, resistir y recuperarse de un determinado impacto”*.

Bajo estos enfoques, la vulnerabilidad está delimitada por la exposición a eventos climatológicos y su capacidad de respuesta es definida por organismos institucionales y sociales.

#### 2.1.1. Vulnerabilidad Social

En México el principal indicador de vulnerabilidad social es la pobreza; información emitida por el Consejo Nacional de Evaluación de la Política de Desarrollo Social señala que en promedio cerca del cincuenta por ciento de la población vive en condiciones de pobreza o marginación (CONEVAL, 2018).

Tan solo cerca del 68% de la población ha sido afectada por desastres naturales, siendo los grupos más vulnerables aquellos clasificados bajo extrema pobreza. Las condiciones de éstos grupos se caracterizan por habitar en viviendas precarias en zonas de riesgo (zonas montañosas, barrancas y áreas susceptibles a inundaciones) incrementando el peligro latente ante catástrofes climáticas (Ministerio de Ambiente, 2012; SAGARPA, 2012).

Sumado a esto, incrementos abruptos de temperatura y un decremento en los niveles de precipitaciones, podría traer consigo severas repercusiones al sector agrícola. En zonas conurbadas, la posibilidad de que las condiciones climáticas afecten los patrones climáticos en las próximas décadas es mayor por la sobreexplotación de combustibles fósiles y recursos naturales.

Por tal motivo, los tomadores de decisiones han optado con mayor frecuencia incluir criterios para minimizar riesgos climáticos durante la construcción de viviendas,

infraestructura de hospitales, en los sectores: energético, comunicación, transportes y turístico; esto para obtener mayor infraestructura para salvaguardar a la población frente a condiciones climáticas extremas.

La Estrategia Nacional de Cambio Climático (ENCC) señala que *“los impactos económicos provocados por los fenómenos hidrometeorológicos extremos han pasado de un promedio anual de 730 millones de pesos en el periodo de 1980 a 1999 a 21,950 millones para el periodo 2000-2012”* (Gobierno de la República Mexicana, 2014).

### **2.1.2. Vulnerabilidad del capital natural y de los servicios ambientales**

México cuenta con el 1.7% del territorio terrestre en el planeta, además posee el 10% de la biodiversidad conocida; por tanto, los ecosistemas tienen la facultad de proporcionar medios naturales y ambientales para enfrentar condiciones climáticas adversas gracias a la captación de carbono, racionamiento y suministro de recursos hídricos, preservación de especies y la regeneración de suelos (Reséndez et al., 2011).

Sin embargo, la probabilidad de incidencias de riesgos climáticos ha ido en aumento; por ello, los esfuerzos por reducir la vulnerabilidad social han tomado mayor importancia siendo la clave principal el desarrollo de medidas de adaptación para incrementar la resiliencia.

La pérdida en la biodiversidad de los ecosistemas ha tenido afectaciones principalmente por la deforestación producida por la sobre explotación de actividades agropecuarias. Se estima que desde el 2002 a la fecha, en México se han perdido cerca de 127 especies vegetales, siendo 74 de ellas endémicas. Entre los años 1976 y 2009 hubo una pérdida de casi el 50% de vegetación primaria en las cuencas del Golfo de México; por otro lado, estudios indican que cerca del 45% de los suelos del territorio mexicano presentan algún tipo de degradación por causas ambientales o fisicoquímicas (Conde-Álvarez, 2003; CONDE, 2011).

Proyecciones emitidas para México estiman que para los próximos 30 años habrá una reducción en la vegetación, principalmente en bosques y desiertos. Sumado a esto, se espera la presencia y permanencia de especies exóticas que desplacen a las especies nativas haciéndolas más vulnerables a los cambios climáticos.

Estudios desarrollados por el PECC (Consejo de Cooperación Económica del Pacífico) señalan que aumentos en las emisiones de bióxido de carbono propician una descalcificación de los corales y reducción en su crecimiento de hasta un 40%. Ante esta

problemática, se ha buscado lograr una recuperación en los servicios ambientales mediante la modificación y diversificación de políticas en la producción.

El PECC a través de un diagnóstico realizado durante los años 2013-2018, establece dos principales objetivos orientados en “*i) Reducir la vulnerabilidad de la población y sectores productivos e incrementar su resiliencia y la resistencia de la infraestructura estratégica*” y, “*ii) Conservar, restaurar y manejar sustentablemente los ecosistemas garantizando sus servicios ambientales para la adaptación y mitigación al cambio climático*” (Gobierno de la República Mexicana, 2014).

Bajo este contexto, se busca fortalecer y priorizar el diseño e implementación de acciones para reducir la vulnerabilidad bajo la premisa de que los costes de implementación de medidas de adaptación son hasta tres veces menores en comparación a los costes generados por la atención de desastres.

## **2.2. Estimación de vulnerabilidad**

La estimación de vulnerabilidad a menudo se realiza con la expertís del evaluador. La estimación debe ser subjetiva debido a que no existen parámetros para la cuantificación de la vulnerabilidad. México cuenta con organismos encargados para la protección civil como el CENAPRED (Centro Nacional para la Prevención de Desastres) y SEDESOL (Secretaría del Desarrollo Social), los cuales han trabajado en la búsqueda de expresar la vulnerabilidad a través de proyecciones cuantitativas que engloben periodos de 20 a 30 años en términos físicos, sociales y económicos considerando el dinamismo para estimar riesgos climáticos (CENAPRED, 2018).

A través de la cuantificación de vulnerabilidad es posible priorizar e implementar las medidas de adaptación que mejor se adapten al sistema en estudio y dar seguimiento para comprobar que exista una reducción en los niveles de riesgo aun bajo circunstancias donde el peligro es latente y está en aumento. Actualmente existen pocos estudios desarrollados para evaluar la vulnerabilidad que propongan esquemas de adaptación para mantener el riesgo bajo niveles tolerables.

El riesgo a menudo está delimitado por el peligro y la vulnerabilidad; sin embargo, éste debe incluir la interacción entre los actores clave y la sociedad. La Figura 1 muestra la relación entre la comunicación del riesgo y la aceptación por parte de esquemas de adaptación.

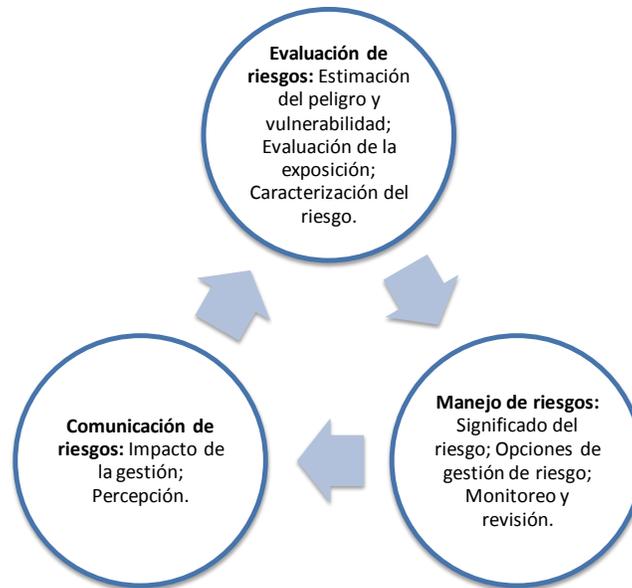


Figura 1 Elementos para el manejo de riesgos (Elaboración propia).

En la **¡Error! No se encuentra el origen de la referencia.**, se muestran aproximaciones desarrolladas en la actualidad para estimar la vulnerabilidad de las poblaciones humanas frente a fenómenos climáticos extremos incluyendo datos proporcionados por el “*Índice de Vulnerabilidad al Cambio Climático (CCVI)*”.

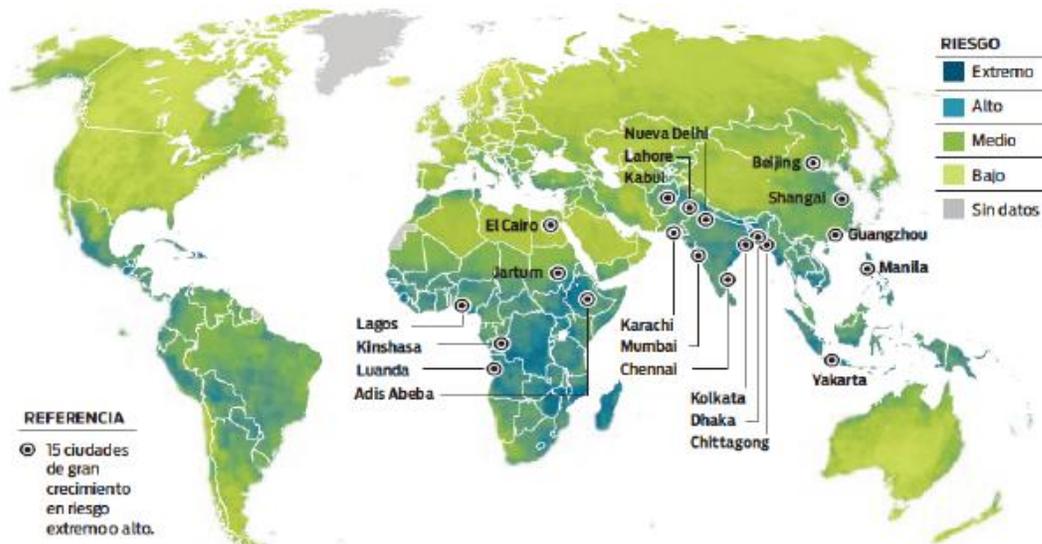


Figura 2 Índice de vulnerabilidad a Cambio Climático, basado en consideraciones de pobreza y desarrollo, considerando eventos extremos (Verisk Maplecroft, 2017).

Existen organizaciones cuyo objetivo es proporcionar ayuda a poblaciones vulnerables que han sido afectadas por desastres meteorológicos a través de un monitoreo de vulnerabilidad climática como herramienta para medir los impactos climáticos. El objetivo de dichas organizaciones es vigilar la relación entre los impactos actuales y los esperados a futuro mediante la comprensión y entendimiento del sistema.

El Instituto Mexicano para la Competitividad (IMCO) ha establecido un “*índice de vulnerabilidad climática (IVC)*” como parámetro para cuantificar el nivel de riesgo con base a los fenómenos climatológicos (IMCO, 2017). Dentro de las principales consideraciones del IVC se encuentra el capital social, infraestructura y proyecciones tendenciales de las afectaciones generadas en los últimos años.

El IVC propone la definición de vulnerabilidad como: “*Análisis de los potenciales impactos de cambio climático para poder diseñar y orientar adecuadamente las políticas públicas en materia de adaptación*”. Los modelos empleados para la cuantificación de vulnerabilidad permiten el desarrollo de escenarios bajo condiciones con y sin adaptación y/o mitigación, permitiendo tomar decisiones para establecer acciones de prevención más fiables.

### **2.2.1. Elementos para evaluar la vulnerabilidad**

La vulnerabilidad se caracteriza por contener elementos de sensibilidad, exposición y capacidad adaptativa ante eventos extremos y cambios en los patrones climáticos (IPCC, 2007). De acuerdo a (Alder, et al., 2013), “*la vulnerabilidad describe un conjunto de condiciones de las personas o sistemas que derivan de los contextos históricos y culturales predominantes, sociales, ambientales, políticos y económicos*”; por lo cual se establece que:

*“La vulnerabilidad es el conjunto de condiciones físicas, sociales y económicas que inciden en la posibilidad de afectación de las personas, de un sistema social y/o natural, debido a la ocurrencia de fenómenos naturales, y que están en relación con su exposición, sensibilidad y capacidad adaptativa (Riveraa, 2012)”.*

Las proyecciones futuras desarrolladas sobre las estimaciones de peligro y vulnerabilidad conllevan cierto grado de incertidumbre. En términos de vulnerabilidad resulta difícil estimar la incertidumbre pues se espera que los niveles de esta se encuentren por debajo de las proyecciones; sin embargo, esto rara vez sucede. Por ello, la estimación de incertidumbre en los escenarios generados difícilmente es abordada ya que depende de decisiones humano-ambientales difíciles de establecer.

Al cabo del análisis de las posibles vertientes involucradas en el estudio de vulnerabilidad, se registra que:

*“No se ha reportado una metodología universalmente aceptada para cuantificar la vulnerabilidad futura que, en conjunto con proyecciones del clima, permita estimar el riesgo que se enfrentará bajo cambio climático (Reyes Anistro et al., 2018)”*.

El concepto de vulnerabilidad y todo aquello que engloba, ha cobrado fuerza recientemente gracias a que permite el análisis de impactos potenciales bajo cambio climático para poder establecer la implementación de estrategias en términos de adaptación (Díaz Caravantes, 2018).

Al realizar un diagnóstico de vulnerabilidad, primero debe ser determinada la causa de vulnerabilidad a través del análisis de factores que sensibilizan los sistemas reconociendo la capacidad de acoplamiento ante medidas de mitigación. Partiendo de esta premisa, debe haber una transición de una evaluación cualitativa a una cuantitativa permitiendo evaluar si se ha alcanzado el desarrollo de manera sostenible (UNDRR, 2004). Una evaluación cualitativa suele ser inconsistente debido a que su desarrollo implica diferentes enfoques o “puntos de vista” contrastando los resultados observados al ser un enfoque inductivo sustentándose en observaciones no estructuradas, revisión de documentos, entrevistas, discusiones, etc. El enfoque cuantitativo es de tipo deductivo, es decir, tiene como objetivo acotar información mediante el diseño de experimentos y/o instrumentos de medición estándar.

Una visión cuantitativa permite verificar la información obtenida por distintos investigadores, estandarizar criterios de medición y calificar de manera objetiva las condiciones observadas por fenómenos naturales que potencialicen la vulnerabilidad. Un enfoque cuantitativo permite un estudio dinámico de vulnerabilidad para la construcción de escenarios futuros.

### **2.3. Historia y tendencias de la vulnerabilidad**

La construcción de escenarios conlleva proyecciones futuras de las condiciones que generan e incrementan los niveles de vulnerabilidad, por lo cual primero debe existir una comprensión en la dinámica histórica del riesgo. Una extrapolación de una variable origina cierto grado de incertidumbre la cual puede aumentar con forme el plazo en la proyección de la tendencia vaya incrementando.

De esta manera, se recomienda que los indicadores de vulnerabilidad se constituyan con datos históricos de los últimos 10 años para extrapolar información en un plazo equivalente

o incluso mayores (15 años) que considere un incremento aceptable de incertidumbre analizando con facilidad y fiabilidad el comportamiento en la tendencia.

Los indicadores tienen la capacidad de ser flexibles, es decir éstos pueden cambiar la vulnerabilidad a corto plazo. A través del estudio en la tendencia de los indicadores es posible predecir cambios de vulnerabilidad bajo la implementación parcial o total de estrategias de adaptación.

A menudo la construcción de indicadores de vulnerabilidad se realiza bajo la implementación de “promedios ponderados” donde el experto tiene la responsabilidad de proponer cual de los factores tiene mayor “peso o importancia” a futuro. Un claro ejemplo, son los censos de población en donde se hace una ponderación con base a condición socioeconómica por zona, nivel de marginación, crecimiento urbano, disponibilidad al acceso de agua, condiciones de la población, etc.; permitiendo la construcción de indicadores a través del comportamiento de los datos históricos y proyecciones futuras.

El horizonte en la proyección de los indicadores flexibles es menor en comparación con aquellos denominados “rígidos” debido a que la tendencia en la proyección a largo plazo tiene niveles mayores de incertidumbre con respecto a los indicadores a corto plazo; por lo cual se recomienda que las tendencias sean proyectadas en periodos de máximo 2 décadas; reforzando lo establecido por el IPCC a cerca de que los impactos por cambio climático deben ser estudiados a corto plazo; de lo contrario, si el estudio se hará a largo plazo se debe considerar un incremento en la incertidumbre (IPCC, Canziani, Palutikof, Van Der Linden, & Hanson, 2007).

### **2.3.1. Indicadores de vulnerabilidad**

El análisis de “datos crudos” para generar de información requiere expertís en el ámbito social y/o ambiental. A través de la capitalización del conocimiento los expertos son capaces de construir modelos conceptuales basándose en el razonamiento para tratar de explicar cómo funciona el sistema en estudio. Para demostrar la validez del modelo, los investigadores han optado por tratar de explicar situaciones que ocurren en el contexto actual a través de un análisis multicriterio.

Un análisis multicriterio sirve de apoyo a la decisión para analizar sistemas y/o situaciones complejas inmersas en aspectos cuantitativos y/o cualitativos. En este sentido, los sistemas socio-ambientales tienen como factor preponderante la variabilidad climática, lo cual no sólo conlleva una simple construcción de un modelo conceptual, sino que se requiere una evolución hacia un modelo cualitativo que permita explicar al sistema (G.A. et al., 1999).

A menudo los investigadores optan por hacer una transición entre el modelo conceptual al modelo cualitativo ya que éstos permiten identificar la relevancia de cada factor hacia el sistema; la cuantificación tiene la ventaja de convertir los fenómenos de observación directa en valores concretos mediante el establecimiento y medición de reglas, parámetros y relaciones funcionales entre cada factor (Ligon and Schechter, 2003).

La selección de los parámetros que mejor se adapten al objeto de estudio depende principalmente de analizar el objetivo de todos los factores (condiciones físicas, sociales, económicas y ambientales) inmersos en el sistema para identificar el nivel de sensibilidad, exposición y capacidad de respuesta (Connor and Hiroki, 2005; Shukla, 2016).

Entre los factores de vulnerabilidad, se encuentran los objetivos y subjetivos que le conceden un papel fundamentalmente explicativo a los cuestionamientos previos “qué o quién”, al “qué”, y al “por qué” (Fowler et al., 2003).

De acuerdo con (Sullivan and Meigh, 2005), *“los indicadores sirven para ordenar y sistematizar información para la planificación, evaluación y toma de decisiones ya que permiten constituir sistemas de información que dan cuenta de las características cuantitativas de un ámbito institucional, económico, geográfico, cultural, educativo”*.

Los indicadores representan datos cuantitativos resultado de observaciones adquiridas de manera directa e indirecta por el investigador. La principal labor del investigador es lograr que todos puedan percibir al sistema de igual manera. Generalmente los indicadores son contruidos a partir de censos a nivel regional, nacional o supranacional.

### **2.3.2. Clasificación de indicadores de vulnerabilidad**

Los indicadores de vulnerabilidad se dividen en tres grupos:

1. Indicadores por exposición.
2. Indicadores de sensibilidad.
3. Indicadores de capacidad adaptativa.

Los indicadores de vulnerabilidad por exposición miden el nivel de estrés climático en términos de frecuencia y magnitud sobre una unidad determinada de análisis. La exposición puede ser representada a través de cambios en los patrones climatológicos originados por variabilidad climática. Dentro de los indicadores por exposición se encuentran los “índices sintéticos” los cuales tienen la capacidad de incorporar diferentes indicadores para realizar comparaciones entre dos o más sistemas. En de este grupo se engloba información referente a frecuencia de eventos extremos, problemática ambiental y cambios modelados del clima.

La sensibilidad climática puede definirse como *“el grado en el que un sistema es potencialmente modificado o afectado por un disturbio, interno, externo o un grupo de ellos. La medida que determina el grado en el que un sistema se puede ver afectado por un estrés son las condiciones humanas y ambientales que pueden empeorar o disminuir los impactos por un determinado fenómeno”* (Monterroso et al., 2013) . En este sentido, al hablar de evaluación de sensibilidad se debe incluir información de la población y la agricultura.

Por su parte, la capacidad adaptativa, se define como *“la capacidad de un sistema de enfrentar los efectos del cambio climático, al potencial de implementar medidas que ayuden a disminuir los posibles impactos identificados. La capacidad adaptativa de una sociedad refleja su capacidad de modificar sus características o comportamientos para enfrentar de una mejor manera o anticiparse a los factores que impulsan el cambio”* (Conde-Álvarez, 2003; Monterroso et al., 2007). Los indicadores de capacidad adaptativa engloban información acerca de capital social, humano, financiero y ambiental.

### 2.3.3. Selección de indicadores de vulnerabilidad

Para lograr una selección adecuada de indicadores, en primer plano debe existir una comprensión sobre las causas o motivos que generan que una región o grupo sea vulnerable a determinado peligro. Al hablar de cambio climático, los indicadores deben ser flexibles y sensibles ante posibles cambios en el sistema para generar medidas de adaptación.

La construcción de indicadores con frecuencia es en base a la creatividad del analista para comprender las relaciones entre el sistema de estudio y el clima. Generalmente estas relaciones se bosquejan en un modelo conceptual para construir los indicadores de vulnerabilidad a través de la normalización y ponderación de información (*“datos crudos”*) (Magaña, 2012). La Figura 3 muestra la jerarquía de agregación de información.

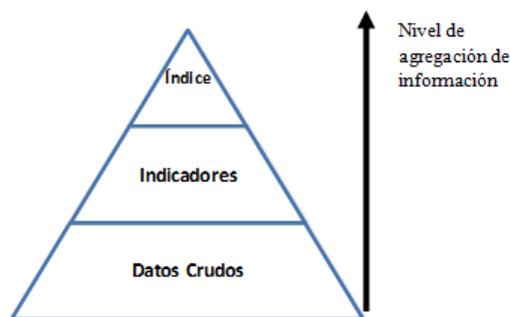


Figura 3 Nivel de agregación de la información para la construcción de índices a partir de indicadores y datos crudos (Magaña, 2012).

En la selección de indicadores de vulnerabilidad es recomendable no incluir una gran cantidad de indicadores pues esto elevaría la incertidumbre en proyecciones futuras. Posteriormente, habiendo seleccionado los indicadores se hace una priorización y ponderación para obtener los índices de vulnerabilidad. Por lo que de acuerdo con (Magaña, Zermeño, & Neri, 2012), el índice sería:

Ecuación 1

$$\text{Índice de vulnerabilidad} = (0.6 * \text{factor social}) + (0.3 * \text{factor económico}) + (0.1 * \text{factor físico})$$

#### **2.3.4. Dominio del objeto de estudio**

En México existen organismos como el CENAPRED (Centro Nacional para la Prevención de Desastres) y el INECC (Instituto Nacional de Ecología y Cambio Climático) que han desarrollado diagnósticos de escalas espacio-temporales para identificar los principales peligros meteorológicos que afectan al país. Un correcto diagnóstico debe incluir una valoración dinámica del riesgo de la zona expuesta. La determinación de la zona expuesta al riesgo está definida por una escala-espacial con base a la naturaleza y disponibilidad de datos (Cardona, 2001).

La extensión espacial para grupos sociales depende de la naturaleza de sus características particulares tales como: sexo, edad, estudios, ocupación y nivel socioeconómico; si embargo, aunque dos o más grupos tengan características similares, la percepción del riesgo puede diferir entre una y otra. Para el sector económico la dimensión espacial no cobra mayor importancia debido a que la determinación del objeto de estudio toma como base la capacidad de la infraestructura y políticas administrativas.

#### **2.3.5. Estrategias para la evaluación de vulnerabilidad**

La evaluación de vulnerabilidad conlleva el desarrollo de estrategias que permitan determinar los niveles de vulnerabilidad esperados cuando el índice de riesgo aumente (INECC, 2018; IPCC, 2007). Dentro de las principales estrategias para la evaluación de vulnerabilidad se tienen (Magaña, 2012):

- a) Uso de indicadores para construir índices cuantitativos.
- b) Selección de los indicadores más representativos para la evaluación de factores físicos, económicos y sociales.
- c) Conformadas por indicadores modelados a través de dinámica histórica para la proyección de tendencias futuras considerando cierto grado de incertidumbre.

La función principal de los indicadores es reducir los niveles de incertidumbre en las proyecciones futuras y establecer escenarios que contemplen medidas de adaptación. La Tabla 1 describe los elementos críticos a considerar para la selección de indicadores considerando el estado previo del sistema a escala particular e integral. Como se observa en la Tabla 1, en primer plano debe i) definirse el objeto de estudio considerando los criterios y reglas empleadas para el desarrollo de indicadores, ii) delimitar los aspectos que se van a evaluar y asignar el peso para cada uno, iii) normalizar el valor de los indicadores para obtener una escala general y iv) evaluar la utilidad del indicador.

Tabla 1 Características y algunos elementos a considerar en la construcción de los indicadores (Magaña, 2012).

<b>Características</b>	<b>Elementos referidos</b>	<b>Elementos considerados</b>
¿Qué se mide?	Variables utilizadas para el indicador. Criterios y reglas.	Parámetro fuente: población, ingreso, uso de suelo, etc.
¿Qué caracteriza o a qué hace referencia?	Aspectos físicos, económicos y sociales de la vulnerabilidad.	Disponibilidad de datos y calidad.
Prioridad y sensibilidad.	Importancia en el cálculo del índice de vulnerabilidad.	Explicar parte de los impactos.
Normalización de los indicadores.	Indicadores entre 0 y 1.	Operación aritmética simple.
¿Por qué es útil de medición?	Se refiere a una acción que genera vulnerabilidad.	Proceso de la dinámica de una región o sector.
¿Cómo se mide?	Formas de medir.	Censos, monitoreo, encuestas, etc.
Desglose	Elementos usados para construir el indicador.	Género, edad, actividad, etc.

## **2.4. Escenarios de impacto**

Como se ha mencionado en secciones previas, recientemente se ha observado aumentos en los niveles de vulnerabilidad debido a la incidencia de eventos meteorológicos elevando el riesgo en los sistemas agroalimentarios; por tanto, mediante la gestión del riesgo se puede identificar y corregir las causas que lo producen mediante el desarrollo de medidas de mitigación.

A diferencia de los escenarios cualitativos, los escenarios de riesgo cuantitativos permiten identificar la magnitud de las posibles repercusiones futuras dentro y fuera del sistema. Los escenarios cuantitativos ó escenarios de impacto tienen dos tipos de aproximación denominadas de “arriba hacia abajo” y de “abajo hacia arriba”.

La Figura 4 presenta dicha aproximación se denomina como de “arriba hacia abajo” donde propone seccionar por regiones los escenarios desarrollados para proyecciones de impactos a nivel global; es decir, busca ir de lo general a lo particular logrando un entendimiento más focalizado del sistema. En la mayoría del territorio mexicano, las tendencias actuales muestran un patrón ascendente en el comportamiento en variables como temperatura y ondas de calor (Pielke et al., 2013).

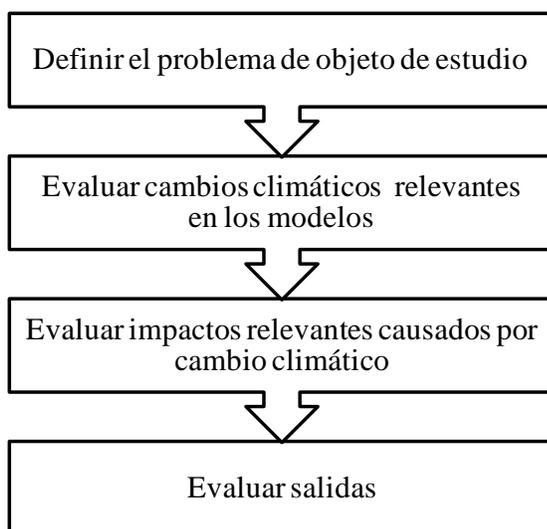


Figura 4 Aproximación de “arriba hacia abajo” para la formulación de escenarios de impacto ante cambio climático (Magaña, 2012).

Por su parte, la aproximación de “abajo hacia arriba” permite estimar las condiciones riesgosas de escenarios de impacto con base a las condiciones de vulnerabilidad considerando proyecciones futuras y antecedentes históricos. Esta aproximación resulta más útil para la construcción de acciones de mitigación. A través de la proyección temporal, la aproximación de “abajo hacia arriba” permite hacer estimaciones sobre las posibles repercusiones generadas por condiciones climáticas diferentes de las actuales. La Figura 5 muestra los niveles jerárquicos en las aproximaciones de “abajo hacia arriba”.

Los escenarios climáticos basados en la metodología establecida por el IPCC emplean aproximaciones de “abajo hacia arriba” para lograr una comprensión sistémica del ambiente, debido al análisis que va de lo particular a lo general permitiendo una gestión del riesgo más óptima.

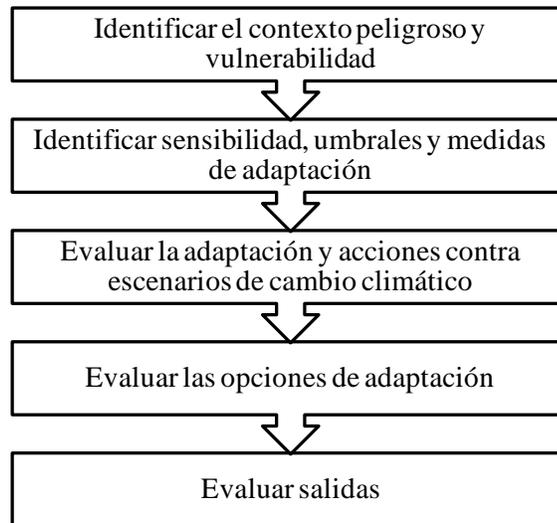


Figura 5 Aproximación de “abajo hacia arriba” para la formulación de escenarios de impacto ante cambio climático (Magaña, 2012)

Entre los años 1994-1996 tras un análisis de vulnerabilidad en el país, se determinó que México es muy vulnerable ante el cambio climático sobre todo en el ámbito agropecuario. Dentro de los factores que potencialmente incrementan la vulnerabilidad se encuentra la disminución de recursos en las actividades agrícolas, pérdida en la fertilidad de tierras, aumento de plagas en cultivos, generando una reducción de cultivos y aumento de pérdidas de ganado.

Aunque pronósticos realizados sobre tendencias futuras señalan que en un lapso de 50 a 100 años los efectos ocasionados por cambio climático serán mayores, actualmente se han presentando efectos secundarios principalmente en la agroindustria. Por ello, las medidas de adaptación desarrolladas deben garantizar mayor calidad y administración de recursos naturales (CONDE, 2011).

## 2.5. Riesgo e incertidumbre ante cambio climático

Bajo un enfoque climático, el peligro es la posibilidad de que suceda un fenómeno adverso el cual suele predecirse con base a información meteorológica histórica, en otras palabras; el peligro es una manifestación de amenaza dentro de un sistema vulnerable. Cuando el peligro se convierte en amenaza, ésta se materializa en impactos que potencialmente pueden aumentar el riesgo en el sistema.

La presencia de riesgo en el sistema incrementa la sensibilidad haciéndolo más vulnerable. La Secretaría Interinstitucional de la Estrategia Internacional para la Reducción

de Desastres (UNDRR, 2004) describe el concepto de vulnerabilidad como “una condición determinada por factores o procesos físicos, sociales, económicos y ambientales, que aumentan la susceptibilidad de una comunidad al impacto por amenazas”.

Sin embargo, existen otras definiciones para el concepto de vulnerabilidad, (IPCC, 2007) la definen como “el grado al cual un sistema es susceptible e incapaz de hacer frente a los efectos adversos del cambio climático, incluyendo la variabilidad climática y los extremos”.

Generalmente los niveles de riesgo son definidos por la exposición del sistema, ya que al no haber exposición la probabilidad de existir riesgo disminuye; por el contrario, al haber un incremento en la periodicidad y magnitud en la exposición la presencia de riesgo incrementa. De este modo, el riesgo es la combinación entre peligro y vulnerabilidad.

La Figura 6, describe la relación entre riesgo-peligro-vulnerabilidad ante el cambio climático.



Figura 6 Diagrama de la estructura del riesgo bajo cambio climático (Ipcc, 2007)

### 2.5.1. Riesgo y desastres

Un desastre podría definirse como “la materialización del riesgo” el cual está delimitado por características presentes en los peligros potenciales. Un análisis histórico permite predecir la probabilidad de incidencia de fenómenos climáticos catalogados bajo peligro. Una reducción en la probabilidad de impactos ocasionados por cambio climático implica no sólo reducir la magnitud de éstos fenómenos, sino reducir de igual manera los niveles de vulnerabilidad para contrarrestar los efectos adversos.

A escala mundial, los desastres originados por fenómenos meteorológicos han ido en aumento resultado del incremento de vulnerabilidad ocasionada por la alta exposición al peligro. La Tabla 2, muestra los costos generados por el impacto de desastres naturales en México.

Tabla 2 Costos originados por desastres naturales en México (El Economista, 2015).

<b>Desastre</b>	<b>Costos (millones de dólares)</b>
Terremotos	1,354.65
Inundaciones	870.08
Ciclones	613.02
Tormentas	103.05
Erupciones volcánicas	0

En el periodo 2005-2014 se estima que los daños originados por desastres naturales han causado la defunción de 1,968 personas, pérdida total de más de 2.5 millones de viviendas y daños en la estructura de 191,000 viviendas; trayendo como consecuencia pérdidas de entre 250-300 mil millones de dólares anuales.

La adopción de medidas de prevención ayudaría a disminuir los costos originados por desastres; para el 2015 se proyectaba una inversión de 6,000 millones de dólares/año para la prevención y disminución de riesgos, lo cual generaría un ahorro de casi 360,000 millones de dólares en los siguientes 15 años (El Economista, 2015). La Figura 7 muestra el porcentaje de impacto producido por desastres en México hasta el año 2015.

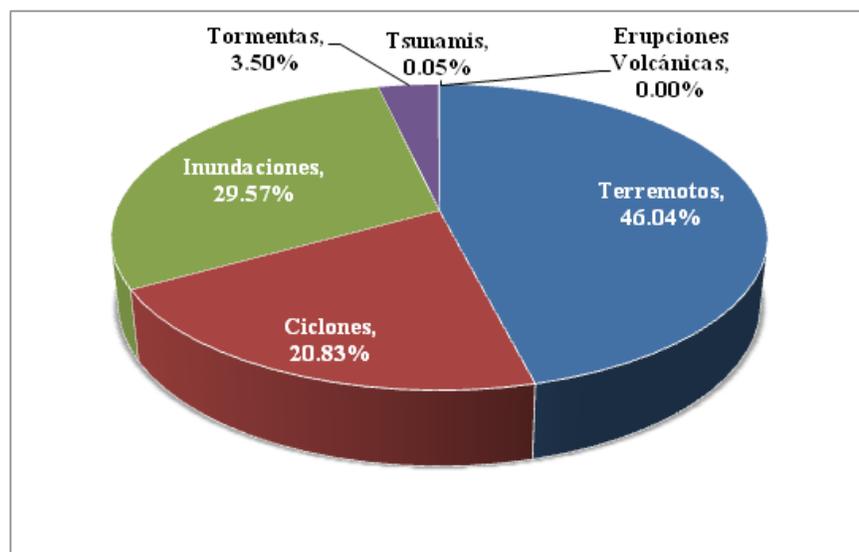


Figura 7 Costos ocasionados por desastres en México hasta el 2015

### 2.5.2. Incertidumbre

La suficiente robustez y una correcta interpretación de información, permite el manejo eficiente de recursos socioeconómicos y ambientales para enfrentar el cambio climático mediante estrategias de adaptación para la prevención y reparación de impactos (Gay and Estrada, 2010).

La evaluación de las probabilidades en la ocurrencia de los factores que causan impactos debe ser complementada con la integración de incertidumbre para obtener distintos escenarios que proporcionen mejores alternativas para la toma de decisiones.

Sin embargo, actualmente no se cuenta con una metodología apropiada para la gestión de incertidumbre; por lo cual, el estimar el riesgo se vuelve superficial y subjetiva. Visto desde el punto estadístico, se han planteado dos tipos de incertidumbre para la evaluación del riesgo:

- *“Aleatoria, se refiere a los casos en los que las probabilidades se pueden establecer mediante la observación y repetición de experimentos aleatorios”*; y
- *“Epistémica, se refiere a los casos en los que el resultado de un experimento es incierto porque existe conocimiento limitado, información incompleta o falta de comprensión”* (Gay et al., 2007).

Por la falta de una metodología para determinación de incertidumbre, a menudo se emplea un enfoque frecuentista para su modelado en los problemas correspondientes al cambio climático; no obstante, este tipo de métodos le dan un enfoque epistémico el cual imposibilita la estimación razonables de probabilidades.

### 2.6. México ante los riesgos del Cambio Climático

Dadas las condiciones edáficas y climatológicas, México se encuentra dentro de los países potencialmente más vulnerables de América Latina ante impactos generados por cambio climático por su ubicación geográfica elevando su exposición ante fenómenos meteorológicos (Gobierno de la República Mexicana, 2014).

En México, el CENAPRED es el organismo encargado de realizar estudios para determinar las zonas potencialmente en peligro. En la Figura 8 se muestran las zonas en peligro por sequía a nivel municipal para el año 2018. El concepto de sequía puede definirse como la falta o déficit de lluvia por periodos prolongados.

La Figura 8, se muestran los impactos producidos por sequía siendo diferentes para cada región puesto que en algunas zonas el déficit de sequía es mayor que en otras por las condiciones climáticas para cada región así como por la disponibilidad y acceso a recursos hídricos.



Figura 8 Grado de peligro por sequías (CENAPRED, 2018).

En la Figura 9 se observan las regiones más expuestas a inundaciones con base a criterios topográficos, edáficos y geológicos. Las zonas en color verde representan zonas con baja probabilidad de inundaciones, las zonas color amarillo con probabilidad media y las zonas rojas con alta probabilidad. Como se observa, alrededor del 23% del territorio nacional está propenso a un riesgo alto de inundación (INECC, 2018).

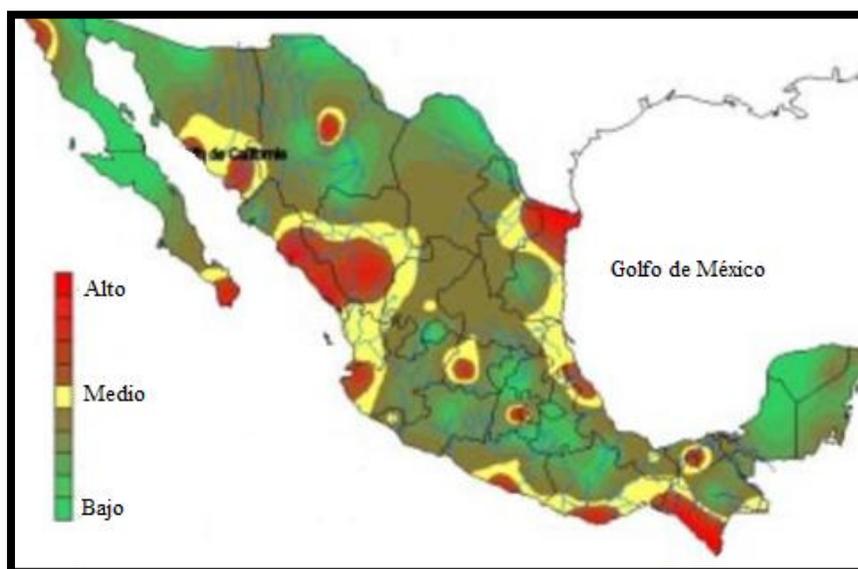


Figura 9 Distribución espacial de las zonas susceptibles a inundaciones (INECC, 2018).

### **2.6.1. Incremento de la temperatura de México en los últimos cincuenta años**

Proyecciones realizadas para un horizonte de 2046-2100 en países de Centroamérica, estima que la recurrencia de fenómenos meteorológicos mostradas en las figuras anteriores será mayor en cuanto a frecuencia y magnitud como consecuencia de los impactos generados por cambio climático. Por ello, se espera que las temperaturas en México aumentaran de 1.5 a 3°C, mientras que la frecuencia de lluvias extremas será mayor (CENAPRED, 2018; Gobierno de la República Mexicana, 2014).

Desde la década de los 60's, se han ido observando incrementos en la temperatura en México, algunas zonas que habían tenido un clima templado fueron modificando su clima a cálido. Estudios realizados por el IPCC demostraron que para esa época la temperatura promedio a nivel nacional había aumentado en casi 1°C para la temporada primavera-verano, mientras que para la temporada otoño-invierno el aumento observado había sido de 1.3°C.

Para el Norte del país, estados como: Baja California Norte, Chihuahua, Sonora, Coahuila, Nuevo León y Tamaulipas, los niveles de temperatura se han incrementado en hasta medio grado centígrado por década para el periodo 1960-2010. Por su parte, los niveles en los índices de precipitación han disminuido en el Sur desde la década de los 50's.

En México, los impactos generados a raíz del cambio en los patrones de comportamiento climáticos repercuten con mayor intensidad a los principales sectores prioritarios incluyendo: agricultura, hídrico, costero, ecosistemas, biodiversidad e infraestructura estratégica. Para el sector agrícola se estima una pérdida de hasta un 25% en la fertilidad de suelos, ocasionando una disminución en el crecimiento y reproducción de cultivos. Proyecciones para el 2050 señalan que el principal cultivo que se verá afectado será el maíz; sin embargo, para el año 2030 se podrá observar una disminución en el rendimiento de cultivos (SEMARNAT, 2014).

### **2.7. Inteligencia artificial como herramienta para la toma de decisiones**

La Inteligencia Artificial (IA), tiene diferentes definiciones por cada autor que escribe con respecto al tema, sin embargo, la que más se adapta al entorno actual es la expresada por la *Encyclopedia Of Artificial Intelligence* (Pino, Raúl; Gómez, Alberto; de Abajo, 2007).

*“La Inteligencia Artificial es un acampo de la ciencia y la ingeniería que se ocupa de la comprensión, desde el punto de vista informático, de lo que se denomina comúnmente*

*comportamiento inteligente. También se ocupa de la creación de artefactos que exhiben este comportamiento”.*

La IA tiene diversas áreas de aplicación, entre las que destacan: procesamiento del lenguaje natural, sistemas expertos, robótica, visión artificial, resolución de problemas y aprendizaje. Originalmente las investigaciones realizadas en torno a la IA estaban enfocadas en la obtención de una herramienta que pudiera emplearse para resolución de problemas.

Sin embargo, el intento por generalizar una herramienta para la solución de problemas ha ido perdido fuerza debido a que actualmente numerosas investigaciones se han enfocado en el diseño de software capaz de emular los procesos de toma de decisiones (Munarríz, 1994).

### **2.7.1. Sistemas Expertos**

De acuerdo con Bourcier, un sistema experto (SE) se define como *“un entorno lógico capaz de gestionar la propia base de conocimientos, resolver problemas bien delimitados y específicos, producir nuevos conocimientos y explicar su razonamiento. Los sistemas expertos (SE) pueden alcanzar resultados separando el conocimiento del razonamiento. La base de conocimientos representa el conocimiento experto de un campo determinado. Un sistema experto comprende tres ámbitos del conocimiento, la lógica, la psicológica cognitiva y asistencia de la decisión”* (Martínez Bahena, 2012).

Según L. Mehl (1986) (Grosan and Abraham, 2011), en un SE no trata de poner en marcha secuencias automatizadas de información, sino de representar situaciones reales y ofrecer al decisor la posibilidad de determinar mejor sus opciones. Usualmente, se entiende por sistema experto como un sistema de gestión; sin embargo, este enfoque diverge del concepto de un sistema experto, ya que los SE no son sólo modelos matemáticos debido a que éstos no se limitan a calcular, sino que razonan en un entorno (Jensen et al., 2005). La finalidad de un SE es el emular el razonamiento humano, basándose en dicho principio, se dice que un SE debe ser capaz de:

- Resolver la problemática cómo se resolvería mediante el razonamiento humano
- Trabajar con información limitada e incierta
- Mostrar los resultados logrados
- Adquisición de nuevos conocimientos
- Con base a la información disponible reestructurar conocimientos
- Desechar políticas o normativas que el experto considere irrelevantes para la problemática

Existen ventajas que los SE tienen sobre los expertos humanos, puesto que los SE documentan y transfieren información más fácil y rápidamente, además permiten reducir costos para todo tipo de organizaciones.

Sin embargo, también existen limitaciones que presentan los SE; un sistema experto carece de creatividad y sentido común, reciben sus entradas en forma simbólica mientras que un experto humano lo hace utilizando sus sentidos, por lo cual un sistema experto está a la desventaja durante la adquisición de conocimientos nuevos por sí mismo. La principal limitación que tiene un SE frente a un experto humano, es que un sistema experto nunca va a reemplazar por completo al trabajo de un hombre (Pino, Raúl; Gómez, Alberto; de Abajo, 2007).

### **2.7.1.1. Arquitectura de un Sistema Experto**

Un SE puede dividirse en dos partes: “*la base de conocimiento-memoria de trabajo*” y por el “*motor de inferencias-subsistemas e interfaces*” (Figura 10). La base del conocimiento contiene las reglas del conocimiento del experto humano y la información más relevante y representativa del objeto de estudio; dicha información debe de incluir todos elementos heurísticos que haya adquirido el analista o investigador a través de la expertís; éstos elementos pueden introducirse en la base del conocimiento tal como son extraídos del especialista (Sosa Sierra, 2011).

La memoria de trabajo está formada por los datos sobre la situación del problema de estudio. El repositorio de información puede utilizarse como memoria auxiliar la cual almacena el razonamiento y cómo éste ha sido empleado. El usuario final es quién se encarga de establecer los requerimientos bajo los cuales el SE tiene la facultad de explicar de llegar a los resultados finales. En ocasiones existe escepticismo acerca del funcionamiento de los SE, pero si el sistema puede llegar al resultado final, entonces el sistema experto es adecuado.

Un motor de inferencias, se define como “*un programa que se encarga de gestionar las informaciones existentes en la base de conocimientos y los datos de la memoria de trabajo, confrontándolos para de esta manera construir una serie de razonamientos que conduzcan a los resultados*” (Shokouhyar et al., 2019).

Los subsistemas e interfaces representan la subsistencia de adquisición del conocimiento, la subsistencia de la explicación y la interfaz del usuario o mejor conocidos como módulos, los cuales se emplean para la comunicación hombre-máquina. El usuario final de un SE es personal, puesto que no tiene relación con el desarrollo e implementación del sistema experto, por lo cual el sistema experto debe ser asequible y de fácil manejo, es

por tal motivo que la construcción de módulos debe permitir un fácil dialogo entre el SE y el usuario (Pino et al., 2010).

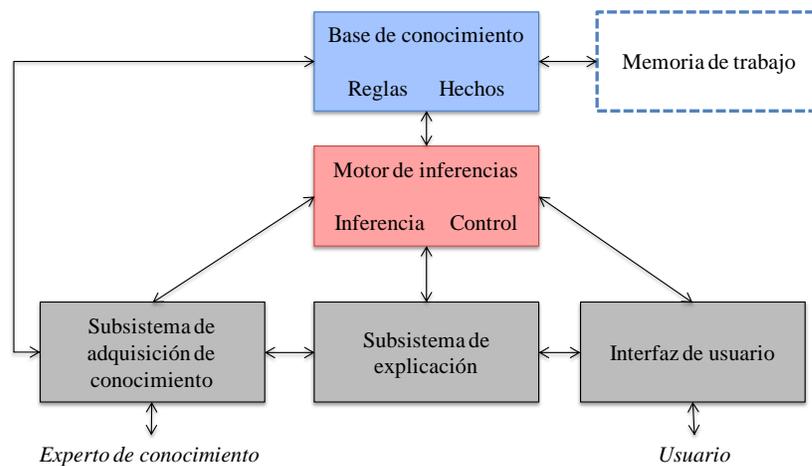


Figura 10 Arquitectura de un sistema experto basado en conocimiento (Pino et al., 2010).

### 2.7.1.2. Características de los Sistemas Expertos

Los SE deben cumplir ciertas características para que éstos sean útiles;

- a) Deben tener la capacidad para actualizar fácilmente sus conocimientos, la capacidad de actualización es necesaria no sólo para corregir las equivocaciones cometidas por el sistema experto, sino también para mantener la adquisición de nuevos conocimientos; es decir, los sistemas expertos deben tener la facultad de aprender nuevos hechos por sí mismos para incrementar los conocimientos.
- b) Deben poseer estrategias flexibles y similares a las del razonamiento humano para la solución de cualquier tipo de problemática; puesto que cada problema a resolver así como la información disponible para su solución, es diferente una de otra.
- c) Deben poseer elevadas prestaciones en términos de capacidad para resolver correctamente los problemas asignados.
- d) Deben ser capaces de explicar lo que están haciendo y porqué lo están haciendo, de la misma manera que el experto explica sus acciones.

Aquellos sistemas expertos con las características mencionadas anteriormente, han tenido resultados exitosos en la solución de problemas reales tales como el diagnóstico y el tratamiento médico, prospección minera y petrolífera, automatización industrial, gestión de calidad en productos industriales, diagnóstico de equipos, panificación, programación, interpretación de señales, análisis financiero, contabilidad, configuración de sistemas informáticos, por mencionar algunos (Ponce Cruz, 2010).

### 2.7.2. Lógica Difusa

De acuerdo a Lotfi Zadeh, la lógica difusa es *“una rama de la inteligencia artificial la cuál le permite a una computadora analizar información del mundo real en una escala entre lo falso y verdadero, la cual manipula conceptos vagos permitiendo analizar información difícil de definir”* (Zadeh, 1996).

El lenguaje natural permite manejar conceptos no precisos a través de un enfoque de lógica clásica evitando la pérdida del contexto y significado, pues de ser así el sistema experto perderá validez.

En 1965, Lotfi Zadeh, en su publicación *“Fuzzy Sets”*, describe la teoría de conjuntos y cómo se relaciona con la lógica difusa. La teoría de conjuntos establece una “función de pertenencia” para cada variable con respecto al conjunto al que pertenecen. Cada función de pertenencia toma un valor “verdadero o falso” delimitado por valores entre [0,1]; teniendo opciones de respuesta mayores e infinitas si no se acota adecuadamente el objeto de estudio (Zadeh, 2013),(Munarríz, 1994).

Al no contar con algoritmos que dicten la manera en que el sistema debe responder ante determinadas situaciones, la lógica difusa emplea el uso de “reglas de sentido común” definidas por expertos las cuales deben representar circunstancias inmersas en el objeto de estudio. Cuando se cuenta con la intervención de un experto los “sistemas difusos adoptivos” desarrollan reglas mediante la observación directa sobre la manera en que el hombre manipula sistemas reales.

La lógica difusa consta de tres fases para lograr los resultados deseados (Ponce Cruz, 2010), en la primera fase las variables tienen cierto nivel de incertidumbre metalingüística por lo que las variables son clasificadas en “conjuntos difusos” dependiendo del valor adquirido; cuando los sensores miden las variables, cada valor adquirido pasa por un proceso de “fusificación” en donde éstos valores pasan por una “propiedad de pertenencia” [0, 1] buscando determinar en qué grado el valor pertenece a dicho conjunto difuso.

Posteriormente, se propone las reglas lingüísticas o de inferencia, las cuales sirven como base para delimitar la conducta del sistema de forma idónea según el tipo de modelo de inferencia o los objetivos a alcanzar. En la tercera fase, a través del “proceso de desdifusificación” se determinan los valores óptimos para cada salida deseada. El proceso de desdifusificación permite relacionar las reglas de inferencia con un grado de pertenencia para obtener valores nítidos y reales. La lógica difusa ha tenido gran éxito al ser empleada sistemas de control, debido a que este conjunto de aplicaciones tiene las ventajas de:

- Aumentar la robustez en los métodos de control lineal.
- Diseñar de manera simple modelos complejos.
- Implementación simplificada.
- Autonomía.
- Adaptabilidad.

En las siguientes secciones se describen los elementos básicos de la lógica difusa.

### 2.7.2.1. Conjuntos difusos

Zadeh, define un conjunto difuso como “Una clase de objetos con continuos grados de pertenencia. Tal conjunto es caracterizado por una función de pertenencia, la cual asigna a cada objeto un grado de pertenencia que varía entre cero y uno”.

Un conjunto difuso representa un concentrado o conjunto de datos o elementos, en donde a cada elemento se le asigna una función de pertenencia al conjunto; en otras palabras, a cada conjunto difuso le corresponde una “función de pertenencia” en el rango de valores de [0,1] debido a que hay variables que no tienen límites claros (Liao, 2005). Los conjuntos difusos se representan mediante una virgulilla por encima de la letra, número o símbolo que lo denote:

Ecuación 2

$$\tilde{A} = \{a, b, c\}$$

La manera de representar los conjuntos difusos puede ser de manera continua o discreta, mediante las siguientes ecuaciones:

Ecuación 3

$$\text{Conjunto difuso discreto: } \tilde{A} = \left\{ \frac{\mu_A(X_1)}{X_1} + \frac{\mu_A(X_2)}{X_2} + \dots \right\} = \left\{ \sum_i \frac{\mu_A(X_i)}{X_i} \right\}$$

Ecuación 4

$$\text{Conjunto difuso continuo: } \tilde{A} = \left\{ \int \frac{\mu_A(X)}{X} \right\}$$

En un conjunto difuso continuo el símbolo integral  $\int$  denota unión de elementos del conjunto.

### 2.7.2.2. Funciones de pertenencia

Son funciones las cuales su forma o estructura lógica, sirven para establecer un valor a la “variable lingüística” asociada, es decir; indican en qué grado la variable lingüística pertenece al conjunto difuso. La representación de los “grados de pertenencia” para cada elemento del conjunto difuso se da mediante la extracción de información del fenómeno para establecer su “función de pertenencia” (Grosan and Abraham, 2011; Ponce Cruz, 2010). Una “función de pertenencia” debe adoptar la forma que mejor se adapte a los elementos del conjunto que se busque representar. Existen funciones de pertenencia convencionales y no convencionales las cuales asignan grados de pertenencia  $[0,1]$ . Las funciones de pertenencia más comunes son función L, gamma, triangulares, trapezoidales, singleton, gaussiana y sigmoidales (Munarríz, 1994).

Con base a la forma, las funciones de pertenencia generalmente se asocian con una distribución de probabilidad o de densidad, habiendo diferencias esenciales en la definición de cada una; sin embargo, usualmente las funciones de pertenencia son definidas por una “función de densidad”.

### 2.7.2.3. Variables lingüísticas

Las variables lingüísticas, se pueden definir como *“una herramienta para procesar lenguaje natural impreciso y difuso, las cuales se constituyen a través de números y la forma difusa de las expresiones humanas”* (Zadeh, 2013).

Por otro lado, Zadeh afirma que *“las variables lingüísticas son similares a las variables numéricas ya que tienen ciertos valores asociados a ellas. A diferencia de las variables numéricas, los valores de las variables lingüísticas no son números sino expresiones del lenguaje natural que describen alguna cantidad abstracta de interés”*, por ejemplo expresiones del tipo “mucho”, “poco”, “más ó menos”.

En este sentido, una variable lingüística puede tomar valores definidos por expresiones ambiguas que permitan describir el objeto de estudio; estas expresiones ambiguas son representadas a través de conjuntos difusos. La variable lingüística, como su nombre lo indica puede tomar valores lingüísticos para conformar conjuntos de etiquetas.

### 2.7.2.4. Reglas de inferencia

Las reglas de inferencia (RI) son reglas establecidas mediante la experticia y el conocimiento para describir cómo se comportará el sistema en estudio. Las RI se emplean

para describir las metas de control en términos de relación entradas-salidas. El proceso de inferencia suele ser más aproximado que exacto. Las RI son operadores lógicos del tipo “SI..... ENTONCES.....” asignadas para cada etiqueta lingüística de un conjunto difuso. Cuando el valor de una variable de entrada se asocia a un conjunto difuso, determinadas reglas de inferencia son activadas en el motor de inferencia para proporcionar un valor de salida (Sivanandam et al., 2007).

Las reglas difusas son empleadas en el razonamiento difuso como método para cuantificar un tipo particular de relaciones difusas; por ejemplo, cuando se tiene la condición difusa “Si  $X$  es  $A$  entonces  $Y$  es  $B$ ”, donde “ $A$  y  $B$ ” son variables lingüísticas, la condición  $A \rightarrow B$  expresa cierto tipo de relación entre  $A$  y  $B$ . Las reglas difusas sirven para trasladar la condición difusa  $A \rightarrow B$  a una relación difusa. Las reglas difusas pueden ser representadas mediante una memoria asociativa difusa ó *FAM* (Fuzzy Associative Memory) (Mendel, 1995; Nedjah et al., 2014).

Las FAM son matrices empleadas para representar de manera gráfica la relación que resulta de la combinación de variables de entrada. La representación debe expresar de manera clara la relación entre las variables lingüísticas de entrada y salida. En el motor de inferencia se deben indicar explícitamente todas las posibles combinaciones de las reglas entre las variables de entrada. A medida que el número de conjuntos difusos de las variables lingüísticas incrementa, la memoria asociativa difusa se vuelve más compleja.

Es posible definir FAM de más de dos dimensiones haciendo su tamaño excesivo dificultando aún más su manipulación; siendo más factible emplear FAM menos complejas en donde las reglas de inferencia se dividen en subconjuntos haciendo la asignación de pertenencia más eficiente.

#### **2.7.2.5. Proceso de difusificación y desdifusificación**

El proceso de difusificación se encarga de “mapear a escala” valores de entrada para convertir los valores de las variables a valores difusos. A través de la difusificación se obtienen los valores lingüísticos ó etiquetas lingüísticas que conforman los conjuntos difusos. La manera en que los conjuntos difusos representan información es mediante la discretización de información; es decir, segmentar los posibles valores que puede adoptar determinada variable de entrada asignándoles un valor de pertenencia para cada segmento.

Por su parte el proceso de desdifusificación consiste en convertir los valores difusos de las etiquetas lingüísticas en valores numéricos que se asignarán a la variable de salida utilizando los valores del grado de pertenencia de los conjuntos difusos. En este sentido, la desdifusificación es “*una herramienta para obtener una acción de control nítida a partir*

de una acción de control difusa” (Zadeh, 2008). La salida de control nítido se puede obtener mediante el “método de centro de gravedad” o el “método de centro máximo”.

### 2.7.2.6. Método de centro de gravedad y de centro máximo

El “método de centro de gravedad” sirve para obtener valores reales en las salidas a través de la segmentación de la función de pertenencia en dos áreas de solución factible. En el área inferior se lleva a cabo el proceso de desdifusificación y es donde se hacen los cálculos; posteriormente ambas áreas se traslapan para determinar el “centroide de superposición” obteniéndose valores de salida nítidos o reales.

El “método de centro máximo” es un método simplificado, para calcular el valor más frecuente o lógico para cada etiqueta lingüística a través del máximo valor observado en la “función de pertenencia”. En las funciones de pertenencia de tipo trapezoidal se selecciona el valor medio maximizado de la función. Posteriormente, le es asignado un valor conforme sea el grado de pertenencia.

La lógica difusa, tiene tres etapas, la fusificación, mecanismo de inferencia y la desdifusificación. En fusificación, son introducidos los valores de entrada al sistema difuso asignándoles un grado de pertenencia, para posteriormente pasar al mecanismo de inferencia en donde se va a seleccionar, decidir, interpretar y aplicar la expertís, para conseguir una solución deseada. Por último en la desdifusificación, es en donde los valores difusos obtenidos en el mecanismo de inferencia, toman valores de igual unidad que las variables de entrada; es decir, valores no difusos (Figura 11).

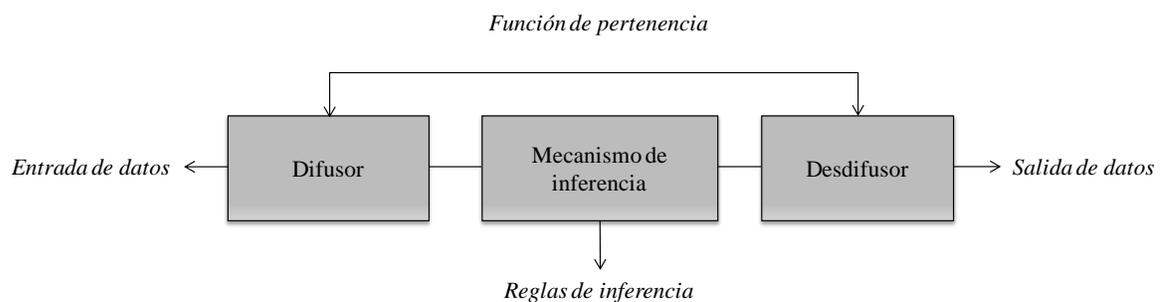


Figura 11 Proceso de Lógica Difusa (Zadeh, 2013) .

- *Entrada de datos:* En esta etapa las variables lingüísticas van a ser ingresadas al sistema adoptando valores delimitados por expresiones para representar el estado del fenómeno de estudio; estas expresiones son representadas mediante conjuntos difusos.

- *Difusor*: Es el conducto por medio del cual las variables de entrada son convertidas en difusas.
- *Mecanismo de inferencia*: Procesador que se emplea para pasar los valores difusos a reales por medio de reglas de inferencia.
- *Reglas de inferencia*: Aquellas reglas que determinan las operaciones a realizar para resolución de problemas, las cuales se derivan de la expertís.
- *Desdifusor*: Es el encargado de tomar un valor difuso y convertirlo en un valor real o concreto de salida, mediante métodos matemáticos de desdifusificación.
- *Función de pertenencia*: Definen la variable lingüística indicando la medida en la que ésta pertenece al conjunto difuso.
- *Salida de datos*: Datos reales, nítidos o concretos.

### 2.7.3. Dinámica de Sistemas

La herramienta de Dinámica de Sistemas (DS) permite modelar y simular sistemas complejos (Jay Forrester (1918), 1961). El objetivo de DS es comprender las causas estructurales que conforman al sistema y sus relaciones causales a través del comportamiento y análisis profundo de cada elemento que integra el sistema y ver como diferentes acciones efectuadas sobre ciertas partes de interés del sistema incrementan o disminuyen las tendencias del comportamiento implícitas en el mismo; en otras palabras, dinámica de sistemas no busca predecir el comportamiento a futuro del sistema y su entorno con efectividad alta, sino que en realidad busca estudiar al sistema mediante la implementación de estrategias y políticas que modelen al mismo y con ello enriquecer el conocimiento del mundo real comprobándose las hipótesis planteadas (Cedillo-Campos, 2008).

La implementación de DS para administrar sistemas organizacionales remonta en la década de los 30's, dando origen al concepto de *feedback* conocido como bucle de retroalimentación, el cual, marco los inicios de los "sistemas complejos". La aplicación de dinámica de sistemas consta principalmente de modelación matemática definida por ecuaciones diferenciales en su mayoría, conocimientos disponibles del área de interés por analizar para delimitar la problemática; por lo que, la dinámica de sistemas se apoya en aspectos cualitativos y cuantitativos. La Figura 12 muestra el análisis de dinámica de sistemas en los sistemas complejos.

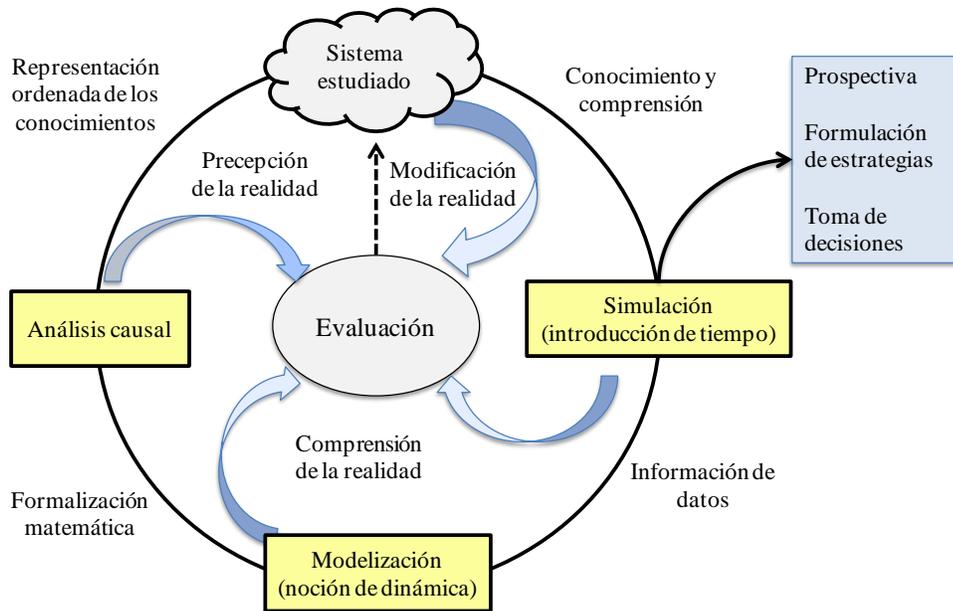


Figura 12 Análisis a través de la dinámica de sistemas complejos (Cedillo-Campos, 2008).

### 2.7.3.1. Enfoque sistémico

El enfoque sistémico cuenta con cuatro aspectos fundamentales: interacción, totalidad, organización y complejidad. La interacción del flujo de información entre cada elemento del sistema conlleva una acción recíproca que interfiere y modifica el proceder de los elementos en el entorno. El flujo de información entre dos elementos, sean *A* y *B*, no siempre es una relación causal de *A sobre B*, sino que dicha relación puede adoptar una doble acción: *A sobre B* y *de B sobre A*.

$$A \leftrightarrow B \text{ en lugar de } A \rightarrow B$$

La interacción de los elementos en un sistema bajo un enfoque de dinámica de sistemas se clasifica en:

- a) Relación clásica causa-efecto.
- b) Relación temporal en el cual un evento *A* es seguido por cierta diferencia por un evento *B*.
- c) La acción de retroacción “*feedback*”, donde cualquier acción de *B* en *A* origina una acción de respuesta de *A* en *B*. Esta relación, puede ser simplificadora del efecto y en ese caso se habla de un bucle de retroalimentación positivo. Por lo contrario, si existe equilibrio el bucle de retroalimentación será negativo.

Cuando se estudian o analizan todas las partes que integran un sistema se hace referencia a la totalidad; sin embargo, esto no significa que la totalidad sea la sumatoria de todos los

elementos como en el razonamiento analítico, sino que el todo implica la aparición de cualidades emergentes que no poseen las partes de manera individual, dando origen a la “jerarquía sistémica”, donde conforme se aumenten los niveles organizacionales del sistema aumenta la complejidad, ya sea de manera local o global.

La organización es el conjunto de relaciones entre componentes o elementos, los cuales al constituir un sistema nuevo poseen cualidades que no tienen los integrantes de manera individual; por lo que la organización debe ser estudiada bajo los aspectos estructural y funcional. El aspecto estructural es generalmente representado por un esquema, mientras que al aspecto funcional los representa un programa. Con base a los objetivos planteados el experto es quien da prioridad al aspecto a estudiar sin dejar de lado la relación entre ellos.

Para lograr una mejor organización, como primer paso es reducir la variedad en los métodos para encontrar soluciones, posteriormente se procede a obtener una mejor organización capaz de establecer nuevas formas relacionales entre subsistemas de elementos estables mejor conocidos como subsistemas. Con lo anterior, es posible establecer relaciones internas en los subsistemas o entre ellos mismos, lo que conlleva a la noción de niveles de organización (Figura 12) para incrementar la variedad de posibles soluciones más simples eliminando lo desconocido, lo aleatorio y lo incierto.

La noción de complejidad a menudo es confundida con la noción más simple de complicación, la segunda hace referencia a un sistema el cual necesita mucho tiempo para ser comprendido. Un sistema complejo requiere además de tiempo, un pertinente enfoque metodológico y un profundo análisis del entendimiento del problema. El grado de complejidad de un sistema depende de la cantidad de elementos que lo componen y del número de relaciones que unen elementos entre ellos (relaciones causales).

### **2.7.3.2. Análisis causal**

El análisis causal o también conocido como estructuración cualitativa, permite obtener una representación ordenada del sistema a estudiar mediante la estructura de relaciones de influencia entre variables parámetros y datos.

Al desarrollar una representación del análisis causal del sistema, se debe seleccionar e integrar variables que en un momento u otro tengan influencia en el progreso del sistema; razón por la que un diagrama causal a menudo suele ser muy extenso para englobar los parámetros que expliquen la problemática del sistema. Las variables y las relaciones de influencia no consideradas en el análisis (modelación y simulación) se presentan con forme el modelo va tomando complejidad.

Lograr un análisis causal que comprenda todas las variables importantes del sistema, se exhorta ir de micro a macro; es decir, comenzar con submodelos que comprendan de 15 a 20 variables para ir explicando de manera detallada el sistema, haciendo énfasis en la interacción de los submodelos para tomar decisiones.

Una vez establecidas las variables que constituyen al modelo y las interrelaciones causales, se representan gráficamente las interrelaciones de las variables mediante flechas acompañadas por un signo (+ ó -) dependiendo si la influencia sobre la variable es positiva o negativa; por lo que Martín J., sintetiza que *“El signo positivo representa un cambio en la variable origen de la flecha que producirá un cambio del mismo sentido hacia la variable destino. El signo negativo simboliza que el efecto producido será en sentido contrario”* (García, 2017). En otras palabras, la relación será positiva si la acción de incremento o disminución de A en B actúa de igual manera de B en A; mientras que si la acción es a la inversa entonces la relación será negativa.

Los modelos de DS se pueden representar a través de bucles de retroalimentación. De acuerdo con Chavez-Guillén, *“un bucle es una cadena cerrada de relaciones causales. Los bucles negativos actúan como elementos estabilizadores de los sistemas al dirigirlos hacia un objetivo determinado”* (Chavez Guillén, 2010). Los bucles positivos se presentan si la suma de bucles negativos es par, y negativos si es impar. Los bucles negativos conducen al sistema hacia una situación estable y los bucles positivos lo hacen inestable.

### **2.7.3.3. Componentes básicos de un modelo de Dinámica de Sistemas**

Durante el estudio de sistemas complejos surgen problemáticas a micro-nivel y macro-nivel. El micro-nivel es aquél que se interesa en las interrelaciones de causa-efecto. Mientras el macro-nivel estudia las relaciones de los subsistemas elementales.

Los modelos de DS tienen componentes y características diferentes debido a su naturaleza, los cuales pueden variar o no su valor cuantitativo. Una “variable” es aquella que varía en función del tiempo, por lo contrario se le denomina “tasa o parámetro” aquellos que pueden ser endógenos o exógenos ya sean propias o ajenas al sistema estudiado. A su vez, los modelos dinámicos utilizan “variables de estado o nivel” para contener el flujo, los cuales varían su nivel dependiendo del flujo de información de entrada y salida. Las variables encargadas del flujo o transferencia de información se les denominan “válvulas” que controlan los flujos por unidad de tiempo; las cuales están abiertas o cerradas en función de los parámetros.

Las válvulas pueden variar durante la simulación o por variables auxiliares. Las variables auxiliares permiten visualizar el comportamiento y condicionantes de los flujos. Las variables constantes son poco empleadas en los modelos de DS debido a que la

variabilidad de los aspectos que se analizan no suelen ser estáticos. Las fases de los modelos DS son: conceptualización, formulación, evaluación e implementación, a continuación de describen en la Figura 13 (Cedillo-Campos, 2008).

Primera fase: Conceptualización	Segunda fase: Formulación	Tercera fase: Evaluación	Cuarta fase: Implementación
<ul style="list-style-type: none"> <li>• Seleccionar el escenario</li> <li>• Definir el propósito del modelo</li> <li>• Identificar las variables críticas y los límites del modelo</li> <li>• Establecer el horizonte del tiempo</li> <li>• Establecer las relaciones entre las variables conocidas como hipótesis dinámicas</li> <li>• Desarrollar el diagrama causal</li> </ul>	<ul style="list-style-type: none"> <li>• Desarrollar el diagrama de bloques (Forrester)</li> <li>• Determinar las ecuaciones matemáticas del modelo</li> <li>• Estimar y seleccionar los parámetros del modelo</li> </ul>	<ul style="list-style-type: none"> <li>• Simulación del modelo y prueba de hipótesis dinámicas</li> <li>• Prueba del modelo bajo diferentes supuestos</li> <li>• Respuesta del modelo con análisis de sensibilidad</li> </ul>	<ul style="list-style-type: none"> <li>• Comportamiento del modelo bajo diferentes políticas</li> <li>• Presentar el modelo en una forma accesible al usuario</li> </ul>

Figura 13 Fases del modelado de Dinámica de Sistemas

#### 2.7.4. Sistemas basados en Agentes Inteligentes

Un modelo basado en agentes tiene la capacidad de incluir dos o más “agentes virtuales” que son en diferente medida heterogéneos, independientes y autónomos con objetivos propios a realizar tanto individualmente como en conjunto.

Un modelo basado en agentes es un modelo que contiene agentes heterogéneos (empresas virtuales) que actúan en un entorno virtual (Li and Chan, 2013). Después de caracterizar el sistema de estudio se procede a programar cada agente inteligente en una plataforma de software especializado para representar y simular el sistema de estudio.

##### 2.7.4.1. Modelo agente actor

Las características sociales de cada individuo afectan la toma de decisiones. Tales decisiones resultan en acciones ejecutadas por un actor de la organización. Un actor es una entidad social, un individuo o grupo de individuos. Labarthe, Tranvouez, Ferrarini, Espinasse, & Montreuil proponen modelar sistemas dinámicos complejos como un conjunto de actores. El modelo agente actor consiste en un modelo simplificado de la realidad que permite el estudio del comportamiento a través del par decisión-acción. El desarrollo del modelo requiere identificar los elementos del sistema real con sus actividades asociadas.

Las mismas actividades se agrupan en uno o varios agentes de decisión o de simulación. El agente actor está compuesto por agentes (deliberativos o reactivos) que modelan las diferentes actividades de un actor. El agente decisión representa la serie de actividades inmersas en la toma de decisiones de un actor del sistema y transmite las decisiones al agente simulación. El agente simulación reproduce la conducta de una actividad operacional y transmite señales al centro de decisión para comunicar los efectos de las actividades.

#### 2.7.4.2. Características de los agentes inteligentes

El concepto de agentes inteligentes es un tema reciente que desde 1980 se ha aplicado ampliamente (Yancato Gurmán, 2012). En la Tabla 3 describe las características de los agentes inteligentes.

Tabla 3 Características de los Agentes Inteligentes (Yancato Gurmán, 2012)

Característica	Descripción
<i>Autonomía</i>	Capacidad de actuar sin la intervención directa de una persona o de otro agente. Un agente debe poder controlar sus propias acciones y estado interno. Una vez que el usuario activa el agente indicando algún objetivo de alto nivel, éste actúa independientemente, seleccionando estrategias y monitoreando el progreso en busca de la meta. Si falla con una estrategia, usará otra, pero sin intervención humana o con la mínima indispensable.
<i>Habilidad Social</i>	Un agente debe ser comunicativo. Debe tener habilidad para interactuar con otros agentes o incluso con alguna persona, para solicitar información o bien para exponer los resultados que se obtienen de la ejecución de las tareas programadas. La naturaleza de la comunicación dependerá del tipo de agente con quien se comunique (humanos o no), en ambos casos se deberá establecer un protocolo común de intercambio de información entre ambas partes.
<i>Reactividad</i>	Se refiere al hecho de que un agente debe poder pensar el estado del ambiente dentro del cual se encuentra inmerso y -en función de esto- actuar, respondiendo de manera adecuada a cambios producidos en el mismo.
<i>Orientación por Objetivos</i>	Un agente no sólo debe actuar por cambios detectados en el medioambiente, sino que – además –debe “trabajar” en función de los objetivos para los cual fue diseñado y las tareas que le fueron delegadas en cada momento. Un agente busca permanentemente satisfacer su agenda interna.
<i>Continuidad Temporal</i>	Un agente es un proceso temporalmente continuo. A diferencia de un programa convencional del cual se conoce su inicio y fin, un agente debe ejecutarse hasta que se haya alcanzado con el conjunto de objetivos solicitados, o bien, mientras su ciclo perdure y su usuario no desee detenerlo.
<i>Movilidad</i>	Es la capacidad de un agente de “viajar” por las redes de computadoras, de nodo a nodo, en busca de los recursos que le permitan cumplir con su agenda. El término “viajar” se refiere a que en un determinado instante de tiempo el agente detiene su ejecución, almacena su estado interno y se dirige a otro sitio dentro de una red de computadoras para luego continuar con su ejecución en la nueva ubicación.

### **2.7.4.3. Sistemas multi-agente**

Los sistemas multi-agente están compuestos por dos o más agentes inteligentes que interactúan entre ellos. Los sistemas multi-agentes a menudo son empleados para dar soluciones a sistemas complejos difíciles de resolver por un agente. De acuerdo a Hípola & Vargas, un agente inteligente se puede definir como:

*“Un agente inteligente es una entidad que, basándose en su propio conocimiento, realiza un conjunto de operaciones destinadas a satisfacer las necesidades de un usuario o de otro programa, bien por iniciativa propia o porque alguno de éstos se lo requiere”* (Hípola Ruiz and Vargas Quesada, 1999).

La simulación multi-agente permite establecer diversos escenarios con entidades activas (agentes) y reactivas para estudiar la problemática y los posibles estados del sistema a estudiar. Los sistemas multi-agente son una técnica de inteligencia artificial capaz de emular entidades, procesos y flujos los cuales caracterizados por incertidumbre.

### **2.7.5. Procesamiento de imágenes**

El procesamiento o tratamiento de imágenes consiste en un análisis que se orienta a un procesamiento de aprendizaje de imágenes continuas. Las técnicas de nitidez y enfoque en la adquisición de imágenes han cobrado mayor relevancia para el aprendizaje mediante técnicas de inteligencia artificial (Sarbjit Kaur, 2016).

El procesamiento de imágenes reduce el ruido por medio de cambios en la intensidad de los colores que integran una imagen, y con ello acotando el umbral de valores en los límites superiores e inferiores de la región de cada pixel. Usualmente el procesamiento de imágenes conlleva la difuminación y binarización para detectar los elementos contenidos en una imagen que necesita un pre-tratamiento.

El pre-tratamiento ó pre-procesamiento de imágenes tiene como objetivo encontrar y extraer características de interés (regiones de pixeles) que conforman una función umbral formando un algoritmo de búsqueda para identificar patrones de comportamiento (Montoya Holguin et al., 2014).

Para la normalización del contraste y efectos de brillo de la imagen, deben ser sustraídos los valores medios de las distintas intensidades y dividirse por la desviación estándar. Para las imágenes a color se debe realizarse un cambio binario para que la imagen sea convertida

a escala de grises (Figura 14) y evitar mayor procesamiento en los canales RGB (rojo, verde y azul).

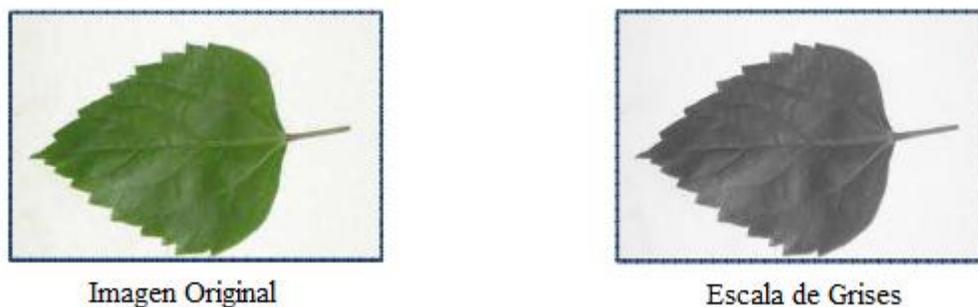


Figura 14 Conversión de una imagen a escala de grises.

### 2.7.5.1. Binarización

La binarización consiste en el pre-procesamiento de la imagen para representarla a través de píxeles para transformar, clasificar y utilizar la imagen para reconocer otra. A menudo es decisión del experto identificar si es conveniente la modificación del área de color, cambio a escala de grises o de los parámetros a optimizar en una imagen; siendo un proceso “a prueba y error” hasta obtener los resultados deseados.

Previo al procesamiento de una imagen, primero se deben buscar regiones dentro de la imagen las cuales se consideran picos o secuencias de píxeles para hacer más fácil la clasificación en las regiones y establecer un patrón. Durante la binarización, la imagen es transformada a escala de grises como se muestra en la Figura 14, en donde cada píxel recibe valores de 0 - 255. La Figura 15 muestra los valores en los píxeles en escala de grises del rango 0 – 255.

218	210	206	139	150	92	143	74
174	181	203	169	117	178	120	82
164	189	183	168	168	171	158	95
173	191	212	199	141	142	111	211
155	167	224	176	103	99	85	218
205	212	227	218	104	192	114	206

Figura 15 Valores de los píxeles de una imagen convertida a escala de grises.

La escala de grises permite crear una representación binaria de la imagen detectando zonas de interés asignando un valor a cada pixel estableciendo un umbral cuando el valor del pixel este arriba/abajo del umbral deseado (Figura 16).

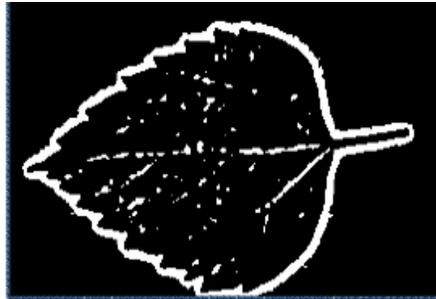


Imagen binarizada con umbral

Figura 16 Representación de una imagen binarizada.

### 2.7.5.2. Difuminado

Otra técnica empleada frecuentemente es el difuminado, éste consiste en promediar los valores de los pixeles de la imagen dependiendo de valor de intensidad de los pixeles circundantes para suavizar las variaciones de intensidad y lograr una transición gradual. La función de “algoritmo de suavizado” (Ecuación 5) toma en cuenta el peso de los píxeles más próximos.

Ecuación 5

$$G(x, y) = \frac{1}{2 * \pi * \sigma^2} * e^{\frac{-x^2+y^2}{2*\sigma^2}}$$

Donde  $x$  representa la distancia desde el punto de pixel del eje horizontal;  $y$  es la distancia desde el punto del pixel del eje vertical y  $\sigma$  es la desviación estándar.

Al aplicar en dos dimensiones la distribución Gaussiana produce una superficie cuyos contornos son círculos concéntricos desde el punto central (Figura 17).



Imagen suavizada

Figura 17 Imagen suavizada mediante la distribución Gaussiana.

### 2.7.5.3. Histograma de gradientes

Las imágenes a procesar comúnmente poseen información adicional innecesaria para el análisis del procesamiento de imágenes; para evitar este tipo de errores, la imagen debe ser simplificada extrayendo la información importante contenida separándola del resto. Este proceso es conocido como “extracción de características”.

Cuando se requiere establecer patrones de comportamiento, la extracción de características tiene mayor relevancia para el rendimiento del algoritmo. Las técnicas más utilizadas para extraer características son: Detectores de características de Haar, Histograma de Gradientes Orientados (HOG), Transformación de Caracteres Invariantes (SIFT), Función Robusta Acelerada (SURF), etc. (Wang, 2014).

Un histograma es una manera de representar la distribución de las intensidades o variaciones en los píxeles que constituyen una imagen, ya sea a color y/o escala de grises. En los canales RGB en donde el rango va de 0 a 255, si un histograma es trazado en el eje X existen 256 bins; es decir, el número de ciclos que el píxel produce ese valor; por lo contrario si solo son utilizados dos espacio equitativos, entonces se duplicaría el número de píxeles dentro del rango [0, 128] o [128, 255]. La Figura 18 muestra la representación del histograma RGB de una imagen.

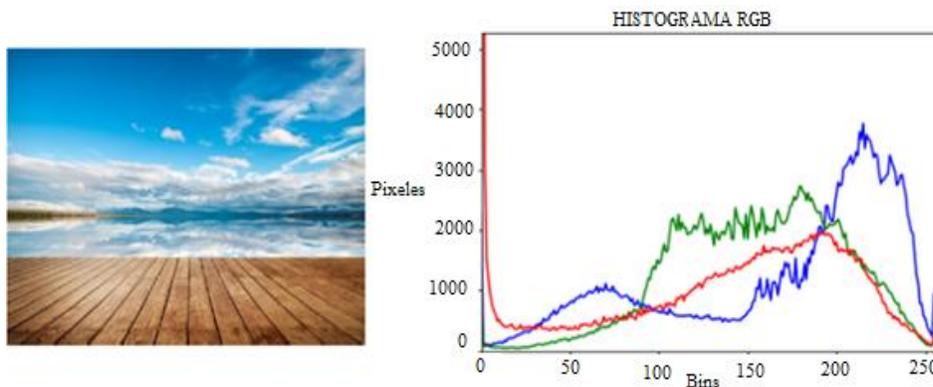


Figura 18 Histograma de color en los canales RGB de una imagen.

En la Figura 18, existe un pico más alto en el histograma azul ( $\approx$  bin 210) lo cual indica un valor azul más claro dado por el rango de colores que integran el cielo.

Visto desde este modo, los algoritmos de procesamiento tienen como objetivo el convertir una imagen de tamaño cual sea en un vector, lo cual sirve para la detección de patrones. El histograma de gradientes (HOG) tiene como principio describir la “aparición del objeto local” a través de un histograma (Dalal and Triggs, 2005).

## **Capítulo 3. Estado del arte**

### **3.1. Panorama de la agricultura ante cambio climático**

Los efectos generados por efectos de cambio climático han traído serias repercusiones en el medio ambiente impactando principalmente los sistemas agrícolas. Estos impactos se fundamentan principalmente en variaciones en variables como temperatura y niveles de precipitación. Actualmente, existen proyecciones de escenarios que indican que para los próximos cincuenta años se espera que las variaciones en temperaturas sigan en ascenso; por su parte, se esperan niveles de precipitación imprevistos en cuanto a magnitud y frecuencia.

Como consecuencia, estas variaciones traen consigo impactos significativos en los cultivos, siendo los cultivos de granos los más afectados por presencia de fenómenos como sequías y ondas de calor; éste último es el que mayor impacto ocasiona en la floración, fase reproductiva, rendimiento de los cultivos por su influencia en procesos fisiológicos del cultivo como en el proceso de polinización y fotosíntesis a nivel del suelo generando pérdidas en la cosecha (Araus et al., 2008; Barnabás et al., 2008; Semenov and Halford, 2009).

Estudios desarrollados relacionados con el estrés térmico en cultivos indican que inclusive incrementos moderados en la temperatura disminuyen el rendimiento de cultivos como: maíz, frijol, arroz y cacahuates. Las temperaturas nocturnas altas pueden influenciar negativamente los rendimientos.

### **3.2. Estudio de la vulnerabilidad y riesgo en sistemas agrícolas**

El estudio de sistemas alimentarios vulnerables, surge para fortalecer e incrementar la seguridad alimentaria. Los principales aspectos a considerar es el acceso y disponibilidad de alimentos mediante el planteamiento de escalas espacio-temporales. Para comprensión efectiva de los sistemas alimentarios en relación al cambio climático a micro y macro nivel, se requiere del análisis de las tendencias y desarrollo de modelos para obtención de posibles escenarios futuros de cultivos y su relación con los elementos del entorno en que éstos se desarrollan (recursos, comunidades, organizaciones, políticas agrícolas, factores socioeconómicos, etc.).

Dentro de investigaciones relacionadas en torno al riesgo y vulnerabilidad a eventos extremos en sistemas de alimentos, se encuentran estudios realizados por (Paloviita et al., 2016) éstos se enfocaron en la vulnerabilidad del sistema alimentario en Finlandia, el cual se concentra más en la agricultura que en el sistema alimentario debido a que se rige por

políticas definidas en agricultura y silvicultura. Además de las políticas, la vulnerabilidad del sistema alimentario se centra en controladores exógenos tales como: cambio climático, riesgos y condiciones meteorológicas extremas.

En este estudio se abordan temas de vulnerabilidad ambiental y social. Los autores desarrollan una matriz de vulnerabilidad en donde proponen 13 factores de vulnerabilidad (filas) y 5 zonas de vulnerabilidad (columnas): actividades del sistema alimentario, cadenas de suministro (CS), grupos vulnerables, sistemas naturales y sistemas técnicos.

La matriz de vulnerabilidad emplea información previa desarrollada por estudios anteriores y datos empíricos. Las zonas vulnerables: sistemas naturales y sistemas técnicos corresponden a una nueva base de datos obtenida empíricamente. Algunos de los factores de vulnerabilidad son: fertilidad del suelo, degradación, enfermedades de plantas y animales, eventos meteorológicos extremos, escasez de agua, propagación de contaminantes, empobrecimiento, políticas alimentarias, región, alimentos insalubres y concentración del mercado.

La matriz de vulnerabilidad tuvo éxito en el sistema alimentario finlandés, ya que aborda toda la información relacionada con seguridad alimentaria y la cadena de suministro. El análisis realizado sobre los impactos ocasionados por cuestiones climáticas en la agricultura se centra en modelos de simulación para representar los ecosistemas agrícolas (tales como modelos de cultivos o pastizales), escenarios socioeconómicos y variables climáticas para determinar los posibles riesgos climáticos. Los estudios de este tipo proporcionan estimaciones cuantitativas de las futuras consecuencias para la productividad y otros servicios agrícolas.

Este tipo de investigaciones adaptan modelos de simulación para permitir un análisis cuantitativo en los ecosistemas agrícolas al estar expuestos a riesgos producidos por cambio climático. Por tanto, la vulnerabilidad es definida como una combinación de la exposición extrínseca de los sistemas ante un cambio meteorológico, la sensibilidad intrínseca al peligro y la falta de capacidad para absorber y recuperarse de las pérdidas resultantes ante amenazas.

(Eza et al., 2015), proponen una plataforma alimentada por modelos basados minería de datos y técnicas de inteligencia artificial como lógica difusa para caracterizar y analizar la vulnerabilidad climática en la región de Auvernia, Francia. Estos modelos son capaces de estimar la producción o rendimiento, así como las variables ambientales (balances de agua y nitrógeno, GEI, etc.).

Los modelos se apoyan en indicadores agroclimáticos e índices de vulnerabilidad; los indicadores agroclimáticos se implementan para detectar los riesgos producidos por

condiciones meteorológicas durante la gestión de la actividad agrícola, los indicadores agroclimáticos utilizados generalmente son número de días de heladas, cálculo de precipitaciones durante periodos específicos, precipitación, ondas de calor y temperatura del aire. Los índices de vulnerabilidad son generados mediante simulaciones de condiciones climáticas y representan las variables de impacto que caracterizan al sistema. Los resultados obtenidos detectaron áreas de oportunidad que minimicen los riesgos agrícolas.

Diversos estudios relacionados con vulnerabilidad agrícola por condiciones climáticas, se enfocan en el uso de bio-controladores de vulnerabilidad y en impactos en la producción agrícola generalmente afectan la topografía, el suelo y la concentración de bióxido de carbono.

(Mitter et al., 2015) desarrollaron un sistema que evalúa la vulnerabilidad en un sistema agrícola que combina aspectos biofísicos, sociales y económicos en Austria para determinar el impacto de los aspectos biofísicos (variabilidad del clima, el suelo, topografía y condiciones agronómicas) y socioeconómicos (agro-política, niveles de riesgo en el sistema agrícola). Las etapas del sistema de evaluación constan de cinco etapas:

(i) Evaluación de impactos en diversos escenarios de la agricultura, (ii) Identificación de las variables óptimas para medir la adaptación del sistema ante la vulnerabilidad, (iii) Evaluación del efecto de las políticas agrícolas en los indicadores de vulnerabilidad, (iv) Evaluación en niveles de oposición al riesgo en el manejo de indicadores, y en la etapa (v) se desarrollaron seis modelos para reducir vulnerabilidad; los cuales son:

- I. Modelo estadístico de cambio climático en Austria utilizando regresión lineal.
- II. Modelo de rotación de cultivos el cual construido por datos históricos del número de cosechas por regiones y las normas agronómicas para maximizar la aptitud agronómica.
- III. Modelo de proceso biofísico el cual simula procesos biofísicos en los ecosistemas de agricultura. Como entradas del modelo se consideran parámetros meteorológicos como: topografía, tipos de suelo, características de los cultivos, administración de cultivos, emisiones de bióxido de carbono en la atmósfera, mínimos y máximos de temperatura, precipitación, radiación solar, porcentaje de humedad relativa y vientos. La salida del modelo muestra los niveles de rendimiento que se espera obtener en los cultivos.
- IV. Modelo para determinar márgenes de cosecha de los cultivos. El cálculo es mediante modelación matemática para definir la relación entre las variables: cultivo-prácticas agrícolas empleadas.
- V. Modelo de optimización de carpeta, con este modelo se busca optimizar estrategias de producción, gestión de recursos, prácticas agrícolas en los cultivos para minimizar los impactos generados por cambio climático.

## VI. Modelo de análisis de clúster para identificar la vulnerabilidad en diferentes regiones e la agricultura ante el cambio climático.

La obtención de los modelos para la minimización de impactos ante la vulnerabilidad en la agricultura, se detectaron áreas de mejora (fertilización, tipos de riego, etc.) para los sistemas agrícolas para aumentar su rentabilidad.

(Popke et al., 2016) desarrollan una serie de subsistemas importantes para aplicar medidas de adaptación agrícola en zonas del Caribe. La investigación aporta un sistema de evaluación del cambio climático; para cada subsistema le es asignada una ponderación con base en el impacto positivo o negativo ante cada problemática. Posteriormente realizaron un análisis en conjunto de las ponderaciones asignadas por cada subsistema para categorizar y priorizar las adversidades y con ello, es posible dar una solución factible en conjunto para la problemática en cuestión. Los autores implementaron el sistema de evaluación en un caso de estudio para la zona al suroeste de Jamaica; como resultado los agricultores se adecuaron a las condiciones climáticas gracias al uso de nuevas tecnologías agrícolas, aun considerando perturbaciones causadas por fenómenos meteorológicos. Como resultado la cosecha en la zona se ha mantenido firme y la economía agrícola sigue brindando oportunidades de subsistencia para muchos agricultores.

(López Guevara, 2015) realizaron estudios en dos comunidades afectadas por cambio climático apoyándose en la implementación de indicadores de vulnerabilidad para cuantificar cambios a través del tiempo, como resultado obtuvieron una herramienta metodológica de evaluación de impactos. El objetivo de la investigación es normalizar y estandarizar los indicadores para ser aplicados en comunidades aledañas con características similares (socioeconómicas, físicas y culturales) y establecer medidas de adaptación.

Los autores combinaron la herramienta desarrollada con un “Modelo de Evaluación de Impacto Ambiental (EIA)” y el “Marco para Medios de Vida Sostenibles (SLF)” para obtener un procesamiento lógico y eficiente para obtener una mejor comprensión entre los riesgos potenciales y las comunidades. De igual manera (Below et al., 2012; O’Brien et al., 2004; Wheeler, 2012) realizaron trabajos desarrollando metodologías mediante la implementación de indicadores de vulnerabilidad en regiones como la India y China para establecer el grado de afectación y cómo este disminuye la producción de los sistemas agrícolas.

Asimismo, se ha optado por el desarrollo de técnicas o tecnologías, entre ellas se encuentra la agricultura protegida (AP) que consiste en realizar las actividades bajo ciertas condiciones que van desde la implementación de estructuras que resguardan los cultivos de posibles riesgos mediante el control de parámetros como temperatura, humedad, vientos, agua, etc. (Moreno Reséndez et al., 2011). La implementación de técnicas como agricultura

protegida genera numerosas ventajas para los agricultores por ser un sistema de producción sustentable. En México, en los últimos veinte años la agricultura protegida ha adquirido mayor importancia principalmente en la exportación de hortalizas hacia países como Canadá y Estados Unidos (Bastida Tapia, 2017). Para el año 2017, datos arrojados en la Encuesta Nacional Agrícola (ENA) indican que cerca de 17,388 unidades de producción agrícola se realizan bajo condiciones de agricultura protegida (INEGI, 2018a).

Otra técnica empleada es la agricultura de precisión para el manejo y gestión del terreno agrícola a través de la detección de una “variabilidad espacial”. La agricultura de precisión se apoya en el uso de herramientas de procesamiento de imágenes como: Sistemas de Información Geográfica (GIS), Sistemas de Posicionamiento Global (GPS) y sensores satelitales, entre otros.

(de Carvalho-Pinto et al., 2007) implementaron tecnologías de posicionamiento global e imágenes satelitales para analizar sistemas agrícolas. El uso e implementación de estas técnicas permitió analizar al sistema de manera homogénea y detectar las zonas más vulnerables en donde se aplicaron acciones correctivas. Como resultado se logró una optimización del sistema de producción aumentando su competitividad mediante la disminución de costos. La agricultura de precisión resulta una herramienta para la mejor administración de recursos e información relacionada con los cultivos, siendo la vitivinicultura el sector en donde se han logrado óptimos resultados del empleo de agricultura de precisión.

(Bousquet and Le Page, 2004) realizaron un análisis del desarrollo de sistemas multi-agente para la administración de ecosistemas determinando que la mayor ventaja del Modelado Basado en Agentes ó ABM es que éstos permiten combinar la naturaleza espacial y la capacidad de representar redes. Dentro de las ventajas del uso de ABM's se encuentra: (i) capacidad de acoplar modelos sociales y medioambientales, (ii) capacidad de estudiar políticas de gestión ambiental y (iii) capacidad de modelar entidades y las interacciones entre sí. El principal reto de los ABM's es aportar nuevos conocimientos sobre los complejos sistemas naturales (Matthews et al., 2007). Los ABM's usualmente son empleados en la modelación del uso de tierras, cobertura de terreno y flujo de información por redes integradas por agentes a mayor o menor escala; en donde los agentes interactúan directamente para entrelazar cada eslabón dentro de la red (Kremmydas et al., 2018).

Los ABM's a son empleados para construir nuevos modelos adaptando diversos enfoques comprendiendo modelos microeconómicos y reglas empíricas (O'Sullivan et al., 2016; Schlüter et al., 2017). La implementación de ABM's integra componentes económicos, sociales y ecológicos (Jones et al., 2017); bajo este enfoque la presente investigación permite modelar variables de decisión que involucren dinamismo e

incertidumbre para determinar la vulnerabilidad y riesgo agrícola a través del uso de técnicas de inteligencia artificial para modelar variables de decisión.

### **3.3. Estudio de vulnerabilidad y riesgo agrícola a través de técnicas de procesamiento de imágenes**

(Fourcade, 2016) desarrollaron un modelo para predecir los cambios climáticos, para la elaboración del modelo los autores tomaron como base modelos de distribución de clases de clima (SDM por sus siglas en inglés) los cuales son alimentados por sistemas de información sobre la biodiversidad del clima presente en un área determinada, sin embargo; los datos presentan altos sesgos; razón por la cual, es necesario recurrir a fuentes alternativas de información para reducir el nivel de sesgo. Una alternativa es emplear mapas de distribución de clases de clima proporcionados por la “Unión Internacional para la conservación de la Naturaleza (UICN)” para realizar predicciones a cerca del clima actual y a futuro. El modelo fue desarrollado con base al conocimiento del experto en donde se definieron seis categorías para describir la diversidad climática basándose en los factores de impacto: “temperatura y precipitación” para minimizar el riesgo de sesgo durante el modelado. Las categorías son: temperatura media anual, temperatura máxima, temperatura mínima, precipitación anual, precipitación del mes más húmedo y precipitación del mes más seco.

A través del uso de Sistemas de información Geográfica (GIS) y Sistemas de Análisis Satelitales es posible la obtención de bases de datos geo-espaciales; los cuales tienen aplicaciones en sectores como la agricultura y administración de recursos naturales.

(Vázquez et al., 2015) proponen sistema de datos geo-espacial por una metodología llamada “GeoBase-L9”. El objetivo del estudio es facilitar el almacenaje e intercambio de información geográfica. Los modelos se alimentan de recursos de información.

La modelación de los recursos de información sirve como guía para implementar y mantener acciones de mejora en el sistema estudiado. La “GeoBase-L9” se encuentra en el estado de Hidalgo y está integrada por imágenes vectoriales-raster. Las imágenes están conformadas por metadatos de información para localizar información requerida por el usuario con base a la cuenca, tipo de formato, clasificación, entre otros.

(Espínola et al., 2016) Presentan un estudio de modelización y la simulación de los fenómenos climatológicos de la precipitación, evaporación de agua y flujo de aguas subterráneas en 3D obtenidas mediante imágenes satélites (RACA). El propósito de RACA es estimar el abastecimiento de agua en una población a futuro, establecer futuros proyectos

de construcción y planeamiento urbano alejado de lugares con alta probabilidad de inundaciones.

Las imágenes satelitales son proporcionadas por la NASA y por estudios de teledetección. El principal fenómeno meteorológico de estudio son las precipitaciones, al ser su modelización virtual es un elemento clave para estimar diversos cambios ambientales, por ejemplo la formación de nuevos ríos o proceso de erosión del suelo.

El fenómeno de la lluvia ha sido investigado desde diversas perspectivas científicas mediante diversos métodos. La simulación matemática de precipitación es un proceso bastante complejo con muchas variables a considerar.

El alcance de la investigación tiene cuatro puntos principales, los cuales son:

1. Análisis de la evolución climática en una región geográfica particular.
2. Estimación de futuro suministro de agua de una población.
3. La proyección futura de construcción y planificación urbana.
4. Prevención de desastres naturales en zonas urbanas con un índice alto de inundaciones.

La investigación simplifica el proceso de simulación, ha proporcionado datos numéricos y 3D para ver resultados rápidos en el último nivel de agua. Además, RACA permite realizar un trabajo de campo previo en el área a estudiar para obtener mejores resultados, añadiendo la gasificación del agua y el flujo de las aguas subterráneas para la simulación.

(Maguire, 2013) Presenta un sistema para supervisar y registrar los datos de los indicadores del cambio climático teniendo como base observaciones satelitales de hielo en zonas del norte de Europa y el Ártico. También incorpora datos de proyección de lluvias, temperatura y velocidad media del viento de Europa. La información obtenida es denominada “SIG” (Sistemas de Información Geográfica).

Para dar robustez a la investigación, los autores emplearon vigilancia satelital de indicadores climáticos, obteniéndose resultados realizados por EuroClim (“Proyecto Europeo sobre el Cambio Climático y la Vigilancia del Sistema de Predicción”). La parte metodológica consta de la incorporación de necesidades del “usuario” para diseñar el sistema. En los resultados obtenidos, el sistema de monitoreo del cambio climático EuroClim ha identificado estrategias para la comunicación efectiva de la información proporcionada por imágenes climáticas, por lo cual el proyecto ha sido aplicado a un caso de estudio para evaluar cómo los métodos ergonómicos pueden ser adaptados para una aplicación particular, demostrando cómo la detección temprana a través de imágenes satelitales en una comunidad ayuda a disminuir los impactos negativos.

La Agricultura Urbana (AU) es una forma de agricultura que produce, elabora y comercializa alimentos vegetales y animales procedentes de productos farmacéuticos, fibras y combustible, en las zonas urbanas y periurbanas. La AU es un medio para obtener ingresos adicionales para familias de medianos ingresos, además es una herramienta sustentable para producir alimentos en hogares de altos ingresos. AU no sólo se relaciona con los conceptos de la seguridad alimentaria, sino también con interacciones sociales y educación ambiental para enfrentar futuros cambios climáticos para contribuir a aminorar la degradación ambiental, mejorar ecosistemas, salud y bienestar de los habitantes. (Pulighe and Lupia, 2016) Proponen una metodología o algoritmo para descubrir polígonos de cultivo en la zona urbana en Roma a través de la fotointerpretación de las imágenes disponibles de Google Earth, combinado con información adicional derivada de fuentes auxiliares. El uso de Google Earth permite obtener múltiples fotografías en “tiempo real” para analizar el patrón espacial del fenómeno de estudio para el período 2007-2013 permitiendo crear sistemas de información espacial de la agricultura urbana para distinguir las distintas tipologías existentes en el área.

Los sistemas de información de AU son empleados para analizar las distintas actividades agrícolas para analizar la extensión y localización de los cultivos urbanos informales para promulgar políticas adecuadas para evitar cualquier riesgo potencial. El estudio de los sistemas urbanos contempla aspectos relacionados con seguridad alimentaria, sociología y agro-biodiversidad.

En las Tabla 4 y Tabla 5 se muestra un concentrado de las principales aportaciones de cada investigación para evaluar la vulnerabilidad por cambio climático a través de diversas metodologías incluyendo investigaciones apoyadas por tratamiento de imágenes.

Tabla 4 Principales aportaciones del estudio de vulnerabilidad ante el cambio climático.

Artículo	Autor(es)	Aportación
Vulnerability matrix of the food system: Operationalizing vulnerability and addressing food security. (2016)	Palovita, A., Kortetm una Ki, T., Puupponen, A. & Silvasti, T.	Matriz cualitativa de vulnerabilidad del sistema alimentario en Finlandia.
An open platform to assess vulnerabilities to climate change: An application to agricultural systems. (2015)	Eza, U. y otros	Plataforma alimentada por modelos basados en sistemas de información y en lógica difusa para caracterizar y analizar la vulnerabilidad climática en la región de Auvernia, Francia.
Spatial modeling of robust crop production portfolios to assess agricultural vulnerability and adaptation to climate change. (2015)	Mitter, H., Heumesser, c. & Schmid, E.	<ul style="list-style-type: none"> <li>– Sistema de evaluación de la vulnerabilidad en un sistema agrícola que combina aspectos biofísicos y socioeconómicos para el oeste de Austria.</li> <li>– Modelos que minimicen la vulnerabilidad en la agricultura ante el cambio climático.</li> </ul>
A social justice framing of climate change discourse and policy: Adaptation, resilience and vulnerability in a Jamaican agricultural landscape. (2016)	Popke, J., Curtis, D. S. & Gamble, D. W.	Sistema de evaluación del cambio climático con perspectiva de justicia social.
Análisis de riesgos climáticos sobre los componentes, recursos y medios de vida de los sistemas alimentarios del departamento de Copán en el año 2014 (Honduras).	López Guevara	Herramienta metodológica adaptada a las características socioeconómicas, biofísicas y culturales para la evaluación de los riesgos de los sistemas alimentarios de las comunidades ante las amenazas climáticas y su capacidad de adaptación
Characteristics of protected agriculture and their environment in Mexico.	Moreno Reséndez, et al.	Implementación de la agricultura protegida (AP) es un sistema de producción realizado bajo diversas estructuras, para proteger cultivos, al minimizar las restricciones y efectos que imponen los fenómenos climáticos.
Precision agriculture: New Tools to Improve Technology Management in Agricultural Enterprises.	Carvalho-Pintoi, et al.	Tecnologías de agricultura de precisión, así como información sobre sus aplicaciones en distintas áreas, con la visión de promover sus usos, fomentar su análisis y entendimiento, y explicar sus beneficios, complejidades y limitaciones.

Continuación Tabla 4 Principales aportaciones del estudio de vulnerabilidad ante el cambio climático.

Artículo	Autor(es)	Aportación
Can farmers adaptation to climate change be explained by socio-economic household-level variables.	Below, et al.	Un índice de adaptación basado en la actividad analizando la relación entre las variables socioeconómicas y el comportamiento de adaptación de los agricultores mediante un análisis de factores explicativos y un modelo de regresión lineal múltiple utilizando variables latentes.
Mapping vulnerability to multiple stressors: climate change and globalization in India.	O'Brien, et al.	Desarrollaron una metodología para estudiar la vulnerabilidad regional ante el cambio climático en la India.
Quantifying Vulnerability to Climate Change: Implications for Adaptation Assistance.	Wheeler	Estudio de V y CC para 233 estados en China. Utilizando las pruebas más recientes, desarrolla indicadores de riesgo para tres problemas críticos: el aumento de los desastres relacionados con el clima, el aumento del nivel del mar y la pérdida de productividad agrícola.
<ul style="list-style-type: none"> <li>- Multi-agent simulations and ecosystem management: A review.</li> <li>- Agent-based land-use models: A review of applications.</li> <li>- A review of Agent Based Modeling for agricultural policy evaluation.</li> <li>- Strategic directions for agent-based modeling: avoiding the YAAWN syndrome.</li> <li>- A framework for mapping and comparing behavioral theories in models of social-ecological systems.</li> <li>- Toward a new generation of agricultural system data, models, and knowledge products: State of agricultural systems science.</li> </ul>	<ul style="list-style-type: none"> <li>- Matthews , et al.</li> <li>- Kremmydas, et al.</li> <li>- Ó'Sullivan, et al.</li> <li>- Schlüter, et al.</li> <li>- Jones, et al.</li> </ul>	<p>Desarrollo y/o análisis de modelos basados en agentes (ABM's) para la gestión de ecosistemas.</p> <p>Los ABM's a son empleados para construir nuevos modelos adaptando diversos enfoques comprendiendo modelos microeconómicos y reglas empíricas, mediante integración de componentes económicos, sociales y ecológicos.</p>

Tabla 5 Principales aportaciones del estudio de vulnerabilidad ante el cambio climático (Uso de tratamiento de imágenes).

Artículo	Autor(es)	Aportación
Comparing species distributions modeled from occurrence data and from expert-based range maps.	Fourcade	Modelo para predecir los cambios climáticos a través de bases de datos y mapas de distribución de las clases de clima.
Enfoque metodológico para la construcción de una Geobase como apoyo a la investigación en agricultura y recursos naturales.	Camacho Vázquez, et al.	Herramienta para el almacenamiento de recursos de información (RI) o ítems geográficos, orientados específicamente hacia la investigación en agricultura y recursos naturales.
Simulating rainfall, water evaporation and groundwater flow in three-dimensional satellite images with cellular automata	Espínola, et al.	Modelización y la simulación de los fenómenos climatológicos de la precipitación, la evaporación del agua y el flujo de las aguas subterráneas en 3D a través de la obtención de imágenes satelitales.
An analysis of specialist and non-specialist user requirements for geographic climate change information.	Maguire	Sistema para supervisar y registrar los datos de los indicadores del cambio climático teniendo como base observaciones satelitales en el norte de Europa y el Ártico.
Mapping spatial patterns of urban agriculture in Rome (Italy) using Google Earth and web-mapping services	Pulighe & Lupia	Metodología para descubrir polígonos de cultivo en la zona urbana de Roma a través de la fotointerpretación de las imágenes disponibles de Google Earth.

## Capítulo 4. Metodología

La metodología propuesta permite estimar la vulnerabilidad y riesgo para generar escenarios de impactos por cambio climático específicamente al sector agrícola. El análisis de las causas de desastres permite identificar los factores vulnerables para desarrollar acciones de adaptación.

La metodología propuesta se muestra en la Figura 19.

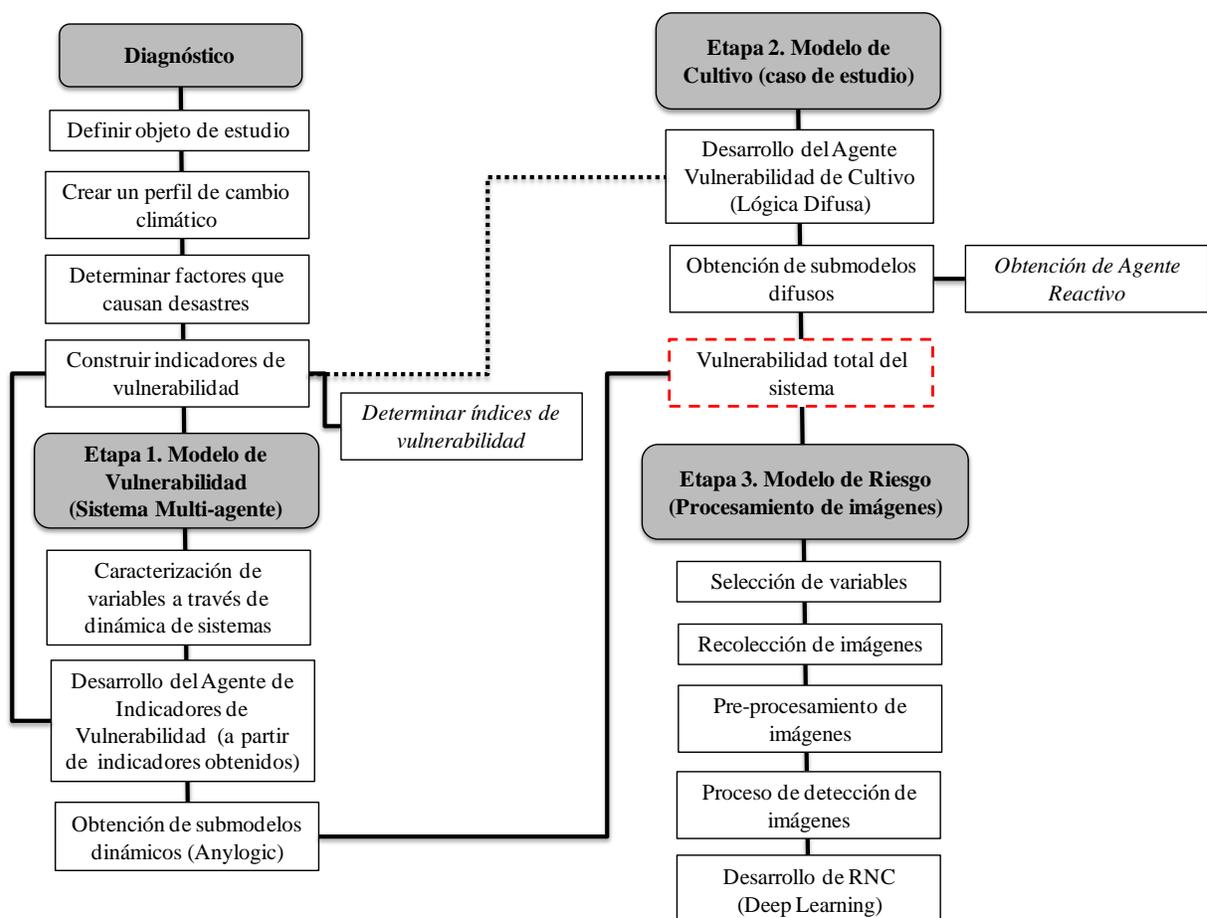


Figura 19 Metodología general

La metodología consta de una primera fase de diagnóstico que ayudará a crear un perfil de cambio climático para caracterizar los principales factores que causan desastres y determinar indicadores de vulnerabilidad en términos de sensibilidad, exposición y capacidad adaptativa.

En la etapa 1 se construye un modelo de vulnerabilidad basado en un sistema multi-agentes a través de técnicas de inteligencia artificial (dinámica de sistemas y agentes inteligentes). La etapa 2 desarrolla el modelo de cultivo del caso de estudio (caña de azúcar) mediante la obtención del “Agente de Vulnerabilidad de Cultivo” con el desarrollo de submodelos de lógica difusa.

Los resultados de la etapa 1 y 2 permitirán estimar la vulnerabilidad total del sistema, posteriormente con la obtención de las variables de impacto se desarrolla el modelo de riesgo agrícola (etapa 3) a través de técnicas de IA como el procesamiento de imágenes y redes neuronales convolucionales (CNN's).

#### **4.1. Diagnóstico**

Con base a la metodología, con el diagnóstico se delimita objeto de estudio en la investigación, se crea un perfil de cambio climático que permita detectar los principales factores que causan desastres ocasionando un aumento en la vulnerabilidad en la agricultura.

Dentro de la presente investigación se pretende estimar la vulnerabilidad y riesgo que tiene el sector agrícola en México ocasionado por cambio climático. Las actividades que conforman la etapa de diagnóstico son las siguientes:

- i. Definir el objeto de estudio. Se delimita el objeto de estudio (región, grupo social, o sector económico); en este caso, para propósitos de la investigación se evalúa la vulnerabilidad y riesgo del cultivo de caña de azúcar producido en Lerdo de Tejada, Veracruz. 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.
- ii. Crear un perfil de cambio climático. Un perfil de cambio climático permite determinar los factores climatológicos que potencializan el riesgo y que han causado impactos negativos. La obtención de documentación y/o conjuntos de datos puede emplearse para resumir el perfil y establecer proyecciones de impactos ambientales, impactos socioeconómicos esperados, riesgos históricos de desastre, la población y los sectores vulnerables primarios, y medidas de adaptación potenciales. El desarrollo de los puntos i y ii, se presentan a detalle en la sección 5.1.
- iii. Determinar factores que causan desastres. La obtención y cuantificación de los factores que causan inestabilidad en el sistema es vital para determinar el grado de

vulnerabilidad presente. Estos factores pueden medirse a través de indicadores de vulnerabilidad. Generalmente los incrementos de vulnerabilidad están relacionados con pérdida de tierras fértiles, pérdida de diversidad de cultivos y aspectos relacionados con apoyos al campo.

- iv. Construir indicadores de vulnerabilidad. Con los sistemas de información se construyen indicadores de vulnerabilidad normalizados. Los indicadores de vulnerabilidad representan factores físicos, sociales y económicos los cuales son ponderados mediante criterios (experts) para la gestión de riesgo. Para la obtención de indicadores, se analiza información histórica existente (5 a 20 años) para evaluar el comportamiento dinámico de la vulnerabilidad y estipula establecer si va en tendencia ascendente o descendente para determinar la magnitud de los posibles impactos.
- v. Obtener un índice de vulnerabilidad. El índice de vulnerabilidad es obtenido a partir de los indicadores. El índice de vulnerabilidad representa la ponderación o “peso” del indicador con respecto a su influencia en el sistema. Cuando se realiza una proyección de indicadores de vulnerabilidad, los “pesos” asignados pueden cambiar a través del tiempo para satisfacer las acciones de adaptación.

#### **4.1.1. Determinación de factores que causan desastres**

En México, fenómenos meteorológicos como La Niña y El Niño han causado cambios significativos en los patrones de comportamiento en las precipitaciones; lo cual ha originado el incremento de eventos como sequías, huracanes, inundaciones, deslaves, ocasionando un aumento en la pérdida de cultivos poniendo en riesgo las cosechas.

Por su parte, también se han observado cambios significativos en los niveles de temperatura, ocasionando el aumento de ondas de calor ocasionando daños en los cultivos a nivel de planta y fruto. Cuando ciertos cultivos están expuestos a temperaturas altas, el follaje de la planta se ve comprometido por la pérdida de agua y nutrientes derivado de la radiación solar.

La presencia de temperaturas muy bajas, repercuten drásticamente al cultivo ya sea en su totalidad o a nivel de tejido de la planta ocasionando pérdidas en los rendimientos de cultivo.

#### **4.1.2. Caracterización de factores (bases de datos)**

Con base al IPCC, metodologías previamente desarrolladas (Magaña, 2012; Monterroso et al., 2013) y la metodología propuesta en la presente investigación, se establecieron tres clasificaciones para los indicadores de vulnerabilidad:

1. Indicadores por exposición
2. Indicadores de sensibilidad
3. Indicadores de capacidad adaptativa

La importancia de los indicadores de vulnerabilidad, radica en que éstos permiten estimar los efectos adversos producidos por cambio climático y la forma en que éstos repercuten en el rendimiento de cultivos y en la administración de recursos en las actividades agrícolas. La construcción de indicadores de vulnerabilidad se realizó a partir de sistemas de información abierta de organismos gubernamentales nacionales e internacionales. La Tabla 6 muestra la clasificación de los organismos consultados.

Tabla 6 Organismos consultados para la recolección de información

<b>Nacionales</b>	<b>Internacionales</b>
<ul style="list-style-type: none"> <li>- Instituto Nacional de Estadística y Geografía (INEGI)</li> <li>- Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT)</li> <li>- Comisión Nacional del Agua (CONAGUA)</li> <li>- Servicio de Información Agroalimentaria y Pesquera (SIAP)</li> <li>- Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación (SAGARPA)</li> <li>- Instituto Nacional de Ecología y Cambio Climático (INECC)</li> <li>- Instituto Mexicano de Tecnología del Agua (IMTA)</li> <li>- Consejo Nacional de Población (CONAPO)</li> <li>- Centro de Análisis para la Investigación e Innovación (CAIINNO)</li> <li>- Encuesta Nacional Agrícola 2012 y 2014 (ENA)</li> <li>- Servicio Meteorológico Nacional (SMN)</li> <li>- Atlas Nacional de Riesgos</li> <li>- Fideicomiso Fondo de Desastres Naturales (FONDEN)</li> <li>- Centro Nacional para la Prevención de Desastres (CENAPRED)</li> <li>- Comisión Nacional Forestal (CONAFOR)</li> <li>- Instituto Nacional de Ecología (INE)</li> <li>- Servicio Sismológico Nacional (SSN)</li> <li>- Sistema de Información Agroalimentaria de Consulta (SIACON)</li> <li>- Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL)</li> <li>- Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP)</li> <li>- Programa de Apoyos Directos al Campo (PROCAMPO)</li> </ul>	<ul style="list-style-type: none"> <li>- Banco Mundial de Datos (The World Bank)</li> <li>- CLImate COMputing project (CLICOM)</li> <li>- Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO)</li> </ul>

A partir de indicadores ya establecidos por el “Banco Mundial de Datos” y el “Sistema Nacional de Indicadores Ambientales”; así como de información obtenida en fuentes citadas anteriormente, se obtuvieron indicadores de exposición, sensibilidad y capacidad adaptativa.

### **4.1.3. Clasificación de indicadores de vulnerabilidad. Definición de variables**

Los indicadores de vulnerabilidad se clasificaron en tres grupos: exposición, sensibilidad y capacidad adaptativa. A continuación se describen las variables (definición, periodo, relación con vulnerabilidad, fuente de obtención) de cada conjunto de indicadores.

#### **VARIABLES DE INDICADORES DE EXPOSICIÓN**

Las variables para los indicadores de exposición obtenidas fueron 12. Las variables “Temperatura (°C)” y “Precipitación (mm)” fueron obtenidas mediante datos observados anualmente. Las variables “Sequía”, “Inundación”, “Sismo”, “Ciclón Tropical”, “Heladas-Granizadas”, “Frente Frío”, “Tormentas Severas” e “Incendios Forestales” se miden en el número de eventos declarados como estado de emergencia y/o desastre natural. Para la variable “Sismo” se consideraron movimientos telúricos por encima de los 6.9° Richter al considerarse que sismos de esta magnitud son capaces de ocasionar degradación del suelo.

Para la corroboración de desastres naturales, el INIFAP ha sido declarado por SAGARPA como autoridad técnica competente para el dictamen de ocurrencia de desastre natural. Mediante los datos registrados y la interpretación agronómica de la afectación ocurrida por algún evento meteorológico extremo, el INIFAP emite los dictámenes de corroboración de desastres naturales como: ciclón, granizada, inundación significativa, lluvia torrencial, helada, granizada, huracán, deslave y sequía atípica.

La variable “Superficie afectada por incendios forestales” indica el número de hectáreas en donde hubo pérdidas totales y/o parciales de cultivos por incendios forestales. La variable “GEI” esta expresada en porcentaje de GEI emitido en la atmósfera anualmente.

En la Tabla 7 se muestra la descripción y características para cada indicador por exposición, tales como periodo de consulta, relación ante la vulnerabilidad y fuente de información.

Tabla 7 Indicadores de Exposición

	<b>Indicador</b>	<b>Descripción</b>	<b>Periodo</b>	<b>Relación ante Vulnerabilidad</b>	<b>Fuente</b>
1	Temperatura	Temperatura histórica en México, en °C	1991-2017	Temp ↑ → Vul ↑	The World Bank
2	Precipitación	Precipitación histórica en México, en mm	2000-2017	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	Inundación	Eventos con declaratoria de "Riesgo y/o Desastre" por inundación	2000-2016	Inund ↑ → Vul ↑	CENAPRED, INIFAP
5	Sismo	Eventos con declaración de "Riesgo y/o Desastre" por sismos mayores a 6.9° Richter	2000-2016	Sismo ↑ → Vul ↑	CENAPRED, SSN
6	Ciclón tropical	Eventos con declaración de "Emergencia, Riesgo y/o Desastre"	2000-2016	CicTrp ↑ → Vul ↑	CENAPRED, SMN, CLICOM
7	Heladas / Granizadas	Eventos con declaración de "Emergencia"	2000-2016	HelGr ↑ → Vul ↑	CENAPRED, INIFAP
8	Frente frío	Eventos con declaración de "Emergencia"	2000-2016	FFrío ↑ → Vul ↑	CENAPRED, SMN
9	Tormentas severas	Eventos con declaración de "Emergencia"	2000-2016	TormSev ↑ → Vul ↑	CENAPRED, SMN, CLICOM
10	Incendios forestales	Número de incendios forestales	1991-2018	IncFor ↑ → Vul ↑	CONAFOR
11	Superficie afectada por incendios forestales	Superficie agrícola afectada por incendios forestales, en Ha	1991-2018	Sup.IncFor ↑ → Vul ↑	CONAFOR
12	Emisiones GEI	Inventario Nacional de Gases y Compuestos de Efecto Invernadero en agricultura, silvicultura y otros usos de la tierra, en porcentaje.	1990-2015	GEI ↑ → Vul ↑	The World Bank, INECC

## VARIABLES DE INDICADORES DE SENSIBILIDAD

Las variables “Población rural” y “Población urbana”, con base a la definición de los organismos nacionales de estadística, se define como *“Personas que viven en áreas rurales o urbanas según lo definen las oficinas nacionales de estadística. Se calcula utilizando las estimaciones de población del Banco Mundial y las proporciones rurales/urbanas de las Perspectivas de Urbanización Mundial de las Naciones Unidas. La agregación de la población urbana y rural puede no sumar a la población total debido a las diferentes coberturas de los países”* (INEGI, 2017).

La variable “Área agrícola disponible” se refiere a la proporción de superficie de tierra cultivable, de cultivos permanentes y de pastos permanentes. Las tierras arables incluyen tierras clasificadas como tierras de cultivo temporal, praderas temporales para cortar el césped o para pastos, tierras con huertas comerciales o huertas y tierras temporalmente en barbecho (se excluyen aquellas tierras de uso migratorio; es decir, que han sido abandonadas). Las “Tierras de cultivo permanente” son aquellas que se emplean durante un largo periodo en donde no forzosamente deben ser sembrados al termino de cada cosecha (incluye: árboles frutales, nogales y enredaderas, pero excluye terrenos bajo árboles cultivados para madera o madera)

El “Rendimiento de cereales” engloba información a cerca de producción de cereales de grano seco (arroz, cebada, maíz, trigo, sorgo, etc.) medida en kilogramo por hectárea cosechada, tomando en cuenta los datos obtenidos al final del año inmediato anterior.

Las variables “Temperatura media mensual (°C)” y “Precipitación media mensual (mm)” representan datos obtenidos en promedio medio mensual a nivel nacional. La “Evapotranspiración” es la evaporación y/o transpiración de agua que es regresada hacia la atmósfera por parte de las plantas. Se estima que de la precipitación pluvial cerca del 72.8% es regresado a la atmósfera, cerca del 21% se drena hacia ríos y el 6% es infiltrado dirigiéndose a los acuíferos.

La variable “Valor de la producción” está expresado en miles de pesos y corresponde a la relación entre la superficie cosechada y la superficie sembrada, incluyendo pérdidas. Las variables “Insecticidas” y “Plaguicidas” indican el total de toneladas producidas y empleadas. La “Eficiencia del agua en el sector agrícola” está expresada por cada Kg/m<sup>3</sup> de agua.

La variable “Disponibilidad de agua en la agricultura” es el volumen concesionado para consumo agrupado en hectómetros cúbicos (hm<sup>3</sup>); el cual incluye las regiones de abastecimiento: Península de Baja California y Yucatán, Noreste, Pacífico Norte y Sur, Balsas, Río Bravo, Cuencas Centrales del Norte, Lema-Santiago-Pacífico, Golfo Norte y

Centro, Frontera Sur y Aguas del Valle de México. De las cuales son destinadas para el sector agropecuario (76%), sector público (14.4%), sector industrial y servicios (4.9%) y energía eléctrica (4.7%) (CONAGUA, 2018).

La “Superficie agrícola (Riego-Temporal)” indica la extensión de tierras dependiendo el tipo de riego empleado para el crecimiento de cultivos: si emplea un sistema de riego o si depende de las precipitaciones. La variable “Origen de agua” se refiere a la naturaleza del agua empleada para riego ya sea bordo, pozo profundo, pozo a cielo abierto, río, manantial o presa. La variable “Sistema de irrigación” abarca riego por gravedad, canales recubiertos o revestidos, tubería de compuerta, microaspersión, aspersión o goteo. La variable “Tipo de agua” se refiere a agua utilizada para riego de cultivos ya sea agua negra, tratada, blanca o salobre. La variable “Principales problemas” se refiere a los problemas en las actividades agrícolas, ya que el 96% de las unidades de producción presentan una o más dificultades para su desarrollo, los cuales pueden ser: acceso al crédito, disminución de la productividad del suelo, pérdida de cosecha por condiciones medioambientales, plagas y/o enfermedades, dificultad para la comercialización, falta de organización para la producción, infraestructura insuficiente, poca capacitación, altos costos de servicios, litigio o invasión de tierra, falta de apoyos, vejez o enfermedad del productor, entre otros. Las variables “Superficie Sembrada y Cosechada” se expresan en hectáreas para cada cultivo. La Tabla 8 muestra la descripción y características para cada indicador por sensibilidad.

Tabla 8 Indicadores de Sensibilidad

	<b>Indicador</b>	<b>Descripción</b>	<b>Periodo</b>	<b>Relación ante Vulnerabilidad</b>	<b>Fuente</b>
1	Población rural	Número de habitantes de población rural en México	1960-2017	PRural ↑ → Vul ↑	CONAPO, INEGI, The World Bank
2	Población urbana	Número de habitantes de población urbana en México	1960-2017	PRural ↓ → Vul ↓	CONAPO, INEGI, The World Bank
3	Área agrícola	Tierra agrícola cultivable que incluye cultivos y pastos, en porcentaje	1961-2015	AreAgr ↑ → Vul ↓	The World Bank, SAGARPA
4	Rendimiento de cereales	Rendimiento de producción de cultivos cosechados (granos secos), en Kg/Ha	1961-2016	RendCer ↑ → Vul ↓	The World Bank, FAO
5	Precipitación media mensual	Temperatura media en México, en °C	1991-2015	Ppmed ↑ → Vul ↑	The World Bank, SMN
6	Temperatura media mensual	Precipitación media en México, en mm	1991-2015	Tmed ↑ → Vul ↑	The World Bank, SMN
7	Evapotranspiración	Evapotranspiración media anual, en km <sub>3</sub> /año	1998-2015	EvT ↑ → Vul ↑	CONAGUA, SEMARNAT
8	Valor de la producción	Valor de la producción agrícola, en miles de pesos	1980-2016	ValorProd ↑ → Vul ↓	SAGARPA, SIACON, SIAP
9	Insecticidas/Plaguicidas (2)	Uso de insecticidas y/o plaguicidas, en Ton	1994-2009	Insecticidas ↑ → Vul ↓ Plaguicidas ↑ → Vul ↓	INEGI, ENA
10	Eficiencia del agua en el sector agrícola	Eficiencia en el uso del agua en el sector agrícola de riego, en kg/m <sup>3</sup>	1994-2016	EfcAgua ↑ → Vul ↓	CONAGUA, SEMARNAT
11	Disponibilidad de agua en agricultura	Volumen concesionado por uso consuntivo agrupado, en hm <sup>3</sup>	2001-2016	H <sub>2</sub> OAgr ↑ → Vul ↓	CONAGUA, SAGARPA
12	Superficie agrícola (Riego y/o Temporal)	Superficie agrícola con disponibilidad de agua para reproducción de sus cultivos (riego y/o temporal), en Ha	2007-2014	Riego_Temporal ↑ → Vul ↓	INEGI, ENA, SEMARNAT
13	Origen de agua	Superficie agrícola de riego según el origen de agua, en porcentaje	2007-2014	OrigenH <sub>2</sub> O ↑ → Vul ↓	INEGI, ENA, SEMARNAT
14	Sistemas de irrigación	Producción con superficie agrícola de riego y tipo de canales por sistema de irrigación utilizado, en porcentaje	2007-2014	Irrigación ↑ → Vul ↓	INEGI, ENA, SEMARNAT
15	Tipo de agua	Tipo de agua utilizada en agricultura (negra, tratada, blanca, salobre), en porcentaje	2007-2014	Tipoh <sub>2</sub> O ↑ → Vul ↓	INEGI, ENA
16	Principales problemas	Unidades de producción según principales problemas presentados en el desarrollo de las actividades agropecuarias, en porcentaje	2007-2014	Problemas ↑ → Vul ↑	INEGI, ENA
17	Superficie Sembrada/Cosechada (2)	Superficie agrícola sembrada y cosechada, en Ha	1980-2016	SupSembrada ↑ → Vul ↓ SupCosechada ↑ → Vul ↓	SAGARPA, SIACON, SIAP

## **Variables de indicadores de capacidad adaptativa**

La variable “Marginación” se refiere a la población con viviendas precarias, con base al Instituto Nacional de Estadística y Geografía, se define como: *“aquellas que carecen de al menos una de las siguientes características: acceso a fuentes de agua mejoradas, drenaje y saneamiento, materiales de construcción apropiados y espacio suficiente para vivir”* (INEGI, 2018b).

La variable “Nivel de estudios” se refiere al nivel del estudios del productor: ninguno, primaria, secundaria, preparatoria o profesional. La “Edad del productor” está definida en años. Las variables “Empleos en la agricultura” y “Sexo del productor” es la cantidad de empleos que actualmente son destinados a la agricultura así como al género del productor, respectivamente.

La variable “Vulnerabilidad del productor” implica las condiciones que afectan al productor, tales como pobreza, pobreza extrema, vulnerabilidad por carencias sociales y vulnerabilidad por ingresos. El “Crédito” se refiere al crédito otorgado hacia agricultores ya sea por la banca comercial o por la banca en desarrollo. El “Valor agregado a la agricultura” indica el porcentaje de la agricultura que favorece al Producto Interno Bruto (PIB). La variable “Solicitud de seguro” se refiere a si se obtuvo o no algún tipo de seguro para desempeñar actividades agrícolas; la variable “Origen del seguro” permite saber si el seguro fue otorgado por institución de gobierno, fondo de aseguramiento o aseguradora privada.

La variable “Tipo de tracción” muestra la superficie agrícola en hectáreas que tienen algún tipo de tracción (mecanizada o no mecanizada) utilizada para las actividades agrícolas.

Las variables “Índice de productividad”, “Índice de producción de alimentos” e “Índice de cosecha” son índices que miden PIB obtenido por hora trabajada, producción de alimentos y producción agrícola de cada año, respectivamente.

Las variables “Tierras agrícolas”, “Tierras cultivables” y “Tierras para la producción de cereales” se refieren a la superficie (Ha) destinada para cada rubro. La variable “Consumo de fertilizantes” es la utilización en kg/Ha de fertilizantes por tierras cultivables, los fertilizantes pueden ser: Nitrogenados (sulfato de amonio, nitrato de amonio, urea), Fosfatados (superfosfatos, sulfato triple) y Complejos (sulfato de amonio-nitrogenados-fosfatados). En la Tabla 9 se muestran los indicadores de capacidad adaptativa.

Tabla 9 Indicadores de Capacidad Adaptativa

	<b>Indicador</b>	<b>Descripción</b>	<b>Periodo</b>	<b>Relación ante Vulnerabilidad</b>	<b>Fuente</b>
1	Marginación	Población que vive en condiciones de marginación, en porcentaje	1992-2014	Marginación ↑ → Vul ↑	INEGI, CONAPO
2	Nivel de estudio	Nivel de estudios del productor, en porcentaje	2007-2014	NivEstudios ↑ → Vul ↑	INEGI, CONAPO, ENA
3	Edad	Edad del productor agrícola, en años	2007-2014	Edad ↑ → Vul ↑	ENA, INEGI
4	Total de empleos en la agricultura	Total de empleos en el sector agrícola, en porcentaje	1991-2017	Empleos ↑ → Vul ↓	The World Bank, CONAPO, INEGI
5	Sexo del Productor	Hombres y/o mujeres que ejercen la agricultura, en porcentaje	1991-2018	H/M ↑ → Vul ↓	The World Bank, INEGI
6	Vulnerabilidad de productores	Condiciones de vulnerabilidad de productores, en porcentaje	2010-2014	VulProductor ↑ → Vul ↑	CONEVAL, INEGI, ENA
7	Crédito a la producción	Crédito otorgado a la producción	2003-2016	Crédito ↑ → Vul ↓	BANXICO, INEGI, ENA
8	Valor agregado a la agricultura	Producción neta del sector agrícola, en porcentaje al PIB	1965-2017	ValorAgr ↑ → Vul ↓	The Bank World
9	Solicitud de seguro	Solicitud de seguro para actividades agropecuarias, en porcentaje	2007-2014	Seguro ↑ → Vul ↓	ENA, INEGI
10	Origen de seguro	Contratación de seguro para actividades agropecuarias según el origen, en porcentaje	2007-2015	OrigenSeg ↑ → Vul ↓	ENA, INEGI
11	Tipo de tracción	Tipo de tracción utilizada para actividades agrícolas, en porcentaje	2007-2014	Tracción ↑ → Vul ↓	INEGI
12	Apoyo al campo	Programa de apoyos otorgados al campo (superficie apoyada), millones de Ha.	2000-2013	SupApoyada ↑ → Vul ↓	PROCAMPO, INEGI
13	Productividad laboral	PIB obtenido por hora trabajada	2005-2016	PLaboral ↑ → Vul ↓	INEGI
14	Índice de producción de alimentos	Índice de producción de alimentos que se consideran comestibles	1961-2016	IPA ↑ → Vul ↓	The World Bank
15	Índice de cosecha	Indica la producción agrícola de cada año	1990-2016	ICosecha ↑ → Vul ↓	The World Bank
16	Tierras agrícolas	Extensión de tierras destinadas a la agricultura, en porcentaje	1961-2015	TierAgr ↑ → Vul ↓	The World Bank
17	Tierras cultivables	Extensión de tierras aptas para cultivo, en porcentaje	1961-2015	TCultivable ↑ → Vul ↓	The World Bank
18	Tierra para producción de cereales	Extensión de tierras destinadas al cultivo de manera permanente, en Ha	1961-2016	TCereal ↑ → Vul ↓	The World Bank
19	Consumo de fertilizantes	Consumo de fertilizantes en el sector agrícola, en Kg/Ha	2002-2015	UsoFertiliz ↑ → Vul ↓	The World Bank, ENA

#### 4.1.4. Construcción de indicadores de vulnerabilidad y obtención de índice de vulnerabilidad

Teniendo la clasificación de los factores de vulnerabilidad, se construyeron los indicadores normalizados para posteriormente obtener el índice de vulnerabilidad. Los indicadores fueron normalizados en el rango [0, 1] para ser estandarizados, en donde “a mayor valor del indicador mayor es la vulnerabilidad”. La normalización se obtuvo mediante la siguiente ecuación:

Ecuación 6

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

Donde,

$X_j$ , es el 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 7

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

Donde,

$P_j$ , es el factor de ponderación y  $X_j$  es el valor normalizado del indicador  $j$  para estimar los componentes de vulnerabilidad.

El índice de vulnerabilidad oscila entre [0,1]; por lo que a medida que el índice se acerca a cero la vulnerabilidad será mínima y por el contrario si se acerca a uno la vulnerabilidad aumenta. Los pesos ( $P_j$ ) fueron estimados por el método propuesto por Iyengar y Sudarshan (1982),

Ecuación 8

$$P_j = \frac{c}{1/\sqrt{\text{var}_i(X_{i,j})}}$$

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 9

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

## 4.2. Etapa 1. Desarrollo del modelo de vulnerabilidad a través de un sistema multi-agente

La siguiente sección describe la etapa 1 de la metodología desarrollada en esta investigación como se muestra en la Figura 20. La Etapa 1, identifica las variables socioeconómicas y ambientales determinantes de vulnerabilidad y riesgo agrícola; con las variables obtenidas se propone el desarrollo del modelo para la evaluación de vulnerabilidad agrícola basado en agentes inteligentes denominado “*Agente Indicadores de Vulnerabilidad*”, el cual está integrado por cuatro redes de información modeladas a través de Dinámica de Sistemas: i) *Rendimiento de tierras agrícolas*, ii) *Valor de la agricultura*, iii) *Eficiencia de recursos hídricos en actividades agrícolas* y iv) *Contingencia ambiental*. En la segunda etapa se desarrolló el modelo “*Agente Cultivo*” a través de técnicas de inteligencia artificial (lógica difusa) para estimar la vulnerabilidad del cultivo de estudio. Posteriormente, se determina la vulnerabilidad global en la caña de azúcar (Etapa 3).

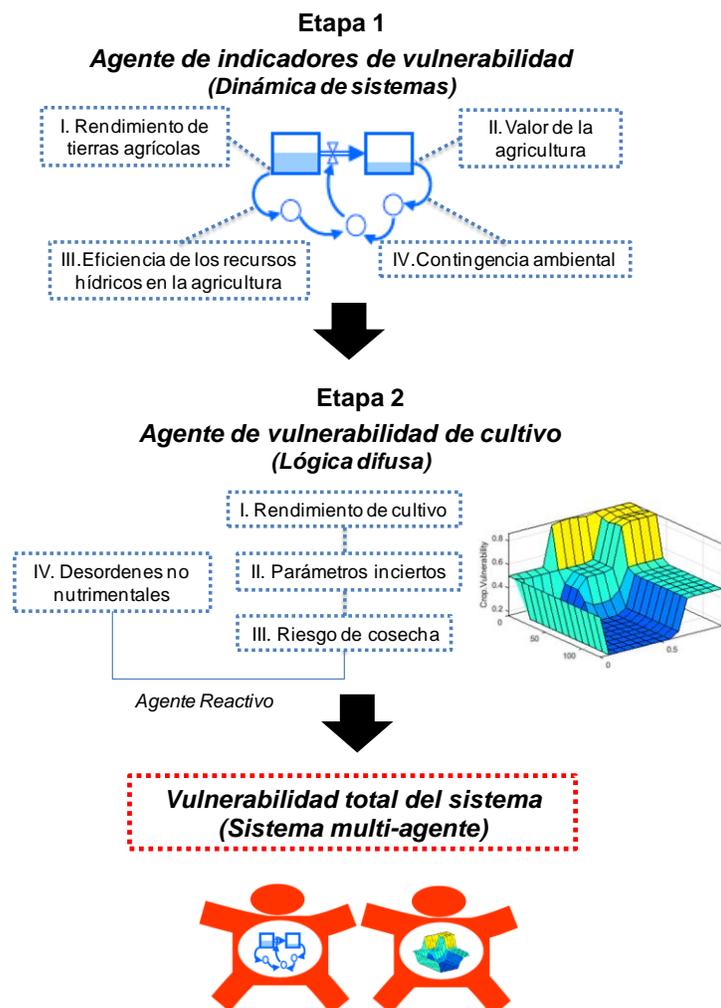


Figura 20 Metodología para determinar la vulnerabilidad total del sistema basado en un sistema multi-agente.

Para lograr una mejor representación del sistema agrícola, el modelo desarrollado aborda representaciones complejas considerando riesgo, aprendizaje e interacciones sociales entre agentes; por lo tanto, el modelo multi-agente es una base del conocimiento integrada por: (i) distribuciones de probabilidad definidas por sistemas de información y por (ii) expertís.

Bajo el enfoque ABM, cada etapa es representada por un agente conformando el sistema multi-agente donde éstos son entidades que muestran autonomía y proactividad (agentes activos); mientras que las entidades pasivas son representadas por cada variable que integran las redes de información (submodelos desarrollados a través de un enfoque sistémico-dinámico y expertís). La Tabla 10 describe los tipos de agentes empleados en el sistema multi-agente y su principal función.

Tabla 10 Clasificación de agentes

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.
Desordenes no nutrimentales	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.

#### 4.2.1. Aplicación de dinámica de sistemas en Anylogic

La metodología de dinámica de sistemas permite modelar y simular sistemas complejos como los sistemas agrícolas. La representación de los sistemas agrícolas o cadenas de suministro agrícola bajo un enfoque sistémico, de acuerdo con Forrester, “*permite representar la estructura del sistema y simular el comportamiento del mismo a través de la retroalimentación de información entre cada variable*” (Jay Forrester (1918), 1961).

Por su parte, de acuerdo a Campuzano, “*un análisis sistémico permite identificar rápidamente los elementos esenciales de la problemática; en este sentido, el objetivo de dinámica de sistemas es examinar la interacción que existe entre las funciones dentro de un sistema, con el fin de comprender y mejorar la interacción de los componentes del mismo*” (Campuzano-Bolarín et al., 2010).

Para la modelación del *agente de indicadores de vulnerabilidad*, se desarrollaron los diagramas: causal y de flujo para representar la estructura del sistema y posteriormente simular el comportamiento del mismo.

#### 4.2.1.1. Conceptualización

Para elaborar el diagrama causal, se identificaron las principales variables que describen los indicadores de vulnerabilidad en los aspectos socioeconómicos y ambientales. De acuerdo con Sullivan, los indicadores “*sirven para ordenar y sistematizar información para la planificación, evaluación y toma de decisiones, y permiten constituir sistemas de información que dan cuenta de las características cuantitativas. Se construyen a partir de datos de censos de contextos regionales, nacionales o supranacionales*” (Sullivan and Meigh, 2005).

La red *Rendimiento de tierras agrícolas* permite estimar la disponibilidad de tierras en la agricultura y la vulnerabilidad producto de sobreexplotación de suelos agrícolas o por degradación. Con la red *Valor de la agricultura* se puede estimar el “valor agregado” producto de actividades agrícolas a partir del flujo de información relacionada a la productividad, problemas en el desarrollo de actividades agrícolas, valor de la cosecha, horas trabajadas.

La red *Eficiencia de recursos hídricos en la agricultura* permite estimar la vulnerabilidad del uso del agua en actividades agrícolas debido a que cerca del 79% de las actividades agrícolas en México no cuentan con un sistema de riego (INEGI, 2018a).

La red *Contingencia ambiental* engloba la presencia de fenómenos ambientales severos resultado de condiciones climáticas y emisiones GEI. Los fenómenos ambientales son considerados aquellos eventos climáticos que por su frecuencia y magnitud ponen en riesgo la cosecha agrícola.

Las variables que alimentan al agente de indicadores de vulnerabilidad están modeladas mediante distribuciones de probabilidad que describen datos históricos del periodo 2001-2018. (CENAPRED; CONAFOR; CONAGUA; ENA; INECC; INEGI; Inifap; SAGARPA; SEMARNAT; SIAP; SMN; The World Bank).

La Tabla 11 describe las principales variables empleadas en los modelos que constituyen el agente de indicadores de vulnerabilidad. En la Figura 21, se muestra el diagrama causal del modelo de agente de indicadores de vulnerabilidad. Las interrelaciones entre las variables están representadas por flechas acompañadas de un signo positivo (+) ó negativo (-) que indica el tipo de influencia que ejerce una variable sobre otra. Las relaciones positivas indican que un incremento ó disminución de la variable A produce el mismo efecto sobre la variable B; mientras que las relaciones negativas indican que un incremento o disminución de la variable A produce un efecto inverso sobre la variable B (Cedillo-Campos, 2008).

Tabla 11 Variables del agente de indicadores de vulnerabilidad

<b>Variable</b>	<b>Descripción</b>	<b>Unidad</b>
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 cereales	Extensión de tierras destinadas a la producción de cereales	Ha
Tierras de cultivo	Extensión de tierras permanentes para cultivo	Ha
Rendimiento de cereales	Rendimiento de cereales por hectárea cosechada	Kg/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 <sup>2</sup>
Superficie con apoyo al campo	Superficie agrícola con algún tipo de apoyo para la realización de las actividades agrícolas.	Ha
Problemas de actividades agrícolas	Principales problemas para el desarrollo de actividades agrícolas, relacionados directamente con el agricultor	-
Seguro	Superficie agrícola con contratación de seguro para actividades agrícolas. Puede tener diferentes tipos de origen	Ha

Continuación Tabla 11 Variables del agente de indicadores de vulnerabilidad

Variable	Descripción	Unidad
INPC	Índice Nacional de Precios al Consumidor, indicador para estimar la evolución de precios de bienes y servicios en México.	-
Índices de desempeño	Indicador para estimar la producción de alimentos, horas trabajadas, etc.	%
PIB	Producto Interno Bruto, base 2013	MUS\$
Valor de la agricultura	Valor agregado de la agricultura en relación al GDP	MUS\$
Origen de agua	Origen de agua según su tipo de fuente: pozo, río, manantial, presa, pozo de agua a cielo abierto, etc.	Hm <sup>3</sup>
Suministro de agua	Abastecimiento de agua subterráneo y superficial	Hm <sup>3</sup>
Disponibilidad nacional de agua	Volumen de agua disponible, el cual es distribuido a diversos sectores	Hm <sup>3</sup>
Tipos de agua	Volumen de agua según su clasificación: aguas negras, aguas de tratamiento residual, agua salobre, etc.	Hm <sup>3</sup>
Eficiencia de recursos hídricos	Eficiencia de los recursos hídricos destinados para el desarrollo de actividades agrícolas	Kg/m <sup>3</sup>
Situación de riesgo/emergencia	Eventos naturales catalogados como estado de emergencia o desastre los cuales ponen el riesgo las actividades agrícolas. incluye: incendios forestales, tormentas, frente frío, heladas, ciclones, sismos, sequías	Number of events
GEI agrícolas	Gases de efecto invernadero (GEI) generados por el desarrollo de actividades agrícolas	Gt CO <sub>2</sub> eq
Emisiones de CO <sub>2</sub>	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 a la tierra	Gt CO <sub>2</sub> eq
Emisiones de CH <sub>4</sub>	Emisiones de metano producidas por la descomposición de la materia orgánica.	Gt CO <sub>2</sub> eq
Emisiones de N <sub>2</sub> O	Las emisiones de óxido nitroso son el principal contaminante de la capa de ozono	Gt CO <sub>2</sub> eq
Emisiones de HFC	Los hidrofluorocarbonos es la tercera generación de gases refrigerantes	Gt CO <sub>2</sub> eq
Emisiones de PFC	Los perfluorocarbonos son compuestos sintéticos que contienen átomo de flúor y carbono. Son gases incoloros no inflamables a temperatura ambiente	Gt CO <sub>2</sub> eq
Emisiones de SF <sub>6</sub>	El hexafluoruro de azufre es un compuesto inorgánico que en condiciones normales de presión y temperatura es un gas no tóxico y no inflamable. El SF <sub>6</sub> es cinco veces más pesado que el aire.	Gt CO <sub>2</sub> eq

*Ton/Ha: toneladas por hectárea m<sup>2</sup>: metros cuadrados MUS\$:Millones de dólares Hm<sup>3</sup>: hectómetros cúbicos Kg/m<sup>3</sup>: kilogramos por metro cúbico Gt CO<sub>2</sub>eq: gigatoneladas de dióxido de carbono equivalente.*

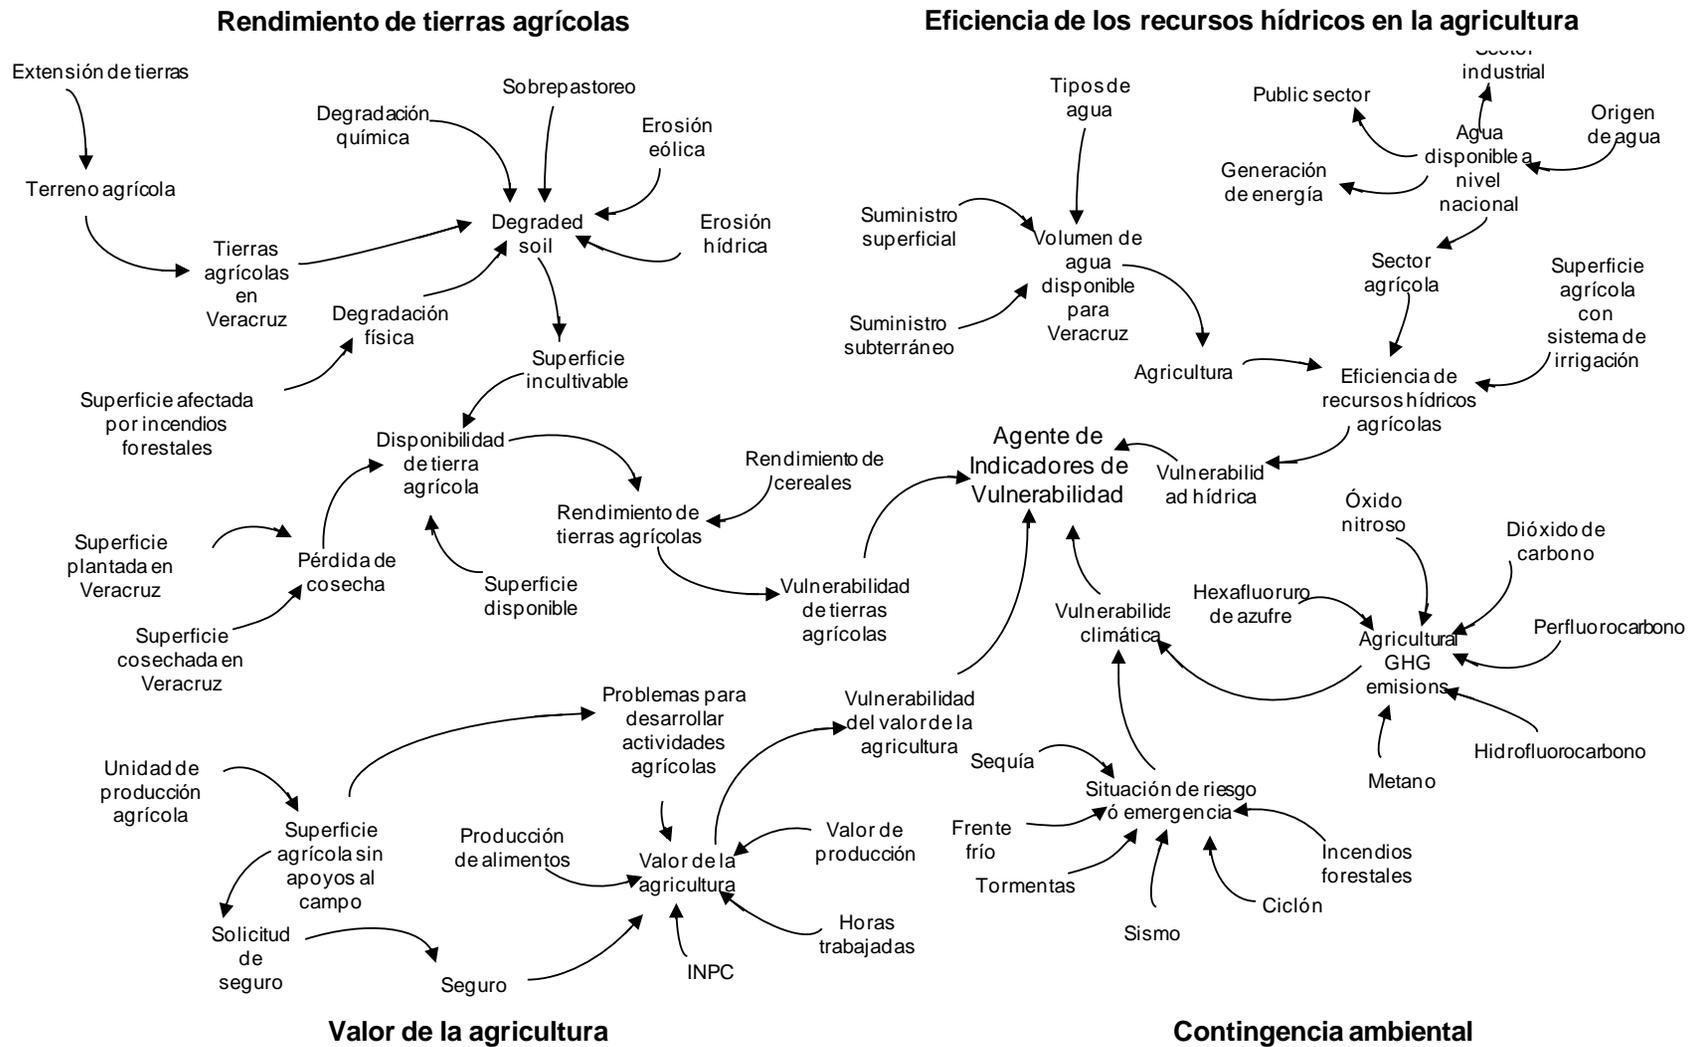


Figura 21 Diagrama causal del modelo agente de indicadores de vulnerabilidad

#### 4.2.1.2. Formulación

En la formulación del modelo se realizaron pronósticos de las variables de interés y se determinaron las ecuaciones para cada subsistema. Para evaluar el comportamiento del sistema a través del tiempo, se determinó la tendencia de las series de tiempo empleadas en el modelo de simulación. La Tabla 12 presenta el tipo de tendencia de cada serie de tiempo analizada y el modelo matemático empleado cuando  $t > 0$ .

Tabla 12 Análisis de tendencias del modelo agente de indicadores de vulnerabilidad

Series de tiempo	Tipo de tendencia	Modelo matemático
Extensión de tierras	Sin tendencia	9299303
Terreno agrícola	Decreciente	69.17%      54.89 < % < 73.38
Superficie afectada por incendios forestales	Ascendente	$f(t; \mu, \sigma) = \frac{1}{t(0.242966)\sqrt{2\pi}} e^{-\frac{(\ln(t)-349617)^2}{2(242966)^2}}$
Superficie disponible	Sin tendencia	125782926
Rendimiento de cereales	Decreciente	$f(t) = \frac{1}{754\sqrt{2\pi}} e^{-\frac{(t-2369)^2}{2(754)^2}}$
Unidad de producción agrícola	Sin tendencia	20
Superficie con apoyos al campo; Ha	Ascendente	$f(t) = \frac{1}{8.81E^5\sqrt{2\pi}} e^{-\frac{(t-127.7E^5)^2}{2(8.81E^5)^2}}$
Solicitud de seguro	Ascendente	3.79 %      3.15 < % < 5.82
Obtención de seguro	Ascendente	9.48%      9.41 < % < 9.67
Índice Nacional de Precios al Consumidor	Ascendente	$f(t) = \frac{1}{34.9\sqrt{2\pi}} e^{-\frac{(t-69.43)^2}{2(34.9)^2}}$
Inflación	Sin tendencia	6.5%
Índice de productividad	Ascendente	$f(t) = \frac{1}{2.47\sqrt{2\pi}} e^{-\frac{(t-99.85)^2}{2(2.47)^2}}$
Índice de horas trabajadas	Ascendente	$f(t) = \frac{1}{6.08\sqrt{2\pi}} e^{-\frac{(t-103.8)^2}{2(6.08)^2}}$
Índice de cosecha	Ascendente	$f(t; \lambda, k) = \frac{3.01}{82.5} \left(\frac{t}{82.5}\right)^{3.01-1} e^{-\left(\frac{t}{82.5}\right)^{3.01}}$
Índice de producción de alimentos	Ascendente	$f(t; \lambda, k) = \frac{2.6}{77.7} \left(\frac{t}{77.7}\right)^{2.6-1} e^{-\left(\frac{t}{77.7}\right)^{2.6}}$
PIB (4 <sup>to</sup> quartile del 2018)	Sin tendencia	18512407
Índice de valor de producción	Ascendente	$f(t) = \frac{1}{0.014\sqrt{2\pi}} e^{-\frac{(t-0.137)^2}{2(0.014)^2}} * PIB Pa$
Disponibilidad de agua para la agricultura	Sin tendencia	76%
Suministro subterráneo (UndS)	Ascendente	$f(t; \mu, \sigma) = \frac{1}{t(23.6)\sqrt{2\pi}} e^{-\frac{(\ln(t)-504.8)^2}{2(23.6)^2}}$
Suministro superficial (SupS)	Ascendente	$f(t; \mu, \sigma) = \frac{1}{t(162.4)\sqrt{2\pi}} e^{-\frac{(\ln(t)-2383)^2}{2(162.4)^2}}$

Series de tiempo	Tipo de tendencia	Modelo matemático
Superficie plantada	Ascendente	$f(t) = \frac{1}{1.41E6\sqrt{2\pi}} e^{-\frac{(t-2.127)^2}{2(1.41E6)^2}}$
Superficie cosechada	Ascendente	$f(t; \lambda, k) = \frac{12.26}{1.97E8} \left(\frac{t}{1.97E8}\right)^{12.26-1} e^{-\left(\frac{t}{1.97E8}\right)^{12.26}}$
Incendios forestales	Ascendente	$f(t) = \frac{1}{2204\sqrt{2\pi}} e^{-\frac{(t-7971)^2}{2(2204)^2}}$
Sequía	Ascendente	$f(t) = 0.004e^{-0.004t}$
Sismo	Ascendente	$f(t) = 0.0229e^{-0.0229t}$
Ciclón	Ascendente	$f(t) = 0.003e^{-0.003t}$
Frente frío	Ascendente	$f(t) = 0.0085e^{-0.0085t}$
Tormentas	Ascendente	$f(t) = 0.025e^{-0.025t}$
Tierras para cereales	Decreciente	$f(t; \lambda, k) = \frac{14.63}{0.08} \left(\frac{t}{0.08}\right)^{14.63-1} e^{-\left(\frac{t}{0.08}\right)^{14.63}}$
Tierras para cultivar	Decreciente	$f(t; \mu, \sigma) = \frac{1}{t(0.012)\sqrt{2\pi}} e^{-(\ln(t)-0.106)^2/2(0.012)^2}$
Tierras destinadas a la agricultura	Decreciente	$f(t; \mu, \sigma) = \frac{1}{t(0.021)\sqrt{2\pi}} e^{-(\ln(t)-0.527)^2/2(0.021)^2}$
Tierras permanentes de cultivo	Decreciente	$f(t; \mu, \sigma) = \frac{1}{t(0.0024)\sqrt{2\pi}} e^{-(\ln(t)-0.010)^2/2(0.024)^2}$
CO <sub>2</sub>	Ascendente	$f(t) = 13438e^{-13438t}$
CH <sub>4</sub>	Ascendente	$f(t) = 64986e^{-64986t}$
NO <sub>2</sub>	Ascendente	$f(t) = 32669e^{-32669t}$
Erosión hídrica	Ascendente	$f(t) = Agricultural\ ground * 0.119$
Erosión eólica	Ascendente	$f(t) = Agricultural\ ground * 0.0949$
Sobrepastoreo	Ascendente	$f(t) = Agricultural\ ground * 0.028$
Degradación física	Ascendente	$f(t) = (Agricultural\ ground * 0.057) + Area\ affected\ by\ fores\ fires$
Degradación química	Ascendente	$f(t) = Agricultural\ ground * 0.1783$

El modelo de agente de indicadores de vulnerabilidad tiene un periodo (t>0) para un periodo de 12 ciclos de cosecha de caña de azúcar y se desarrolló en el software Anylogic® Personal Learning Edition (software libre para versión estudiante) en la librería de “Dinámica de Sistemas”. A continuación se muestra la formulación matemática para los elementos básicos del modelo en donde se emplean series de tiempo para su desarrollo.

- a) *Degradación de suelo (DS)*. La variable está representada por el flujo de las variables: erosión hídrica (HE), erosión eólica (EE), sobrepastoreo (Og), degradación química (CD) y degradación física (PD).

Ecuación 10

$$\frac{dDS}{dt} = DS_{t=1} + (HE + EE + Og + CD + PD)$$

- b) *Disponibilidad de tierras agrícolas (AreaAgr)*. Indica el terreno disponible para el desarrollo de actividades agrícolas excluyendo la superficie incultivable por degradación de suelos y superficie agrícola con pérdida de cosecha por causa de fenómenos climatológicos.

Ecuación 11

$$\frac{dAreaAgr}{dt} = AreaAgr_{t=1} + (AreaAvailable) - \left[ \frac{dDS}{dt} + (PlantedArea - HarvestedArea) \right]$$

Ecuación 12

$$AreaAvailable = CerealLand + Farmland + AgriculturalLand + CropLand$$

- c) *Superficie sin apoyos al campo (FWSA)*. Superficie sin apoyo gubernamental y/o privado para el desarrollo de actividades agrícolas.

Ecuación 13

$$FWSA = \left( \frac{dAreaAgr}{dt} - FieldSupportArea \right) * AgriculturalProductionUnit$$

- d) *Valor de la agricultura (AgrValue)*. Valor agregado de la agricultura en relación al PIB; engloba las series de tiempo de los índices: producción de alimentos (FPi), valor de la producción (PVi), cosecha (Hi), horas trabajadas (HWi), nacional de precios al consumidor esperado (NCPIexp), índice de productividad (Pi) y el índice de problemas para el desarrollo de actividades agrícolas (PRi).

Ecuación 14

$$\frac{dAgrValue}{dt} = AgrValue_{t=1} + (FPi + PVi + Hi + HWi + NCPIexp + Pi - PRi) * GDP$$

- e) *Disponibilidad de recursos hídricos (HyRes)*. Volumen proveniente de distintos suministros de abastecimiento (pozo, río, manantial, presa de agua, pozo de agua a cielo abierto, bordo de agua u otras fuentes).

Ecuación 15

$$\frac{dHyRes}{dt} = HyRes_{t=1} + \left( \frac{1}{9722\sqrt{2\pi}} e^{-\frac{(x-4.64E^5)^2}{2(9722)^2}} \right) 0.76$$

- f) *Eficiencia de recursos hídricos (WREff)*. Indica la eficiencia del abastecimiento subterráneo y superficial de los recursos hídricos agrícolas para la zona geográfica del caso de estudio.

Ecuación 16

$$\frac{dWREff}{dt} = WREff_{t=1} + \frac{\frac{dHyRes}{dt}}{\left[ \left( \frac{1}{0.0272\sqrt{2\pi}} e^{-(x-0.7637)^2/2(0.0272)^2} \right) (UndS + SupS) \right]}$$

- g) *Emisiones GEI*. Sumatoria de emisiones derivadas del desarrollo de actividades agrícolas.

Ecuación 17

$$\frac{dGHG}{dt} = GHG_{t=1} + \sum (SF_6 + PFC + N_2O + CO_2 + CH_4 + HFC)$$

- h) *Desastres ambientales (ED)*. Incluye fenómenos meteorológicos (sequía, sismo, ciclón, frente frío, tormentas eléctricas) e incendios forestales catalogados en estado de emergencia ó desastre que incrementan el riesgo de la cosecha.

Ecuación 18

$$\frac{dED}{dt} = ED_{t=1} + \sum (Emergency\ or\ risk\ events)$$

#### 4.2.1.3. 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 22-25 muestran el diagrama de flujo para cada red:

La red *Rendimiento de tierras agrícolas* (Figura 22) permite estimar los principales tipos de degradación de suelo y dependiendo del grado de degradación estimar la superficie incultivable. La superficie agrícola disponible determina el área potencialmente cultivable descartando aquella superficie afectada severa y extremadamente; para con ello, determinar el rendimiento y vulnerabilidad de la superficie agrícola.

La red *Valor de la agricultura* (Figura 23) dependiendo del área agrícola disponible, estima la superficie agrícola con apoyos al campo, sí cuenta con algún tipo de seguro

agrícola, puesto que la falta de recursos y apoyos al campo aumentan la vulnerabilidad; posteriormente con base a índices de desempeño agrícola es posible determinar la vulnerabilidad en el valor de la agricultura.

La red *Eficiencia de los recursos hídricos* (Figura 24) se calcula a través del agua disponible para el sector agrícola tanto de fuentes subterráneas como superficiales y la superficie agrícola que emplea algún sistema de irrigación.

La red *Contingencia ambiental* (Figura 25) se compone de dos módulos, el primer módulo determina la suma de emisiones GEI resultantes del sector agrícola, el segundo módulo permite estimar la cantidad de eventos climatológicos potencialmente riesgosos.

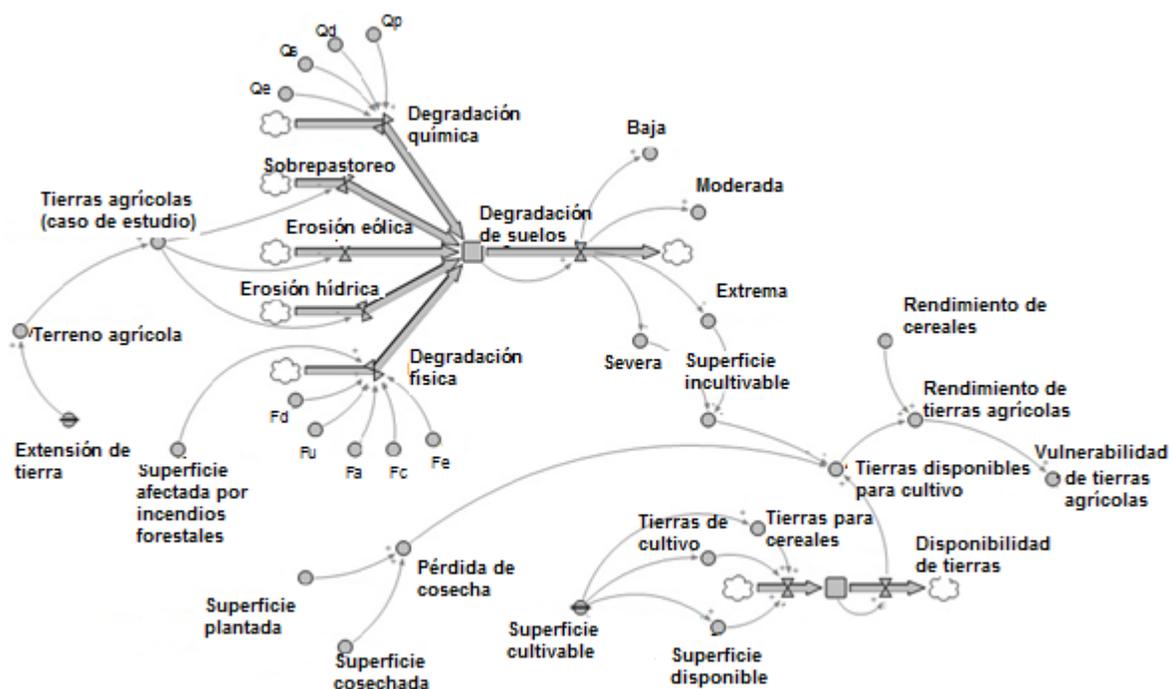


Figura 22 Diagrama de flujo de la red *Rendimiento de tierras agrícolas*.

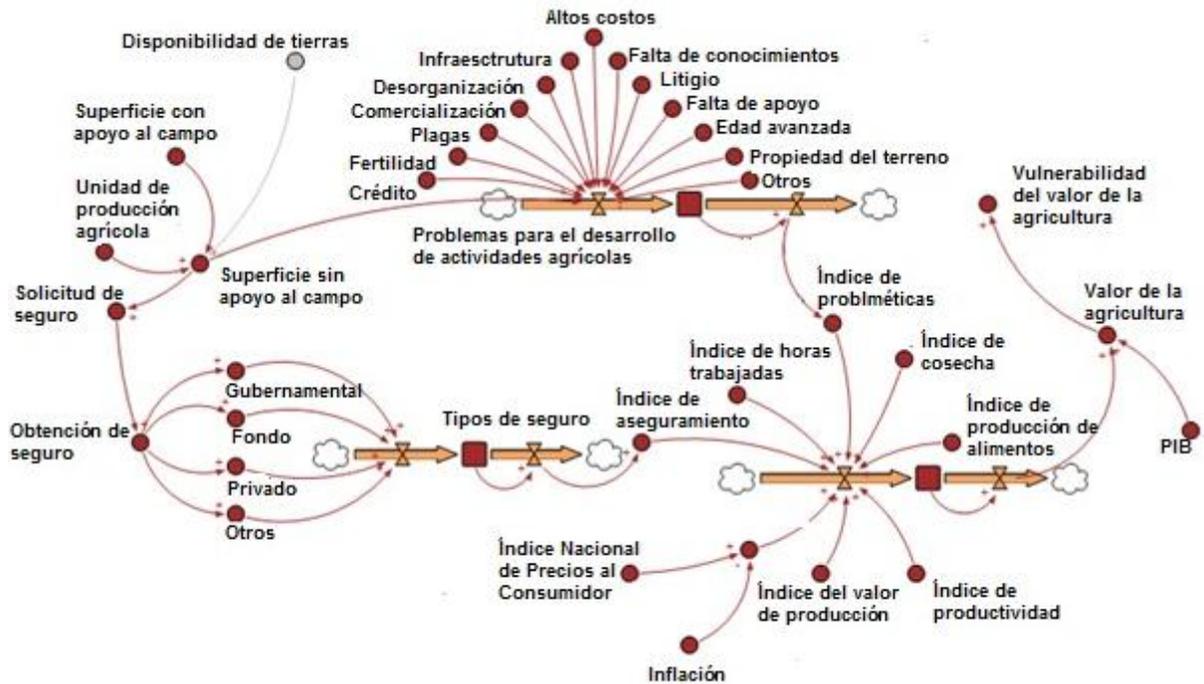


Figura 23 Diagrama de flujo de la red *Valor de la agricultura*.

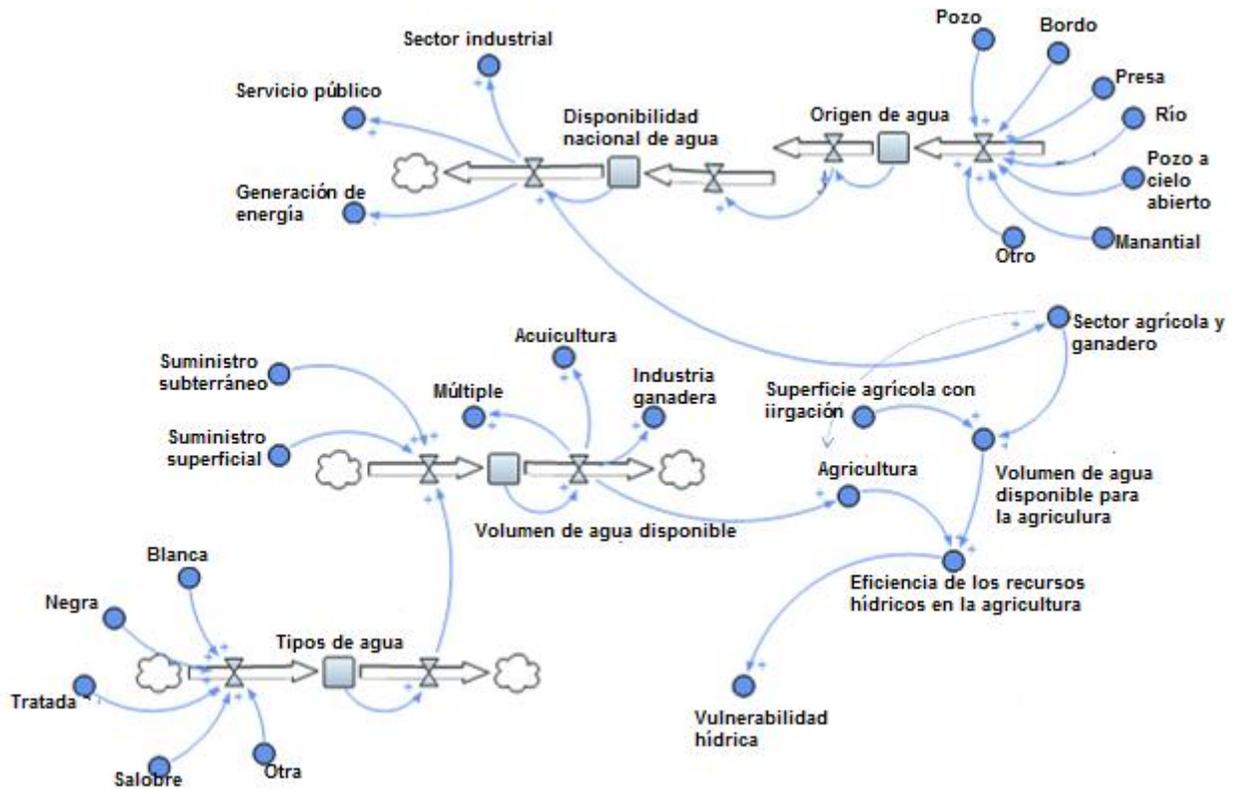


Figura 24 Diagrama de flujo de la red *Eficiencia de los recursos hídricos en la agricultura*.

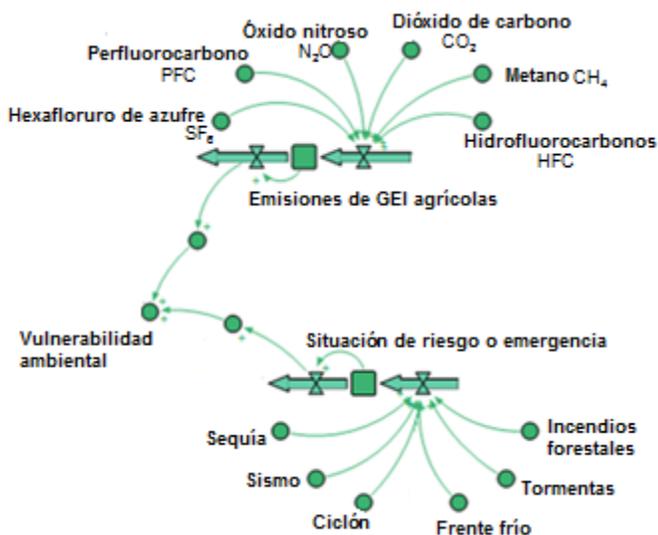


Figura 25 Diagrama de flujo de la red *Contingencia ambiental*.

### 4.3. Etapa 2. Desarrollo del modelo de cultivo: Caña de Azúcar (Caso de estudio)

Para la selección del caso de estudio, se realizó una clasificación de las regiones geográficas en México dependiendo de su extensión territorial y las diferencias climáticas, geográficas y económicas del país (SAGARPA, 2012) obteniéndose ocho regiones. La Tabla 13, muestra como está constituida cada región y el número de cultivos reportados (SIAP, 2018).

Tabla 13 Clasificación por regiones

Región	Estado	Cultivos
1	Tabasco y Veracruz	115
2	Chihuahua, Coahuila, Durango y Zacatecas	102
3	Chiapas, Guerrero y Oaxaca	125
4	Nuevo León y Tamaulipas	73
5	Colima, Guanajuato, Jalisco, Michoacán, Nayarit y Querétaro	177
6	Campeche, Quintana Roo y Yucatán	72
7	Aguascalientes, Hidalgo, México, Morelos, Puebla, San Luis Potosí y Tlaxcala	226
8	Baja California, Baja California Sur, Sinaloa y Sonora	145

Posteriormente se seleccionaron los principales cultivos para cada región según el volumen de producción en toneladas (Ton) para el año 2018 (Tabla 14).

Tabla 14 Principales cultivos de la región 1

<b>Región: Tabasco - Veracruz</b>	
<b>Cultivo</b>	<b>Volumen (Ton)</b>
Caña de azúcar	21,526,269.13
Naranja	2,417,877.30
Maíz	1,351,452.50
Plátano	919,015.37
Limón	742,175.25
Piña	600,050.96
Café	276,927.15
Uva	249,772.26
Mandarina	178,955.00

Dado que el caso de estudio se llevo a cabo en Veracruz, se selección la caña de azúcar al ser el cultivo con mayor producción obtenida. Se desarrollo una base de datos del año 2001 al 2018 con información de la superficie sembrada y cosechada, producción por cultivo, valor de la producción y pérdida de cultivo (Tabla 15).

Tabla 15. Producción de caña de azúcar en el estado de Veracruz

<b>Año</b>	<b>Superficie plantada (Ha)</b>	<b>Superficie cosechada (Ha)</b>	<b>Producción (Ton)</b>	<b>Valor de la producción (Miles de \$)</b>	<b>Pérdida de cosecha (Ha)</b>
2001	236,700.49	236,369.21	17,093,414.87	4,882,529,946.47	331.28
2002	247,739.25	246,026.75	17,268,324.59	5,020,943,423.66	1,712.50
2003	255,302.38	253,110.79	18,276,831.21	5,481,741,447.41	2,191.59
2004	256,907.60	254,222.25	18,314,345.84	5,834,120,583.73	2,685.35
2005	266,274.10	263,596.48	19,905,413.42	7,074,587,558.25	2,677.62
2006	265,598.52	251,973.64	19,032,889.97	6,863,380,267.14	13,624.88
2007	265,144.13	260,371.16	18,879,316.56	7,038,810,820.91	4,772.97
2008	269,290.00	263,734.00	18,204,201.00	7,010,470,588.34	5,556.00
2009	248,710.60	247,858.60	16,150,215.03	6,053,569,538.92	852.00
2010	274,221.67	271,244.87	18,672,089.59	11,506,978,398.10	2,976.80
2011	281,850.68	269,800.15	17,420,773.56	10,213,591,775.85	12,050.53
2012	294,192.07	274,860.39	18,321,345.59	11,877,473,969.63	19,331.68
2013	299,138.97	287,438.26	21,480,697.49	10,825,395,841.99	11,700.71
2014	288,997.84	279,364.77	19,226,604.33	8,575,132,302.30	9,633.07
2015	289,550.80	283,618.04	19,771,238.42	9,391,140,716.51	5,932.76
2016	300,753.25	290,316.07	20,036,707.85	10,281,608,834.62	10,437.18
2017	302,412.43	295,598.73	21,175,521.70	13,534,208,548.41	6,813.70
2018	305,473.91	290,600.64	21,282,823.66	15,282,749,839.76	14,873.27

La Figura 26 muestra la relación de Producción-Valor de producción de la caña de azúcar. Para el año 2018 se obtuvo una mayor producción de caña de azúcar con 21,

282,823.66 Ton y un valor de producción de \$ 15, 282, 749,839.76. Mientras que en el año 2001 se registró la menor producción.

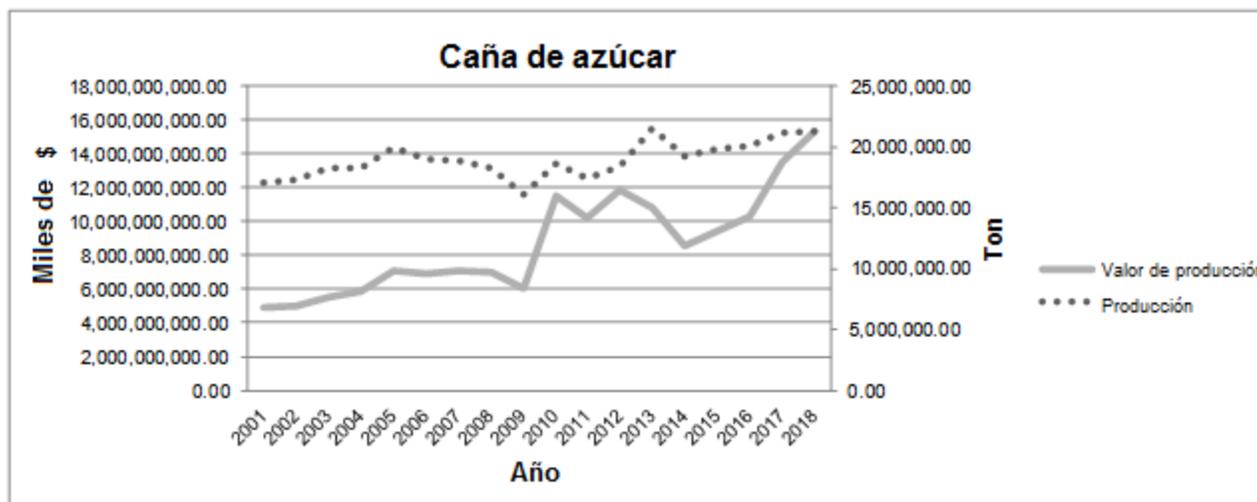


Figura 26 Valor de la producción de la caña de azúcar en el estado de Veracruz

Para determinar si el área de estudio pudiera experimentar vulnerabilidad agrícola, se aplicó el “índice de diversidad de cultivos de Simpson” (Ecuación 19). La correlación entre el índice de diversidad de cultivos de Simpson y la vulnerabilidad agrícola es la siguiente:

*“A medida que el índice de Simpson se acerca a 1 existe baja vulnerabilidad, debido a que existe una alta cantidad de cultivos, por lo contrario a medida que el índice se acerca a 0 la vulnerabilidad será alta por la baja cantidad de cultivos”.*

Ecuación 19

$$Id = 1 - \frac{(\sum_{i=1}^{Nc} Aj)^2}{At^2}$$

Donde

*At*: Superficie cosechada, en Ha.

*Nc*: Número total de cultivos reportados

*Aj*: Cosecha de cultivo *i*, en Ha.

$(\sum_{i=1}^{Nc} Aj)^2$ : Sumatoria al cuadrado de la superficie cosechada (*Aj*) de cada cultivo *i*, en Ha

La Tabla 16, muestra los resultados de la aplicación del índice de diversidad de cultivos de Simpson.

Tabla 16 Resultados del índice de Simpson

Año	At	Nc	$\sum_{i=1}^{Nc} * A_j^2$ :	Id
2001	1,502,940.12	86	568,343,890,832.02	0.74839003
2002	1,493,733.11	96	494,442,576,769.08	0.77839995
2003	1,349,445.32	100	446,837,687,184.32	0.75461997
2004	1,340,135.31	98	430,469,195,041.69	0.76031284
2005	1,272,799.48	101	385,723,696,345.57	0.76190167
2006	1,335,219.04	101	440,264,164,515.04	0.75305041
2007	1,274,905.95	97	353,292,698,982.05	0.78264063
2008	1,389,615.80	98	465,364,083,550.85	0.75900758
2009	1,344,486.33	99	427,741,947,361.46	0.7633704
2010	1,346,412.00	105	410,428,234,928.27	0.77359747
2011	1,360,879.75	109	447,815,748,411.98	0.75819802
2012	1,420,704.94	110	393,152,492,127.50	0.80521601
2013	1,420,509.40	111	762,740,677,827.95	0.62200271
2014	1,444,899.99	112	483,896,979,641.51	0.76821927
2015	1,436,386.06	111	483,031,212,703.90	0.76588306
2016	1,450,333.83	106	487,721,600,925.58	0.76813455
2017	1,425,811.28	107	479,475,101,328.47	0.76414669
2018	1,431,415.79	106	481,359,798,860.21	0.76507015

La Tabla 16 muestra los resultados tras la aplicación del índice de Simpson para el periodo 2001-2018 arrojando una media de  $\approx 0.76$ ; es decir, un valor de vulnerabilidad de  $\approx 0.25$  considerada baja a moderada (CONAGUA, 2015).

Con los datos obtenidos anteriormente, se observa que en la producción agrícola en el estado de Veracruz hay presencia de vulnerabilidad; por lo cual, una vez definido el caso de estudio, se desarrolló el modelo para determinar la vulnerabilidad de la caña de azúcar a través de técnicas de IA (lógica difusa).

La Figura 27 muestra la metodología empleada en la etapa 2.

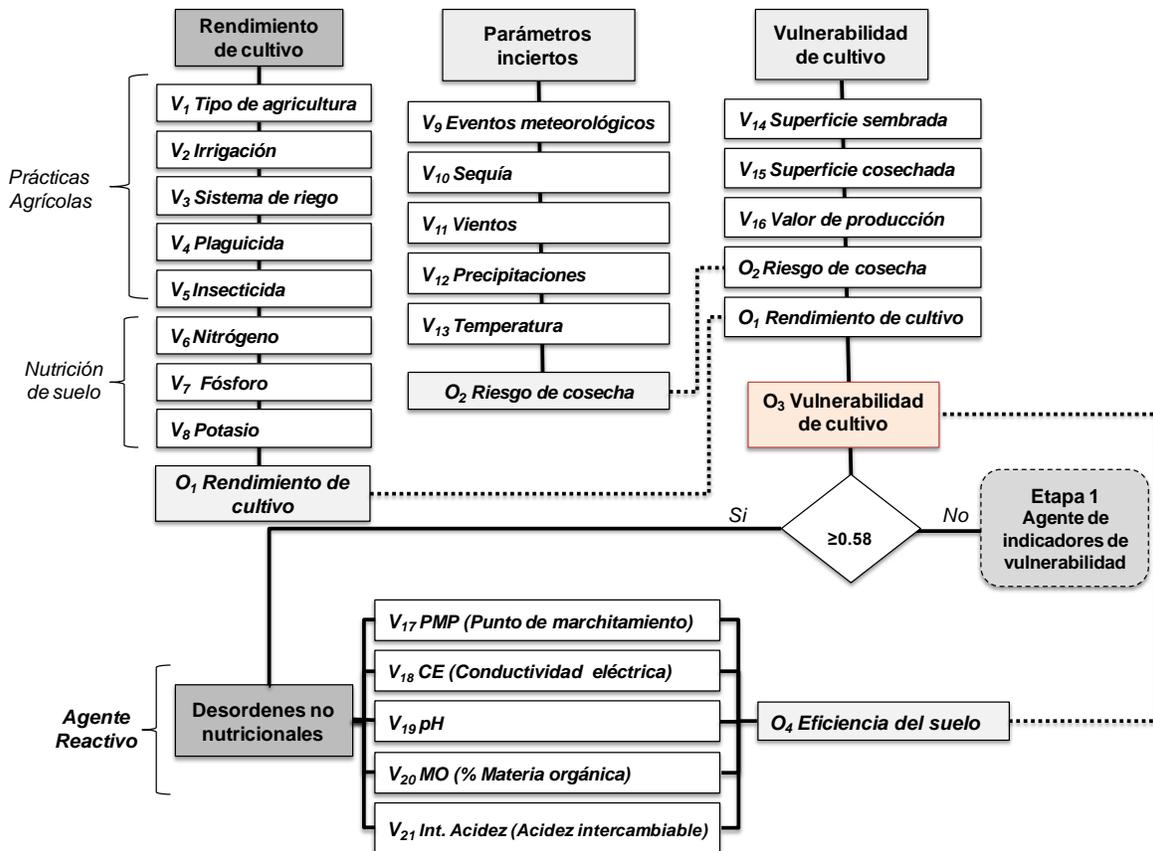


Figura 27 Metodología del modelo de agente de vulnerabilidad de cultivo

El modelo de Agente de vulnerabilidad de cultivo está compuesto por tres modelos de lógica difusa: Rendimiento de cultivo, Parámetros inciertos y Vulnerabilidad de cultivo.

El modelo *Rendimiento de cultivo* incluye variables relacionadas con las prácticas agrícolas y nutrición de los suelos para determinar el rendimiento que tendría el cultivo bajo condiciones óptimas.

El modelo *Parámetros inciertos* permite modelar variables no controlables relacionadas con fenómenos climatológicos que influyen en la producción agrícola.

El modelo *Vulnerabilidad del cultivo* engloba variables relacionadas con la producción agrícola. Si la vulnerabilidad es  $\geq 0.54$  existe una vulnerabilidad alta en la producción agrícola, la cual pudiera estar relacionada con desordenes no nutrimentales como características físico-químicas y edáficas en la zona del caso de estudio. Estos indicadores están relacionados con niveles de precipitación y almacenamiento de agua en los suelos (PRONAC et al., 2009).

De lo contrario, si la vulnerabilidad del cultivo es menor a 0.54; con base a los resultados de la *Etapa 1. Agente: Indicadores de Vulnerabilidad (dinámica de sistemas)*, se puede determinar la vulnerabilidad total del sistema.

### 4.3.1. Aplicación de lógica difusa en MatLab

Los modelos de lógica difusa están diseñados en MatLab® empleando el motor de inferencia Mandami constituido por “funciones de pertenencia” para las veintiún variables de entrada y cuatro variables de salida. La lógica difusa consiste en la implementación de variables lingüísticas para procesar lenguaje natural impreciso y difuso constituido por números y expresiones humanas (Wedding, 1997).

De acuerdo con (Ponce Cruz, 2010) *“una variable lingüística, adopta valores con palabras que permiten describir el estado de un objeto o fenómeno; estas palabras se pueden representar mediante conjuntos difusos. Las funciones de pertenencia sirven para definir el valor de la variable lingüística asociada, es decir, indican en qué grado la variable lingüística pertenece al conjunto difuso”*.

Los conjuntos difusos de las variables (entrada-salida) son modelados a través de una función triangular (Tr) formada por tres puntos y función trapezoidal (T) constituida por cuatro puntos. Las funciones que representan estas ecuaciones se muestran a continuación, respectivamente:

Ecuación 20

$$Tr(r; a, b, c) = \begin{cases} 0; & a < r \\ 1 - \left(\frac{b-r}{b-a}\right); & a \leq r \leq b \\ 1 - \left(\frac{r-b}{c-b}\right); & a \leq r \leq c \\ 0; & c > r \end{cases}$$

Ecuación 21

$$T(t; a, b, c, d) = \begin{cases} 0; & t < a \\ 1 - \left(\frac{b-t}{b-a}\right); & a \leq t \leq b \\ 1; & b \leq t \leq c \\ 1 - \left(\frac{t-c}{d-c}\right); & c \leq t \leq d \\ 0; & t > d \end{cases}$$

En el proceso de lógica difusa, la caracterización del comportamiento del sistema emplea reglas de inferencia las cuales son establecidas mediante la experticia y el conocimiento para caracterizar el comportamiento del sistema (Zadeh, 2013).

(Sivanandam et al., 2007) establecen que *“las reglas de inferencia se fundamentan en los denominados conjuntos difusos y un sistema de inferencia difuso basado en reglas de la forma IF-THEN”*; las cuales se pueden representar a través de Fuzzy Associative Memory (FAM).

Por tanto, las FAM: *“son matrices que representan las consecuencias de cada regla definida para cada combinación de dos o más entradas, permitiendo realizar una representación gráfica clara de las relaciones entre dos variables lingüísticas de entrada y la variable lingüística de salida, para ello, es necesario que se indique explícitamente todas las posibles combinaciones de reglas con las variables de entrada”* (Nedjah et al., 2014).

La Tabla 17 describe las variables utilizadas en el diseño de modelos de lógica difusa, y se especifica para cada una de ellas, su unidad de medida y tipo de variable, ya sea de entrada (I) o de salida (O) en el sistema experto.

Tabla 17 Variables del modelo Caña de azúcar

Variable	Descripción	Unidad	Tipo de Variable
V <sub>1</sub> Tipo de agricultura	Modalidad en la que se llevan a cabo las actividades agrícolas: cielo abierto o protegida	Moda	I
V <sub>2</sub> Irrigación	Modalidad hídrica empleada en el desarrollo y reproducción del cultivo: temporal o riego	Moda	I
V <sub>3</sub> Sistema de irrigación	Sistema de riego empleado, ya sea por gravedad, canales de agua, aspersión, goteo o tubería	Moda	I
V <sub>4</sub> Plaguicida	Prácticas agrícolas para el control de plagas que afectan el cultivo. El control sobre éstas se convierte en una determinante para asegurar la producción agrícola	Aplicación	I
V <sub>5</sub> Insecticida		Aplicación	I
V <sub>6</sub> Nitrógeno		Kg ha-1	I
V <sub>7</sub> Fósforo	Las variables: nitrógeno, fósforo y potasio, hacen referencia a la nutrición de suelos, la cuál es una práctica agrícola que se utiliza para suministrar nutrientes a suelo y a las raíces de la caña de azúcar, con el objetivo de maximizar los rendimientos de producción y calidad del cultivo.	Kg P2O5 ha-1	I
V <sub>8</sub> Potasio		Kg K2O ha-1	I
O <sub>1</sub> Rendimiento de cultivo		Relación de la producción total de un cierto cultivo cosechado por hectárea de terreno utilizada	Ton/Ha
V <sub>9</sub> Eventos meteorológicos	Fenómenos hidrometeorológicos declarados como estado de "emergencia" poniendo en riesgo al cultivo	Número de eventos	I
V <sub>10</sub> Sequía	Falta de lluvias durante un período prolongado produciendo sequedad en los campos agrícolas y escasez de agua	Número de eventos	I
V <sub>11</sub> Vientos	Evento incierto que afecta directamente el rendimiento de la producción y calidad del cultivo	Km/hr	I
V <sub>12</sub> Precipitaciones	Evento incierto que a su vez provee el agua a los cultivos	mm/mes	I
V <sub>13</sub> Temperatura	Parámetro incierto que representa la magnitud física que refleja la cantidad de calor en el ambiente	°C	I
O <sub>3</sub> Riesgo de cosecha	Interacción de parámetros climáticos para determinar riesgo existente en el desarrollo del cultivo	Nivel de riesgo	O
V <sub>14</sub> Superficie sembrada	Superficie agrícola en la cual se deposita la semilla del cultivo	Ton	I
V <sub>15</sub> Superficie cosechada	Superficie agrícola en la cual se obtuvo producción del cultivo deseado	Ton	I
V <sub>16</sub> Valor de producción	Valor monetario obtenido de la venta de la producción agrícola obtenida	Miles de dólares	I
O <sub>3</sub> Vulnerabilidad de cultivo	Grado en el que el cultivo puede verse afectado adversamente por la interacción de diversos factores	Nivel de vulnerabilidad	O
V <sub>17</sub> Punto de marchitamiento (PMP)	Punto de humedad mínima en el cual una planta no puede seguir extrayendo agua del suelo	Nivel PMP	I
V <sub>18</sub> Conductividad eléctrica (CE)	Mide la concentración de sales solubles presentes en la solución del suelo	dS/m	I
V <sub>19</sub> pH	Medida para determinar el grado de alcalinidad o acidez presentes en el suelo	Nivel de pH	I
V <sub>20</sub> Materia orgánica (MO)	Compuesto heterogéneo formado por la acumulación de materiales de origen animal y/o vegetal parcial o completamente descompuesto	%	I
V <sub>21</sub> Acidez intercambiable	Cantidad de iones de hidrógeno intercambiables por fracción de materia orgánica en el suelo	cMol*Kg-1	I
O <sub>4</sub> Eficiencia del suelo	Capacidad de almacenamiento de agua por el suelo basada en indicadores fisicoquímicos del ambiente edáfico	Nivel de eficiencia	O

### 4.3.1.1. Modelo rendimiento de cultivo

El modelo *Rendimiento de cultivo* permite estimar la cantidad producida (cosecha) por terreno de área utilizada (superficie sembrada). El modelo se alimenta de ocho variables de entrada, las cuales describen la modalidad de agricultura empleada (cielo abierto ó protegida), tipo de irrigación (temporal ó riego), el manejo de prácticas agrícolas para minimizar plagas y/o enfermedades que afecten el cultivo, así como la nutrición de suelos a través del suministro de nutrientes necesarios N-P-K (nitrógeno-fósforo-potasio) para maximizar los rendimientos de producción del cultivo (PRONAC et al., 2009), sistema de irrigación empleado (gravedad, canales, aspersión, goteo ó tubería). La Tabla 18 describe los parámetros empleados para la construcción del modelo: variables de entrada, constitución de conjuntos difusos (etiquetas lingüísticas e intervalos), base del conocimiento (reglas de inferencia) y variable de salida.

Tabla 18 Modelo *Rendimiento de cultivo*: conjuntos difusos e intervalos de operación

Entrada (I)				Base de conocimiento	Salida (O)			
Variable	Conjuntos difusos				Variable	Conjuntos difusos		
	Etiqueta	Función de pertenencia	Intervalo			Etiqueta	Función de pertenencia	Intervalo
Tipo de agricultura	Cielo abierto	Triangular	[ 1 2 ]	768 Reglas de inferencia	Rendimiento de cultivo	Ninguno	Triangular	[ 0 4.4 ]
	Agricultura protegida	Triangular	[ 2 3 ]					
Irrigación	Temporal	Triangular	[ 0 1 ]					
	Riego	Triangular	[ 1 2 ]					
Sistema de irrigación	Ninguno	Triangular	[ 0 1 ]					
	Gravedad	Triangular	[ 1 2 ]					
	Canal	Triangular	[ 2 3 ]					
	Aspersor	Triangular	[ 3 4 ]					
	Goteo	Triangular	[ 4 5 ]					
	Tubería	Triangular	[ 5 6 6 ]					
Nitrógeno (Kg ha <sup>-1</sup> )	Bajo-Medio	Trapezoidal	[ 0 36.5 ]					
	Alto	Trapezoidal	[ 25 65 ]					
Fósforo (Kg P <sub>2</sub> O <sub>5</sub> ha <sup>-1</sup> )	Bajo-Medio	Trapezoidal	[ 0 14 ]					
	Alto	Trapezoidal	[ 10 25 ]					
Potasio (Kg K <sub>2</sub> O ha <sup>-1</sup> )	Bajo	Triangular	[ 0 58 ]					
	Medio-Alto	Trapezoidal	[ 43 200 ]					
Pesticida	Si	Triangular	[ 1 2 ]					
	No	Triangular	[ 0 1 ]					
Insecticida	Si	Triangular	[ 1 2 ]					
	No	Triangular	[ 0 1 ]					
						Alto	Trapezoidal	[ 65.5 125 ]

La Figura 28 describe gráficamente los “conjuntos difusos” para cada variable lingüística del modelo difuso Rendimiento de cultivo.

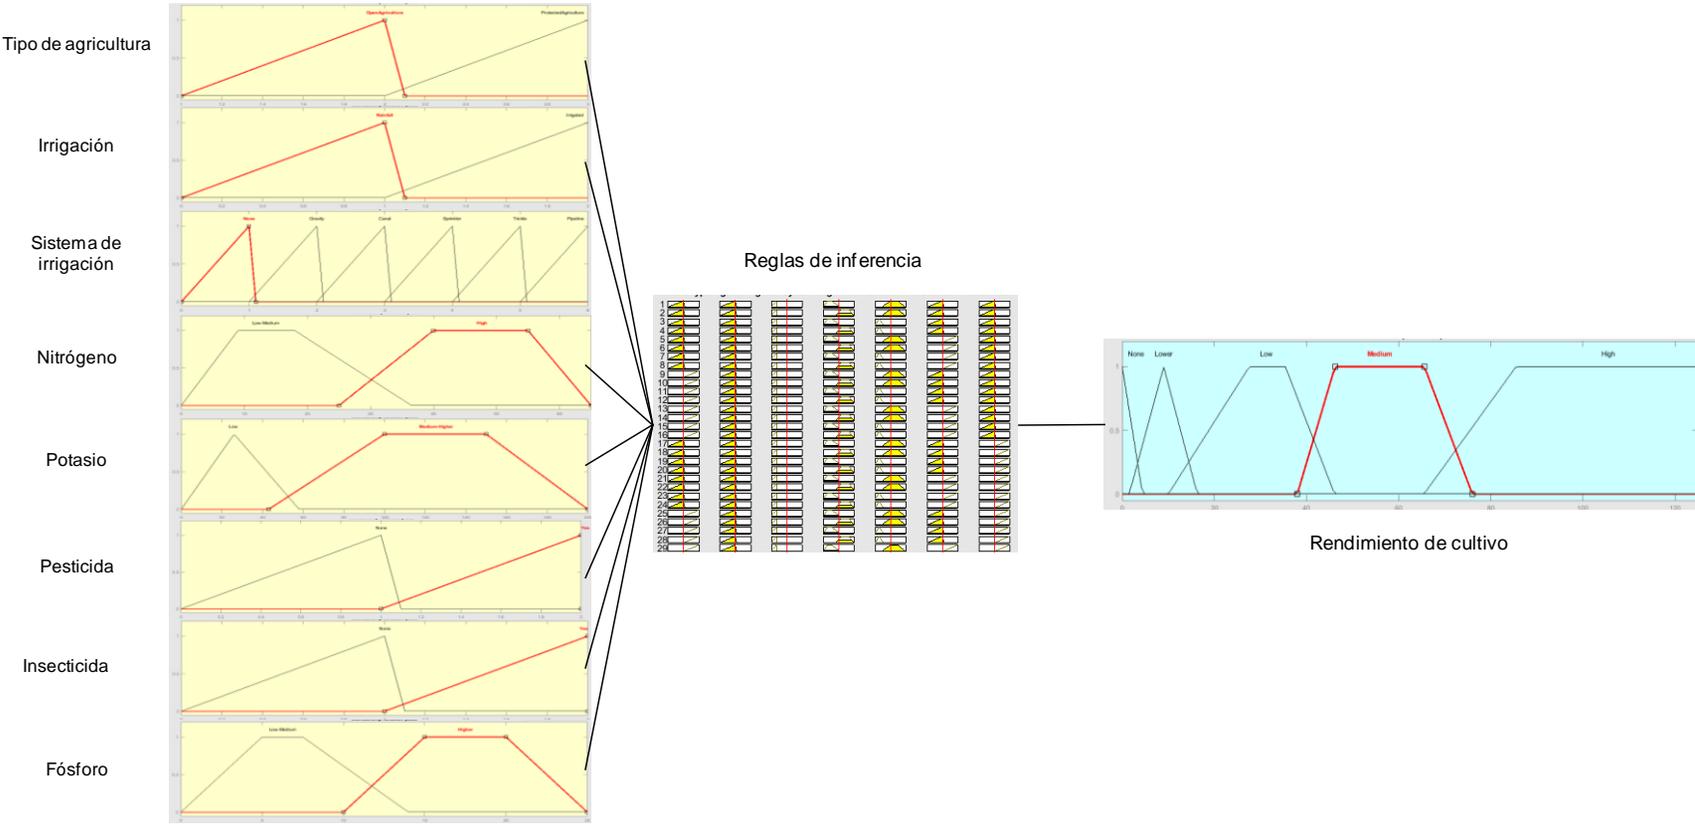


Figura 28 Representación gráfica del modelo difuso Rendimiento de cultivo.

La Figura 29 representa de manera gráfica el total de reglas de inferencia resultado del total de posibles combinaciones entre variables de entrada y salida. El color gris representa las reglas de inferencia válidas (384 reglas). Las reglas inválidas son aquellas que no se cumplen bajo ninguna circunstancia; para la variable “*Tipo de agricultura*”, la etiqueta “*Agricultura protegida*” implica el uso de algún sistema de irrigación, por lo cual se inactiva la etiqueta “*Temporal*” de la variable “*Irrigación*”. De igual forma para la variable “*Cielo abierto*” se desactiva la etiqueta “*Irrigación*” debido a que la agricultura a cielo abierto utiliza irrigación de tipo temporal para su desarrollo.

	Insecticida	Plaguicida	Potasio	Nitrógeno	Cielo abierto		Agricultura protegida				Cielo abierto		Agricultura protegida				Tipo de agricultura																			
					Temporal		Irrigación		Temporal		Irrigación		Temporal		Irrigación			Irrigación																		
					N	G	C	A	Go	T	N	G	C	A	Go	T			N	G	C	A	Go	T	N	G	C	A	Go	T	N	G	C	A	Go	T
					Sistema de irrigación																															
No	No	M - A	[Grid cells]																																	
		Bajo	[Grid cells]																																	
	Si	M - A	[Grid cells]																																	
		Bajo	[Grid cells]																																	
Si	No	M - A	[Grid cells]																																	
		Bajo	[Grid cells]																																	
	Si	M - A	[Grid cells]																																	
		Bajo	[Grid cells]																																	

N: Ninguna G: Gravedad C: Canal A: Aspensor Go: Goteo T: Tubería B-M: Bajo a Medio M-A: Medio a Alto

Figura 29 Matriz de inferencia del modelo Rendimiento de cultivo.

#### 4.3.1.2. Modelo de parámetros inciertos para predecir el riesgo de cosecha

La importancia de caracterizar el sistema agrícola, está en lograr controlar o predecir el comportamiento de variables que impactan el rendimiento del cultivo y en modelar el comportamiento de aquellos parámetros inciertos que pueden intervenir a lo largo de la producción del cultivo. El modelo *Parámetros inciertos* plantea la relación de variables no controladas potencialmente presentes en la obtención de caña de azúcar las cuales ejercen

influencia en forma positiva o negativa en dicho rendimiento. Dentro de éstos parámetros inciertos se encuentran principalmente la variable “*Eventos meteorológicos*” tales como ciclones, huracanes, tormentas tropicales, entre otros, declaradas en estado de “emergencia” o “desastre” que pudieran traer consigo impactos adversos al sistema de producción de la caña de azúcar. De igual manera se encuentran eventos tales como la variable “*Sequía*” la cual impacta principalmente el suelo agrícola. Las variables “*Vientos*”, “*Precipitaciones*” y “*Temperatura*” son condiciones hidroclimatológicas predominantes en el desarrollo del cultivo; por lo cual, el modelado de dichas condiciones ambientales (parámetros inciertos) ayudan a predecir la productividad en el cultivo y determinar el grado de “*Riesgo de cosecha*” (variable de salida).

Las reglas de inferencia son validadas a través de datos abiertos proporcionados por organismos gubernamentales (CENAPRED; CONADESUCA; ENA; PRONAC). En la Tabla 19 se describen los parámetros empleados en el diseño del modelo: variables (entrada-salida), conjuntos difusos (etiquetas lingüísticas e rangos) y base del conocimiento (reglas de inferencia).

Tabla 19 Modelo Parámetros inciertos: conjuntos difusos e intervalos de operación

Entrada (I)				Base del conocimiento	Salida (O)			
Variable	Conjuntos difusos				Variable	Conjuntos difusos		
	Etiqueta	Función de pertenencia	Intervalo			Etiqueta	Función de pertenencia	Intervalo
Eventos meteorológicos	Advertencia	Trapezoidal	[ 0 119 ]	72 Reglas de inferencia	Riesgo de cosecha	Inofensivo	Triangular	[ 0 0.43 ]
	Emergencia	Trapezoidal	[ 95 258 ]					
Sequía	Advertencia	Trapezoidal	[ 0 117 ]					
	Emergencia	Trapezoidal	[ 76 185 ]					
Vientos (Km/hr)	Débil	Triangular	[ 0 50 ]					
	Recio	Triangular	[ 40 60 ]					
	Fuerte	Trapezoidal	[ 50 100 ]					
Precipitaciones (mm/mes)	Nivel bajo	Trapezoidal	[ 0 50 ]		Riesgo de cosecha	Moderado	Triangular	[ 0.3 0.72 ]
	Nivel alto	Triangular	[ 10 170 ]					
Temperatura (°C)	Mínimo	Trapezoidal	[ 14 23 ]			Riesgo de cosecha	Riesgo	
	Óptimo	Trapezoidal	[ 18 32 ]					
	Máximo	Trapezoidal	[ 29 43 ]					

La Figura 30 describe gráficamente los conjuntos difusos correspondientes a cada variable lingüística del modelo difuso *Parámetros inciertos*.

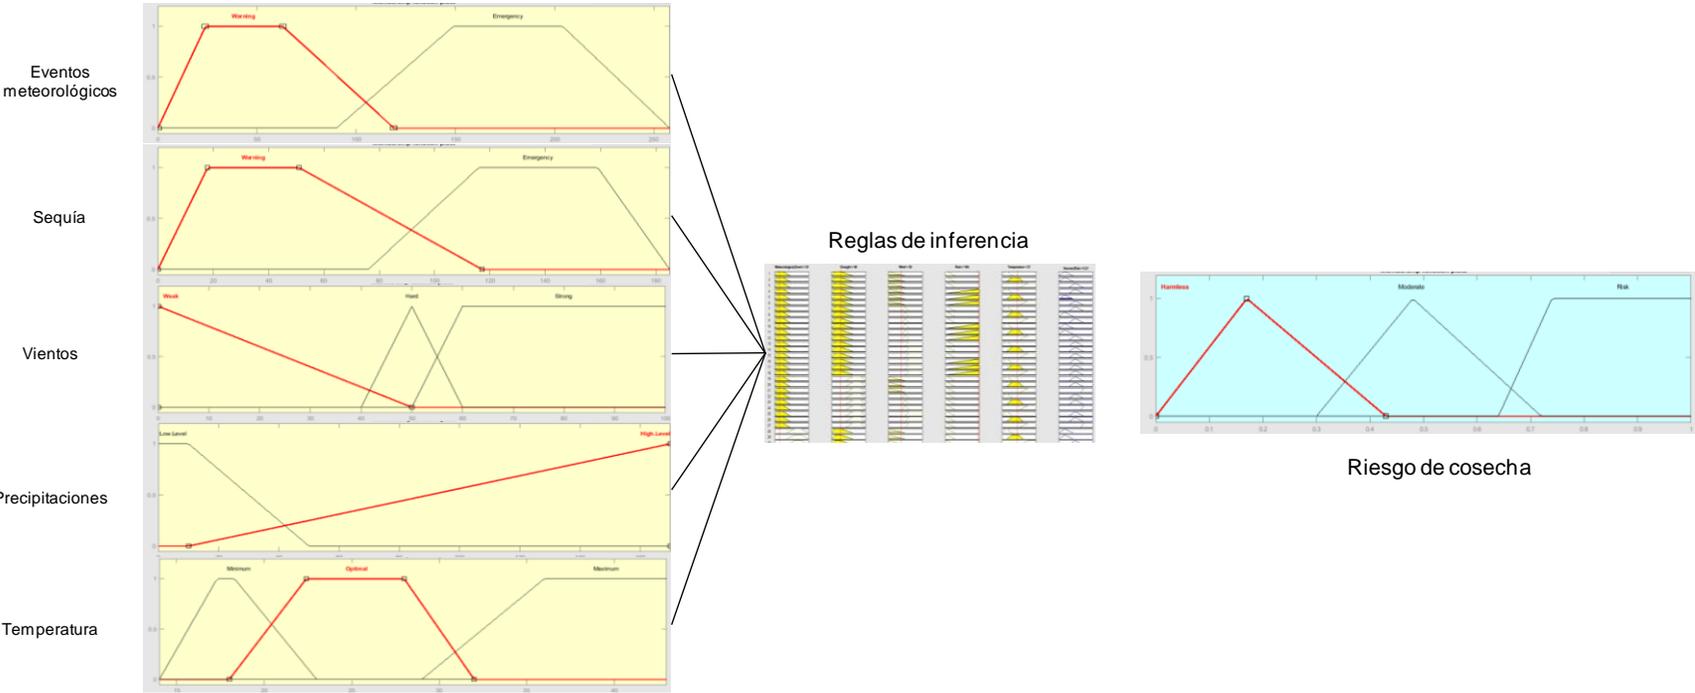


Figura 30 Representación gráfica del modelo Parámetros inciertos.

La Figura 31 representa de manera gráfica las reglas de inferencia (72 reglas) resultado del total de posibles combinaciones de la interacción de las variables de entrada y salida. El total de reglas válidas obtenidas son 45 (color gris) y las reglas inválidas 27. Las reglas de inferencia son validadas a través de datos abiertos proporcionados por organismos gubernamentales (CENAPRED; CONADESUCA; ENA; PRONAC)

Sequia		Temperatura												Eventos		
		Advertencia						Emergencia								
		Nivel bajo			Nivel alto			Nivel bajo			Nivel alto			Precipitaciones	Vientos	
		D	R	F	D	R	F	D	R	F	D	R	F			
Emergencia	Max															
	Op															
	Min															
Advertencia	Max															
	Op															
	Min															

D: Débil R: Recio F: Fuerte Min: Mínimo Op: Optimo Max: Máximo

Figura 31 Matriz de inferencia del modelo Parámetros inciertos.

#### 4.3.1.3. Modelo para predecir la vulnerabilidad del cultivo de caña de azúcar

El modelo *Vulnerabilidad de cultivo* permite determinar qué tan vulnerable es la producción de caña de azúcar para estimar las capacidades de adaptación e incrementar la resiliencia del sistema de producción agrícola.

El modelo se alimenta de datos históricos del periodo 2001-2018 de cosecha de caña de azúcar en Veracruz, de igual manera se alimenta por las variables de salida de los modelos *Rendimiento de cultivo* y *Parámetros inciertos*. Las reglas se validaron mediante datos abiertos históricos del sistema de producción agrícola de caña de azúcar en el estado de Veracruz (CONADESUCA; ENA; PRONAC; SIAP). En la Tabla 20 se describen los parámetros empleados en el diseño del modelo: variables (entrada-salida), conjuntos difusos (etiquetas lingüísticas e intervalos) y la base del conocimiento (reglas de inferencia). La Figura 32 muestra gráficamente las reglas de inferencia obtenidas en el modelo (120 reglas). las reglas fueron validadas por datos abiertos del sistema de producción agrícola de caña de azúcar (CONADESUCA; ENA; PRONAC; SIAP). Las reglas válidas obtenidas fueron 60, las cuales están sombreadas de color gris.

Tabla 20 Modelo Vulnerabilidad de cultivo: conjuntos difusos e intervalos de operación

Entrada (I)				Base del conocimiento	Salida (O)			
Variable	Conjuntos difusos				Variable	Conjuntos difusos		
	Etiqueta	Función de pertenencia	Intervalo			Etiqueta	Función de pertenencia	Intervalo
Superficie sembrada (Ha)	Temporada baja Temporada alta	Trapezoidal Trapezoidal	[ 6 7354 ] [ 4333 25000 ]	120 Reglas de inferencia	Vulnerabilidad de cultivo	Baja	Triangular	[ 0 0.33 ]
Superficie cosechada (Ha)	Cosecha baja Cosecha alta	Trapezoidal Trapezoidal	[ 3 8187 ] [ 4108 23800 ]					
Valor de producción (Miles de dólares)	Esperada Alta	Trapezoidal Trapezoidal	[ 1.59E <sup>3</sup> 1.71E <sup>7</sup> ] [ 1.14E <sup>7</sup> 4.73E <sup>7</sup> ]					
Rendimiento de cultivo	Ninguno	Triangular	[ 0 4.4 ]			Media	Trapezoidal	[ 0.2 0.76 ]
	Muy bajo	Triangular	[ 1.5 16.3 ]					
	Bajo	Trapezoidal	[ 10 46.1 ]					
	Medio	Trapezoidal	[ 38 76 ]					
Riesgo de cosecha	Inofensivo	Triangular	[ 0 0.43 ]			Alto	Trapezoidal	[ 0.65 1 ]
	Moderado	Triangular	[ 0.3 0.72 ]					
	Riesgo	Trapezoidal	[ 0.64 1 ]					

Rendimiento de cultivo	Superficie cosechada	Riesgo de cosecha						Superficie sembrada						Valor de producción									
		Inofensivo		Moderado		Riesgo		TB		TA		TB		TA		TB		TA		TB		TA	
		TB	TA	TB	TA	TB	TA	TB	TA	TB	TA	TB	TA	TB	TA	TB	TA	TB	TA	TB	TA	TB	TA
		E	Alto	E	Alto	E	Alto	E	Alto	E	Alto	E	Alto	E	Alto	E	Alto	E	Alto	E	Alto	E	Alto
Alto	Alto																						
	Bajo																						
Medio	Alto																						
	Bajo																						
Bajo	Alto																						
	Bajo																						
Muy bajo	Alto																						
	Bajo																						
Ninguno	Alto																						
	Bajo																						

TB: Temporada baja    TA: Temporada alta    E: Esperado

Figura 32 Matriz de inferencia del modelo Vulnerabilidad de cultivo.

La Figura 33 describe gráficamente los conjuntos difusos correspondientes a cada variable lingüística del modelo difuso *Vulnerabilidad de cultivo*.

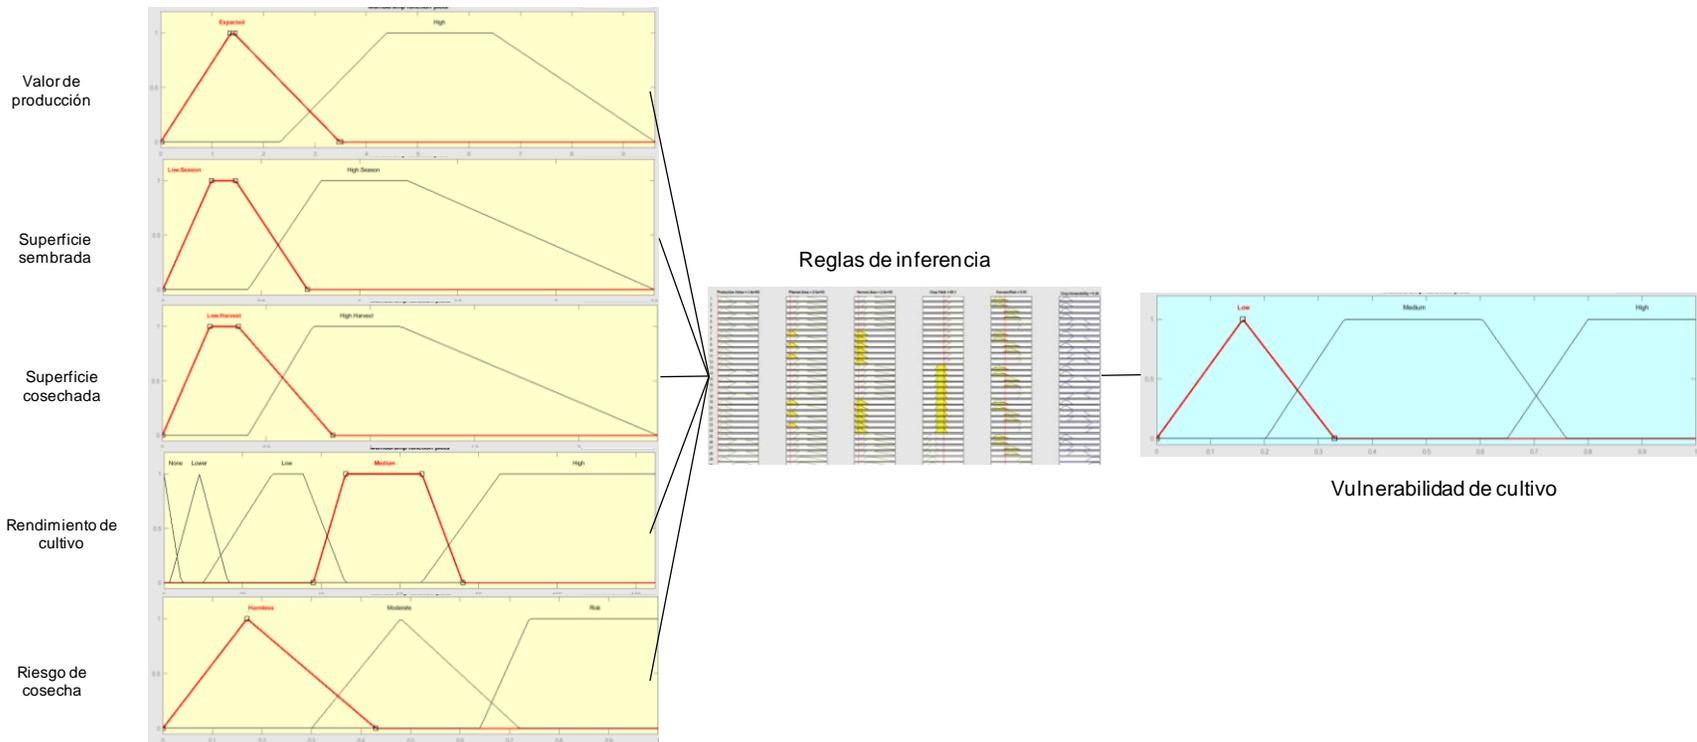


Figura 33 Representación gráfica del modelo Vulnerabilidad de cultivo.

#### 4.3.1.4. Modelo de eficiencia del uso de suelo (agente reactivo)

El modelo difuso denominado *Desordenes no nutricionales* ocupa el rol de *Agente reactivo* cuya función es reaccionar a estímulos en el entorno (Sterling and Taveter, 2018); por lo que cuando el valor de vulnerabilidad sea  $\geq 0.54$  valor considerado como una vulnerabilidad “*media-alta*” el agente reactivo entra en función.

La relación del modelo de agente reactivo con respecto a la vulnerabilidad del cultivo es que a mayor eficiencia del suelo menor será la vulnerabilidad.

Los desordenes no-nutricionales son indicadores edáficos y de riesgo de anegamientos en el área agrícola (Stockdale and Watson, 2009). Las reglas son validadas mediante la experticia de resultados obtenidos de investigaciones previas sobre información geográfica y edáfica en la producción de caña de azúcar en México (PRONAC et al., 2009).

En la Tabla 21 se describen los parámetros del diseño del modelo “*Desordenes no nutricionales*”.

Tabla 21 Modelo Desordenes no nutricionales: conjuntos difusos e intervalos de operación

Entrada (I)				Base de conocimiento	Salida (O)			
Variable	Conjuntos difusos				Variable	Conjuntos difusos		
	Etiqueta	Función de pertenencia	Intervalo			Etiqueta	Función de pertenencia	Intervalo
PMP Punto de marchitamiento	Bajo	Triangular	[ 0 28 ]	72 Reglas de inferencia	Eficiencia de suelo	Óptima	Trapezoidal	[ 0.55 1 ]
	Óptimo	Trapezoidal	[ 22 73 ]					
CE Conductividad eléctrica (dS/m)	Min	Trapezoidal	[ 0 0.19 ]			Media	Triangular	[ 0.19 0.72 ]
	Med	Trapezoidal	[ 0.1 0.9 ]					
	Max	Trapezoidal	[ 0.73 1.6 ]					
pH	Min	Triangular	[ 0 4.8 ]			Pobre	Triangular	[ 0 0.28 ]
	Med	Triangular	[ 3.5 6.5 ]					
	Max	Triangular	[ 5.4 7.4 ]					
MO% Materia orgánica	Medio	Trapezoidal	[ 0 5.7 ]					
	Máximo	Trapezoidal	[ 4.2 10.8 ]					
Int.Acidez Acidez intercambiable cMol*Kg <sup>-1</sup>	Medio	Triangular	[ 0 0.22 ]					
	Máximo	Triangular	[ 0.1 0.6 ]					

La Figura 34 describe gráficamente los conjuntos difusos correspondientes a cada variable lingüística del modelo difuso *Eficiencia de suelos (Agente Reactivo)*.

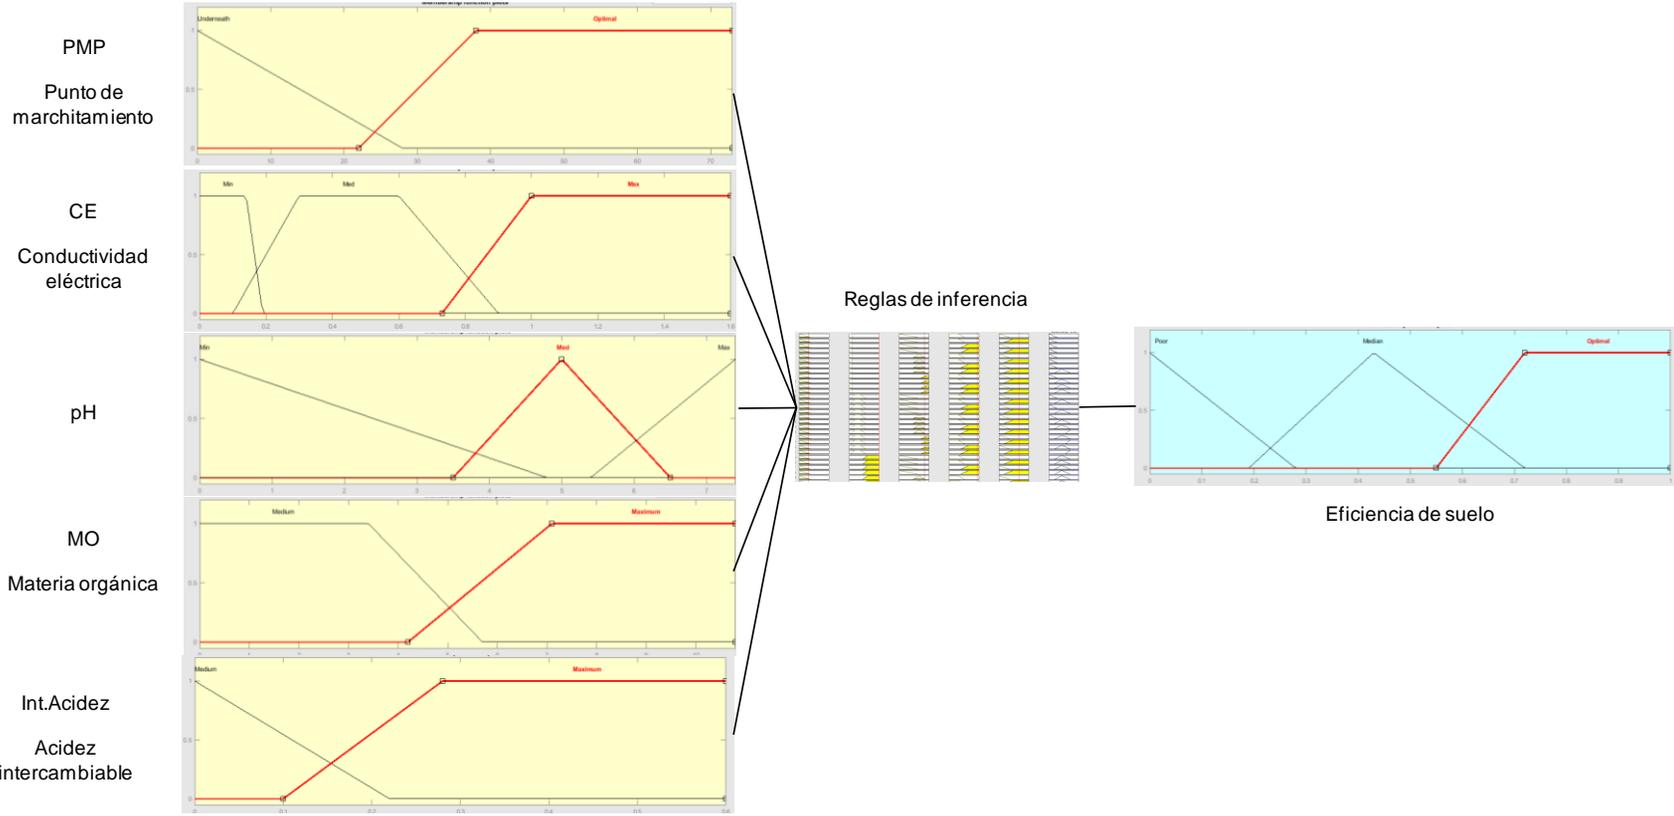


Figura 34 Representación gráfica del modelo difuso Desordenes no nutrimentales.

La Figura 35 muestra gráficamente las 72 reglas de inferencia obtenidas en el modelo. Las reglas son validadas mediante la experticia de resultados obtenidos de investigaciones previas sobre información geográfica y edáfica de la agricultura de la caña de azúcar en México (PRONAC et al., 2009).

PMP	CE	Medio						Máximo						Int.Acidez
		Medio			Máximo			Medio			Máximo			MO
		Min	Med	Max	Min	Med	Max	Min	Med	Max	Min	Med	Max	pH
Óptimo	Max													
	Med													
	Min													
Bajo	Max													
	Med													
	Min													

Figura 35 Matriz de inferencia del modelo Desordenes no nutrimentales (Agente reactivo).

#### 4.4. Etapa 3. Desarrollo del modelo de riesgo agrícola a través del procesamiento de imágenes

Actualmente, en México los sistemas agrícolas cuentan con acceso a servicios de información geográfica, el cual muestra de manera detallada zonas desérticas, vegetación de suelos, etc. (Semini, 2016). La información satelital sirve de apoyo a organismos como: Servicio de Información Agroalimentaria y Pesquera, Comisión Nacional del Agua, Servicio Meteorológico Nacional, entre otros.

El procesamiento de imágenes permite identificar zonas de interés que pudieran poner en riesgo al cultivo agrícola mediante el desarrollo de algoritmos.

##### 4.4.1. Selección de variables a evaluar

Para construir el modelo de riesgo se seleccionaron dos variables de interés a evaluar: temperatura y precipitaciones.

La temperatura es un factor asociado al crecimiento y desarrollo de la planta teniendo valores óptimos de entre 25~38 °C, valores fuera de este rango repercuten durante el rebrote o formación de la caña de azúcar. Valores por encima de 38°C reducen el proceso

de fotosíntesis del cultivo, alterando la concentración de sacarosa. Además de la temperatura, la velocidad de vientos es un factor determinante que incrementa el riesgo de cosecha; en áreas agrícolas con presencia de vientos fuertes la pérdida de agua es alta por la rápida evaporación a nivel del suelo.

Los requerimientos hídricos en la etapa de crecimiento del cultivo de caña de azúcar son mayores respecto a otros cultivos. Tan solo entre el 50-70% de agua es distribuido en los primeros 30 cm, siendo esta zona donde existe una mayor absorción de nutrientes y agua. En periodos de sequía donde prevalecen condiciones con niveles de humedad baja, la raíz del cultivo tiende a crecer más en profundidad buscando recurso hídrico, lo cual origina mayor concentración de agua en la raíz y en menor cantidad en el resto de la planta disminuyendo la capacidad productiva del cultivo.

Las variables fueron seleccionadas con base a resultados obtenidos en las superficies de respuesta del modelo difuso *Rendimiento de cultivo* desarrollado en la etapa 2 (ver sección 5.3).

#### **4.4.2. Recopilación de imágenes**

En México, la Estación Virtual de Imágenes Satelitales de Muy Alta Resolución (EVISMAR) es la encargada de recibir imágenes satelitales gracias al satélite “GeoEye-1”, además se encarga del procesamiento de imágenes para ser utilizadas de acuerdo a las funciones de la Secretaría de Marina (SEMAR) y del Instituto Nacional de Información Geográfica (INEGI). Actualmente, EVISMAR se encuentra en operación bajo personal capacitado en las áreas de ingeniería de sistemas y ciencias de la tierra (SEMAR, 2105).

Los satélites de “órbita baja” se caracterizan por sobrevolar la Tierra en un rango de 200-1200 km en un lapso de entre 90-300 minutos, lo cual los hace idóneos para detectar zonas de incendios y estudiar la capa de ozono. Por su parte los satélites de “órbita alta” ( $\geq 35,800$  km) se utilizan para estudios de meteorología.

La Figura 36 muestra la clasificación de los satélites de teledetección.

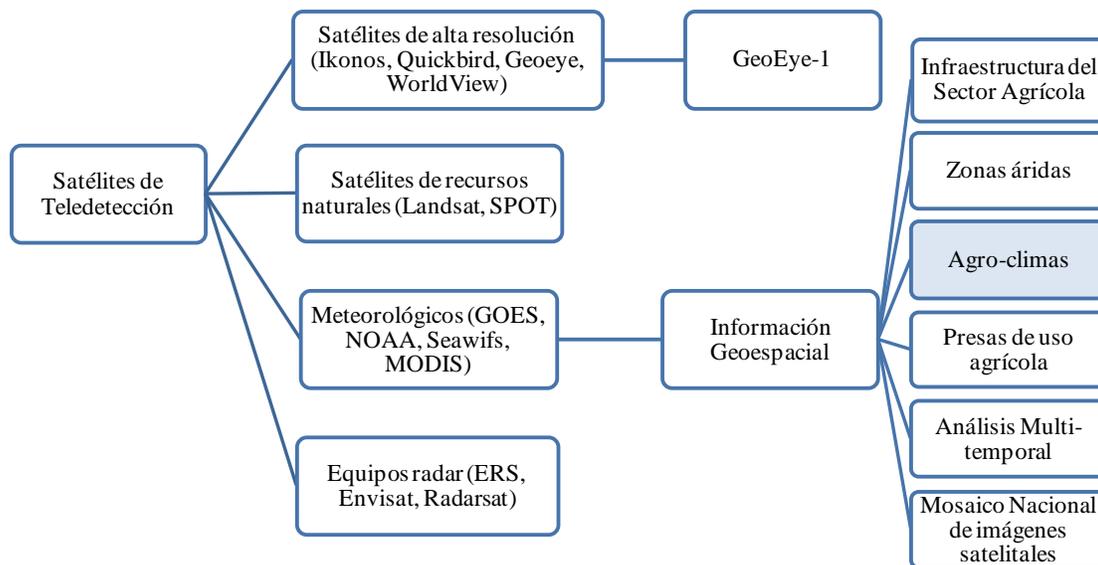


Figura 36 Clasificación de satélites de teledetección más comunes (Seminis, 2016; SIAP, 2016a; Vázquez et al., 2015).

Para propósitos de esta investigación, se optó por la utilización de información geoespacial proporcionada por Agro-climas, debido a que éste cuenta con información satelital de las variables de interés a evaluar: temperatura y precipitación. Las imágenes recopiladas se obtuvieron del Sistema Nacional Meteorológico, las cuales son producidas por el satélite GOES Este. La zona de interés corresponde a la región sureste que abarca el estado de Veracruz y la zona de estudio (Figura 37), en donde se seleccionó el canal RGB dado que es el que mayor nitidez y resolución de imágenes presenta para fines del análisis.



Figura 37 Imagen satelital en el umbral RGB del Sistema Nacional Meteorológico (SNM)

Posteriormente, se capturaron imágenes de las variables “temperatura” y “precipitación” durante un lapso de 60 días. En las siguientes figuras se indica la zona de interés a evaluar correspondiente a cada color para las variables temperatura (Figura 38) y precipitación (Figura 39).

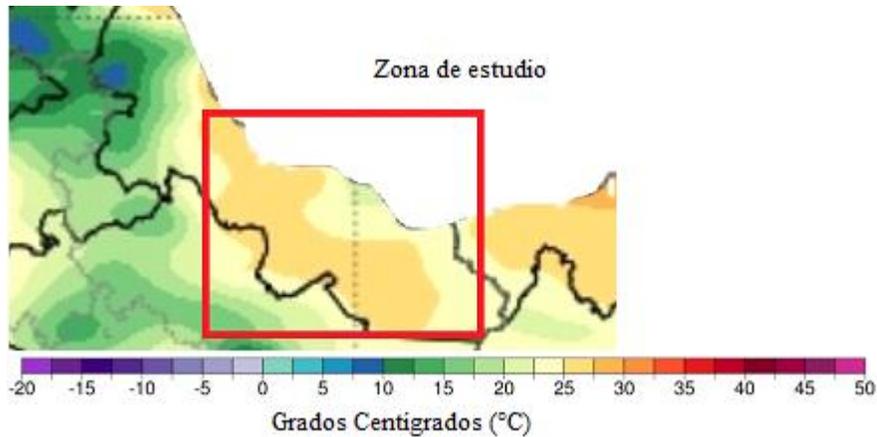


Figura 38 Imagen satelital para la variable temperatura

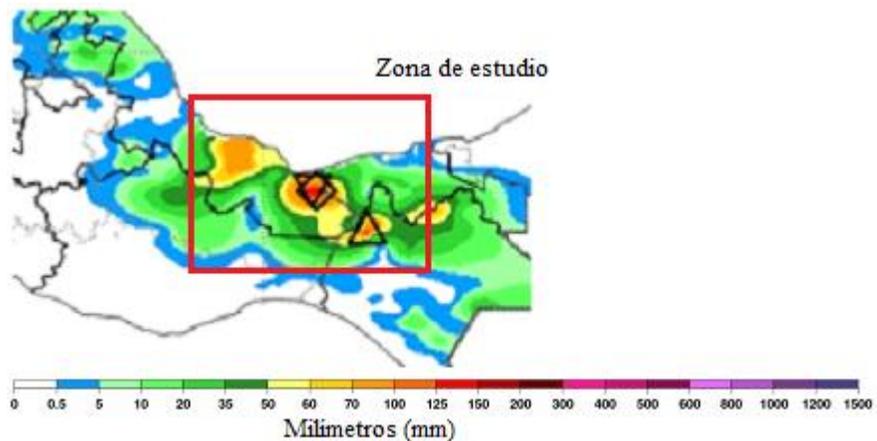


Figura 39 Imagen satelital para la variable precipitación

Las escalas correspondientes para cada imagen, señalan el espectro de interés para la variable temperatura que oscila del rango de color naranja en adelante ( $>32^{\circ}\text{C}$ ) debido a que como se mencionó anteriormente, valores por encima de esa temperatura podrían poner potencialmente en riesgo el cultivo. De igual modo, para la variable precipitación, los valores por debajo de 70 mm (color naranja) causan concentraciones de agua mayormente en la raíz y en menor proporción en otras partes de la planta disminuyendo la capacidad productiva del cultivo.

Una vez obtenidas las bases de datos para cada imagen, se realizó un pre-procesamiento de la imagen para eliminar las zonas de fondo que pudieran interferir en los canales RGB

de cada imagen. El procesamiento o tratamiento de imágenes se realizó en el software MatLab®, en la sección de “Apps” con la herramienta *Thershoud* en el canal  $L^*a^*b$ , al ser un canal uniforme mediante el cual se puede representar el color en un objeto, se utiliza mediante correlaciones de valores numéricos de color, haciéndolo el más consistente para la percepción visual humana.

La Figura 40 muestra una representación gráfica del canal  $L^*a^*b$ .

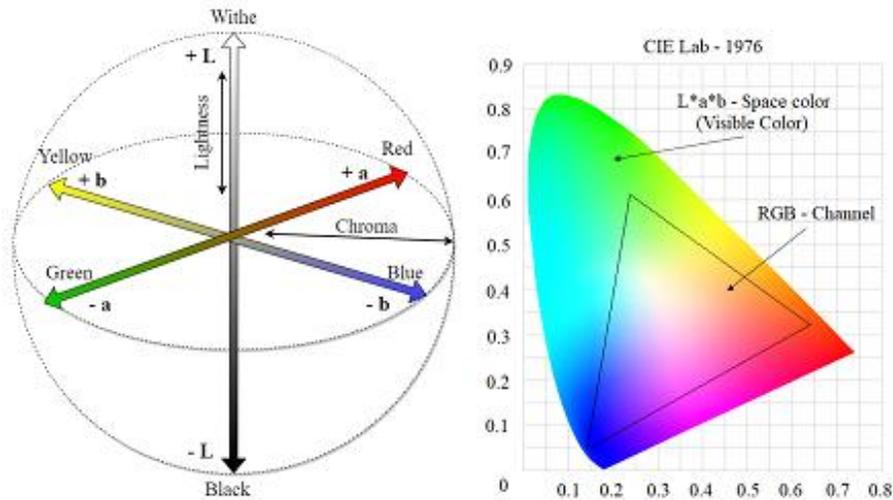


Figura 40 Canal  $L^*a^*b$

Donde,

$\Delta L^*$  = Luminosidad, diferencia entre la luz y la oscuridad de un objeto

$\Delta a^*$  = Diferencia entre los colores rojo y verde (+ rojo, -verde)

$\Delta b^*$  = Diferencia entre los colores amarillo y azul (+ amarillo, -azul)

La finalidad de suprimir el fondo blanco, es eliminar el “color”, debido a que al aplicar el canal RGB, el software podría reconocer algún “punto de color” en el área de fondo. Las Figura 41 y Figura 42 muestran la conversión del fondo y el canal  $L^*a^*b$  del área a estudiar para las variables temperatura y precipitaciones, respectivamente.

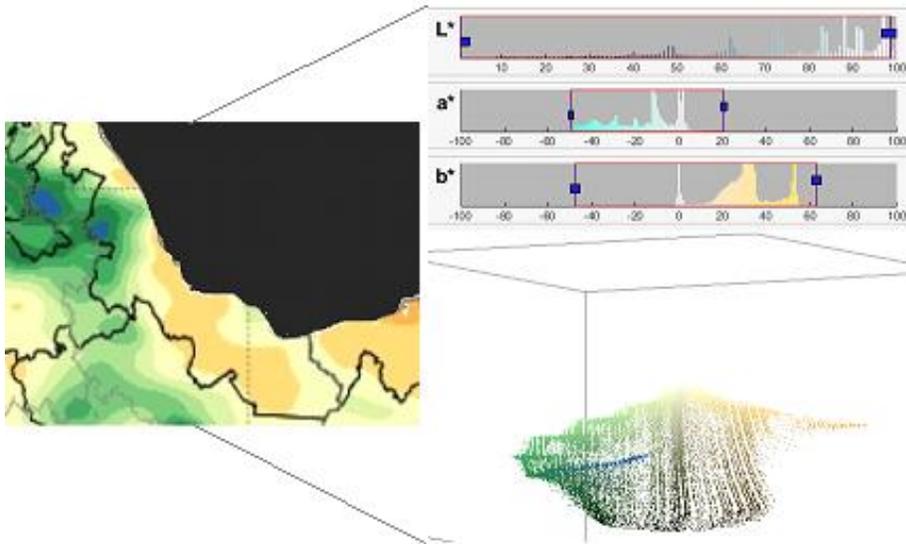


Figura 41 Canal  $L^*a^*b^*$  de la variable temperatura

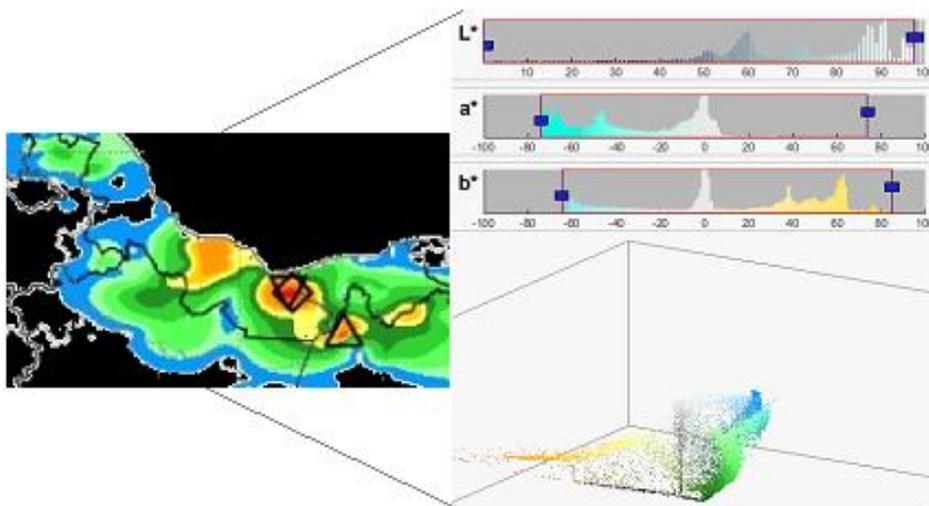


Figura 42 Canal  $L^*a^*b^*$  de la variable precipitación

#### 4.4.3. Procesamiento de imágenes

La metodología empleada en el procesamiento de imágenes consta de siete etapas (Figura 43), la primera etapa “pre-procesamiento” se realizó en la sección 4.4.2. Posteriormente se realizó la carga de imágenes pre-procesadas en MatLab®, para continuar con las etapas: captura de imágenes en negativo, aplicación de filtro, aplicación de threshold mask, resolución para mejorar imágenes, las cuales constituyen el procesamiento

digital de imagen (DIP); por último se realizó la detección de imágenes a través de Deep Learning mediante la creación de una Red Neuronal Convolutiva (CNN).

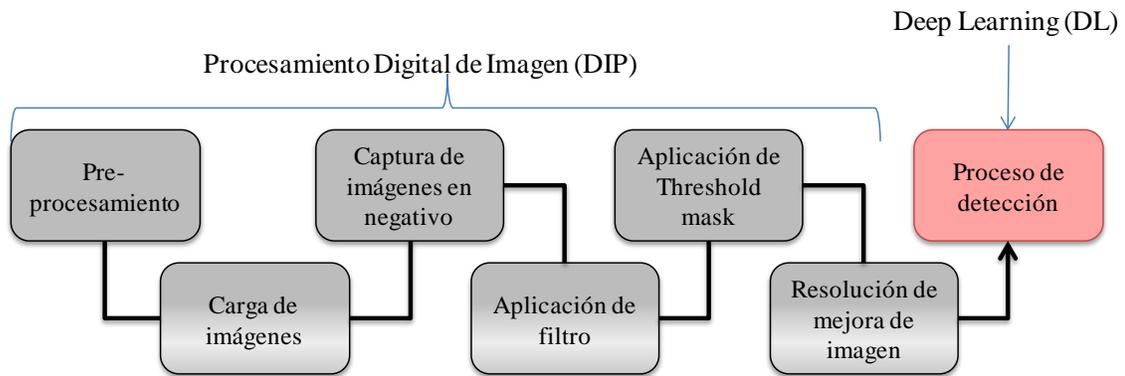


Figura 43 Metodología empleada en el procesamiento de imágenes

#### 4.4.3.1. Captura de imágenes en negativo

En la captura de imágenes en negativo, la imagen debe ser binarizada; para ello, se determina la escala de color (RGB) en que oscilan los píxeles de la zona de interés. Una imagen está constituida por un grupo de píxeles, a los cuales se les denomina como la unidad elemental de análisis contenida en una imagen y se representan a través de escala de grises y colores. La escala de grises oscila entre valores de  $[0, 255]$  que van desde el color negro hasta el color blanco. Mientras que los píxeles a color son representados a través de espacios de color tal como el canal RGB. La Tabla 22 muestra la codificación de cada color.

Tabla 22 Codificación de la escala de color en el canal RGB

Color	Vector RGB
Negro	[ 0 0 0]
Rojo	[255 0 0]
Azul	[0 0 255]
Marrón	[128 0 0]
Amarillo	[255 255 0]
Blanco	[255 255 255]
Verde	[0 255 0]
Fucsia	[255 0 255]
Morado	[128 0 128]
Azul marino	[0 0 128]

Para la detección de la codificación de los píxeles en el área de interés del canal RGB, se empleó la función “*imtool*” de MatLab (Figura 44).



Figura 44 Codificación de pixeles de la zona de interés de la variable temperatura

La figura anterior, el vector de color oscila entre 120-250 correspondiente a tonalidades marrones-rojizas.

La Figura 45 muestra la “codificación de pixeles” en la región donde hay menos niveles de precipitación que pudiesen afectar la reproducción y crecimiento del cultivo de caña de azúcar (< 50 mm). En la imagen se observa que la zona de interés se encuentra entre el rango 71-249 oscilando entre los colores azul y verde.

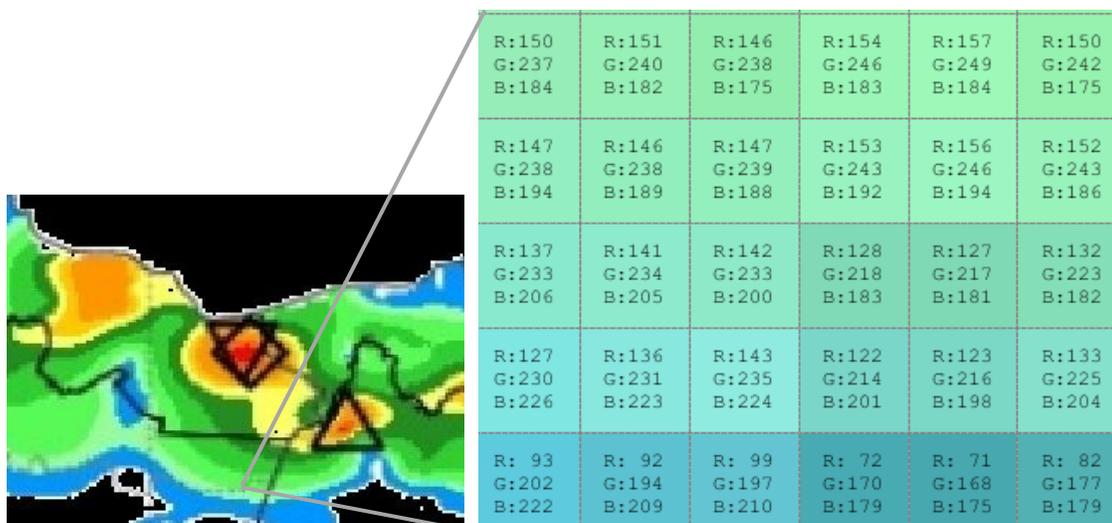


Figura 45 Codificación de pixeles de la zona de interés de la variable temperatura

Posteriormente, se aplicó la escala RGB para determinar bajo que umbral oscilan los pixeles en la zona de riesgo en ambas variables. Las Figura 46 y Figura 47, muestran los resultados obtenidos en los canales RGB para las variables, temperatura y precipitación, respectivamente.

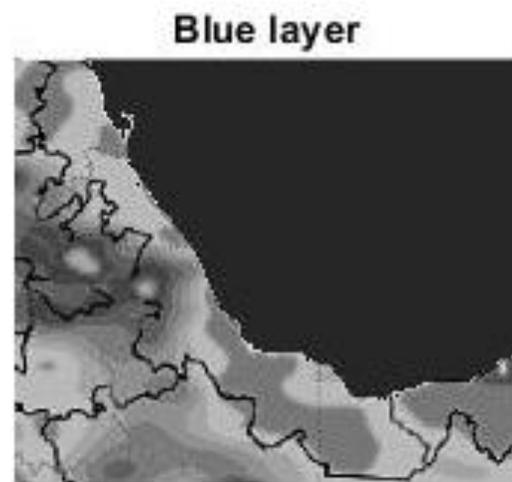
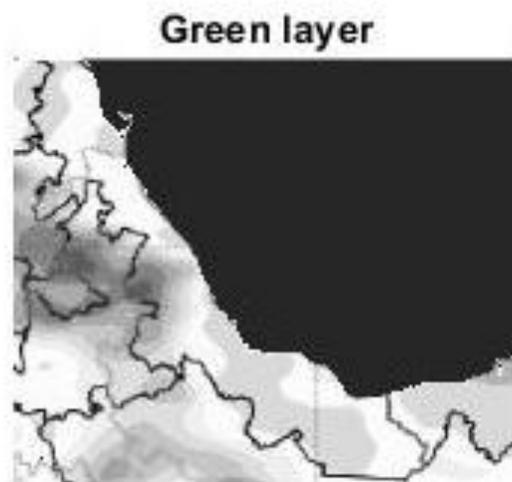
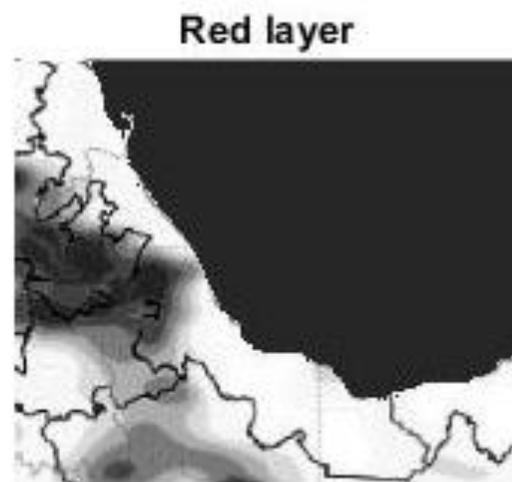
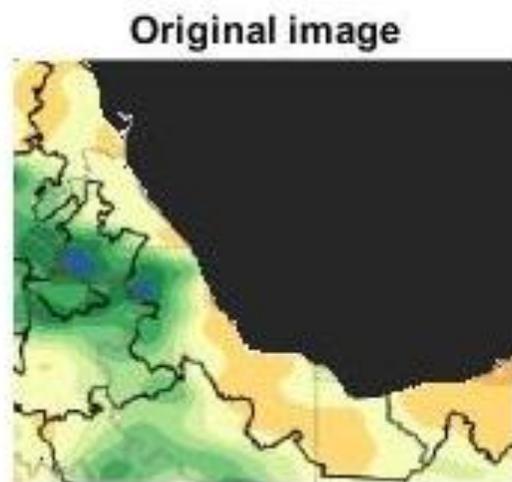


Figura 46 Canal RGB para la variable temperatura

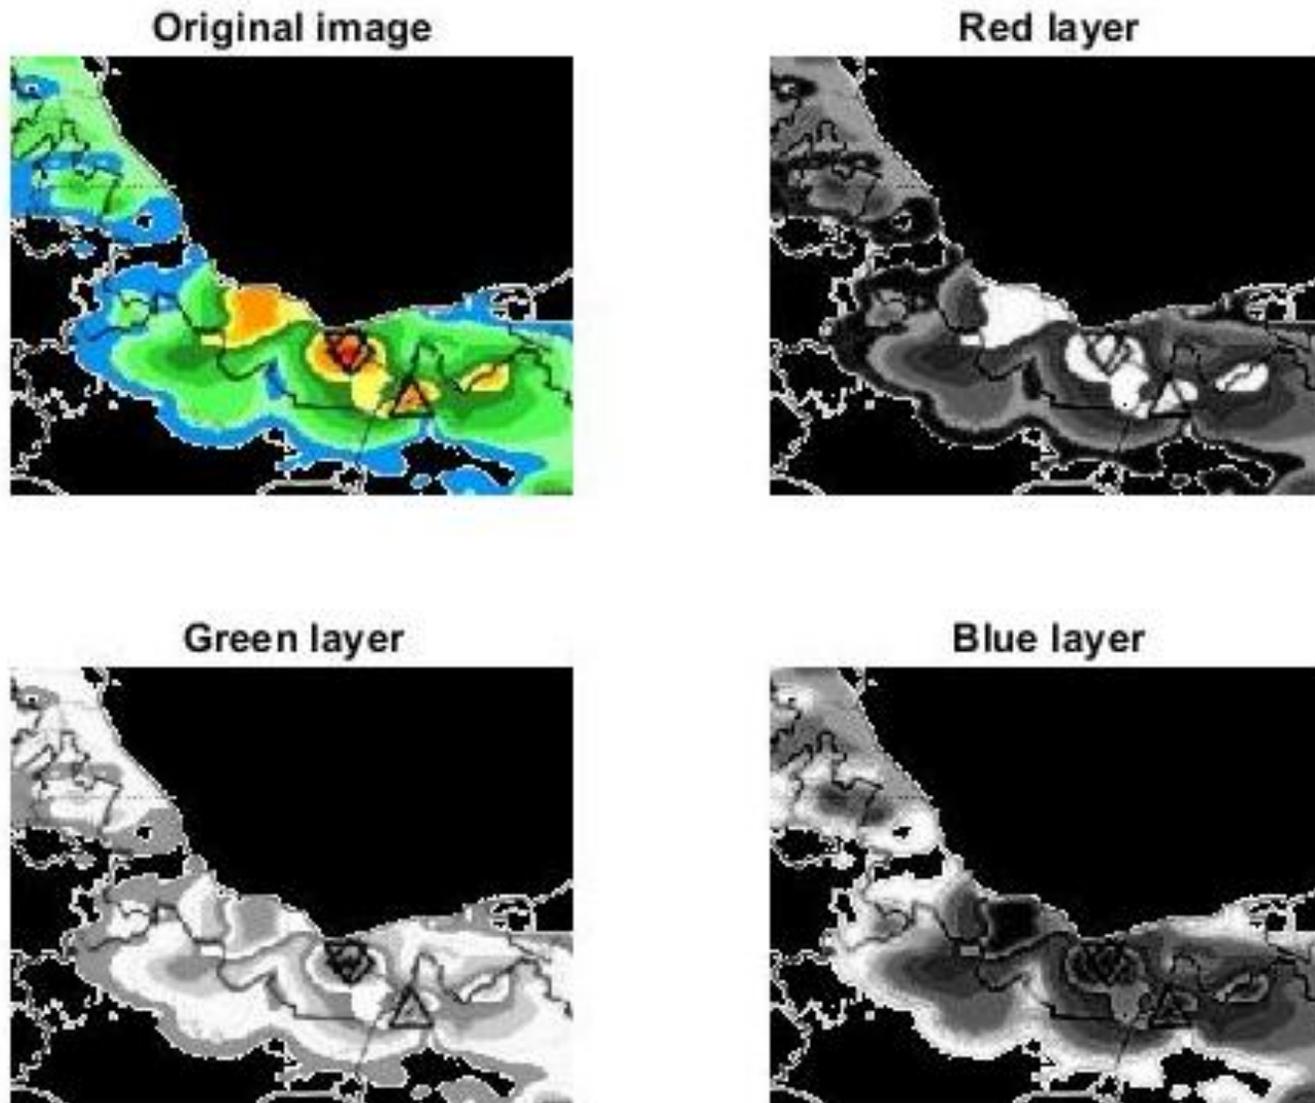


Figura 47 Canal RGB para la variable precipitación

En la Figura 46, para la variable temperatura, se observa que en el canal rojo (R), el área objetivo se acerca más al blanco, lo que indica que ésta se compone en su mayoría de color rojo. Mientras que para la variable precipitación (Figura 47) el área objetivo es en el canal verde (G) donde se acerca más al color blanco. Por lo que para el procesamiento de imágenes se selecciona el canal rojo para la variable temperatura y verde para precipitación.

El análisis de captura de imágenes en negativo permite una mejor interpretación de la imagen, donde el objetivo aumenta su definición, lo que favorece a una mejor interpretación de los colores contenidos en la imagen por parte del software.

En las Figura 48 y Figura 49, se observa la evaluación del punto de intercepción específico entre la zona de riesgo y las demás áreas en sus valores RGB después de haber aplicado la captura negativa, obteniéndose una mayor definición en la separación de la zona de estudio en relación a las regiones circundantes, permitiendo al software lograr una mejor comprensión de los colores para segmentar e identificar las zonas de riesgo; y posteriormente, lograr una entrenamiento más óptimo de la red neuronal.

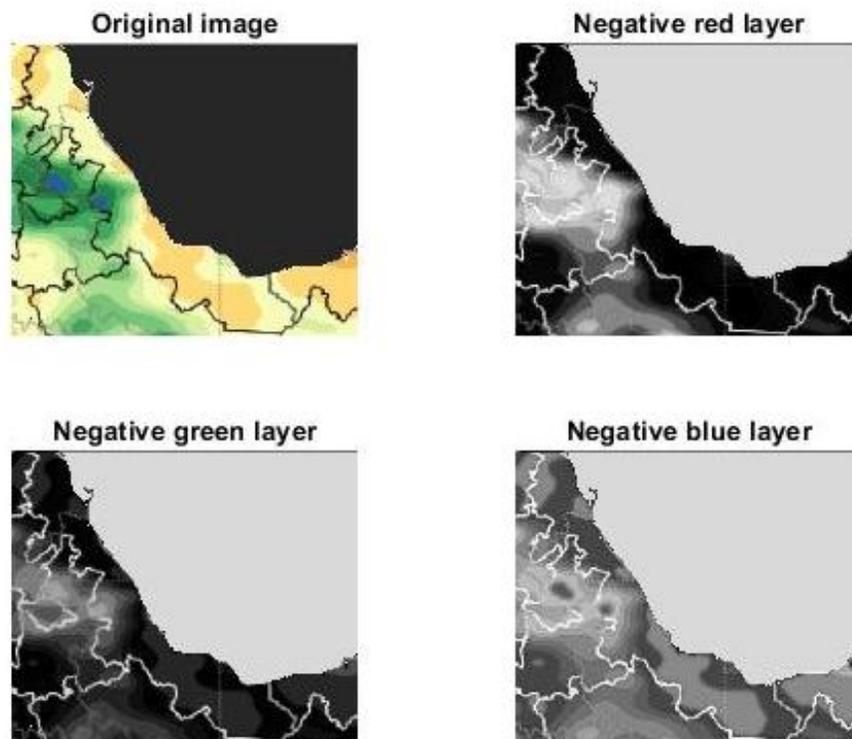


Figura 48 Captura de imagen en negativo para la variable temperatura

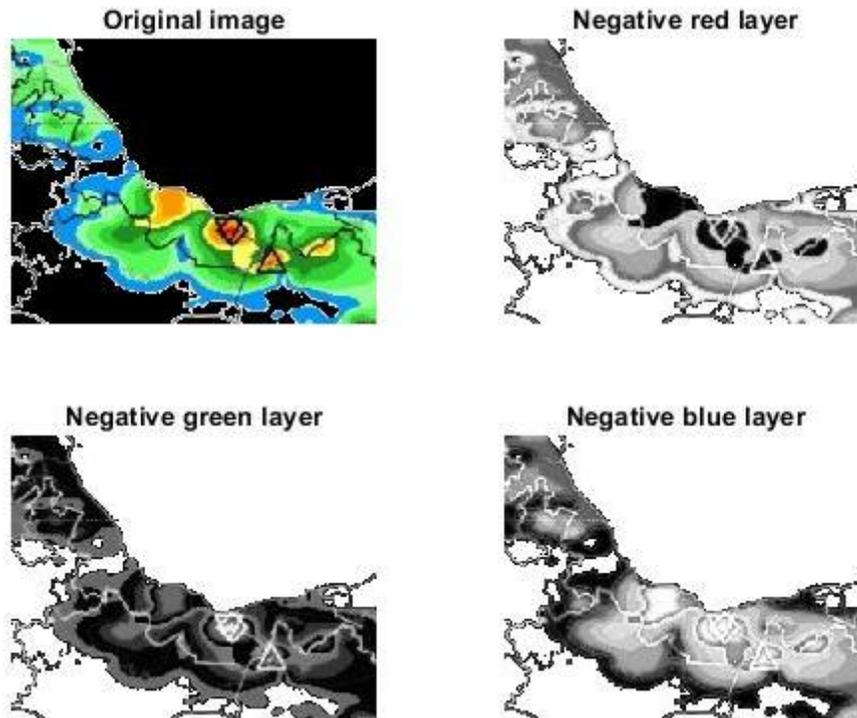


Figura 49 Captura de imagen en negativo para la variable precipitación

La codificación empleada en MatLab para la obtención de imágenes en negativo, se muestra a continuación.

```
f=imread('Temprature1.jpg'); Ó f=imread('Precipitation1.jpg');

%Pixel definition in interest area:

imtool(f)

%RGB scale:

R=f(:,:,1);
G=f(:,:,2);
B=f(:,:,3);

figure(1), subplot(2,2,1), imshow(f), title('Original image')
figure(1), subplot(2,2,2), imshow(R), title('Red layer')
figure(1), subplot(2,2,3), imshow(G), title('Green layer')
figure(1), subplot(2,2,4), imshow(B), title('Blue layer')

%Negative image

NR=imadjust(R, [0 1], [1 0]);
imshow(NR)
```

```

NG=imadjust(G, [0 1], [1 0]);
imshow(NG)

NB=imadjust(B, [0 1], [1 0]);
imshow(NB)

figure(2), subplot(2,2,1), imshow(f), title('Original image')
figure(2), subplot(2,2,2), imshow(NR), title('Negative red layer')
figure(2), subplot(2,2,3), imshow(NG), title('Negative green layer')
figure(2), subplot(2,2,4), imshow(NB), title('Negative blue layer')

```

#### 4.4.3.2. Aplicación de filtro

La principal problemática al realizar DIP es el “ruido”, puesto que dificulta el proceso de obtención de información. El ruido se define como *“la cantidad de defectos en los niveles de color en el proceso de captura de una imagen dando como resultados colores ó pixeles que no reflejan las intensidades del color del mundo real”*. Todas las imágenes poseen cierto grado de ruido, especialmente las obtenidas a través de satélites. El ruido en las imágenes en su mayoría es imperceptible sin inferir con el resultado final o extracción de información.

Para lograr una reducción de ruido, se recurre a la aplicación de filtros como: gaussiano, promedio, laplaciano y disco; cuyo propósito es elevar la calidad en la imagen. En el procesamiento de imágenes se optó por la implementación del filtro promedio.

El método de filtro promedio es un método de agrupación donde se calcula el promedio de un vector [i, j], este proceso busca la agrupación de un patrón de color dominante dentro de una matriz creando un filtro de dos dimensiones.

Este mismo proceso es repetido en toda la imagen para estandarizar las capas de color en una región dada, obteniendo los promedios de los pixeles; y con ello, el ruido es estandarizado al valor entero más cercano de la media.

Con la “prueba y error” se determinó que la media dentro del vector [10 10] proporciona el valor óptimo disminuyendo gran parte del ruido de la imagen para ambas variables de interés. A continuación se muestra la ecuación del filtro promedio; donde  $h$  es el Kernel de correlación.

Ecuación 22

$$h = \left( n(1), \frac{n(2)}{n(1) * n(2)} \right)$$

Las imágenes satelitales suelen contener una mayor cantidad de ruido; por lo que se optó por realizar un ajuste al filtro para minimizar aún más los niveles de ruido contenidos en las imágenes.

Las Figura 50 y Figura 51 muestran una comparativa entre los filtros aplicados para las imágenes de las variables temperatura y precipitación, respectivamente.

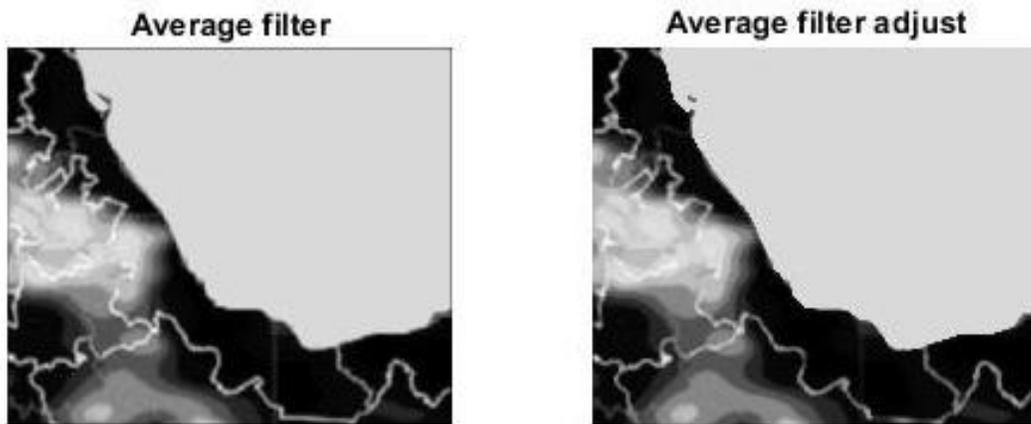


Figura 50 Aplicación de filtros en la imagen de la variable temperatura

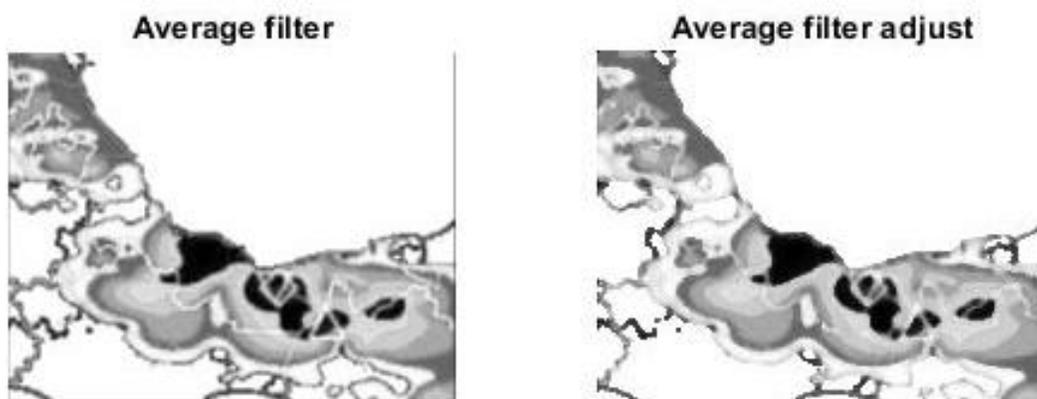


Figura 51 Aplicación de filtros en la imagen de la variable precipitación

En las figuras anteriores, se observa que tras la aplicación de los filtros, se pierde resolución o detalle con respecto a las imágenes originales, debido al estandarizado de las regiones en un grupo de píxeles donde los bordes que definen a la imagen no son dominantes y, como consecuencia son absorbidos por su entorno.

Lo anterior significa que aunque la definición se ha reducido en las imágenes, la obtención de información es más fácil, ya que los colores se han homogeneizado minimizando el ruido al mismo tiempo.

La codificación empleada en la aplicación de filtros, se describe a continuación.

```
%Average filter

AverageF=fspecial('average',6);
filter_media=imfilter(NR,AverageF);
filter_median=medfilt2(NR,[10 10]);

figure (3), subplot (1,2,1), imshow(filter_media), title('Average
filter')
figure (3), subplot (1,2,2), imshow(filter_median), title('Average filter
adjust')

figure (4), imshow(filter_median), title('Average filter adjust')
```

#### 4.4.3.3. Aplicación de Thershold mask

El objetivo de la implementación del *thershold mask*, es separar los colores contenidos en el área de estudio catalogada como riesgo, extrayendo solo la información requerida. Basándose en la lógica IF...THEN; es decir, si los niveles de color son diferentes al *thershold mask* entonces el color será cero perteneciente al color negro, de lo contrario se colocará el valor de 1 perteneciente a cualquier color perteneciente al negro. El *thershold mask*, como se mencionó anteriormente es una herramienta ubicada las aplicaciones de MatLab®.

Durante la ejecución del *thershold mask*, en la lógica implementada IF...THEN, se aplicó una máscara invertida, para resaltar las zonas de interés y facilitar la segmentación de las imágenes. De igual modo, la implementación de la máscara utilizó el umbral de color  $L*a*b$ .

La Figura 52 se muestra la interfaz del *thershold mask* en MatLab y la segmentación por color en el canal  $L*a*b$  para la variable temperatura.

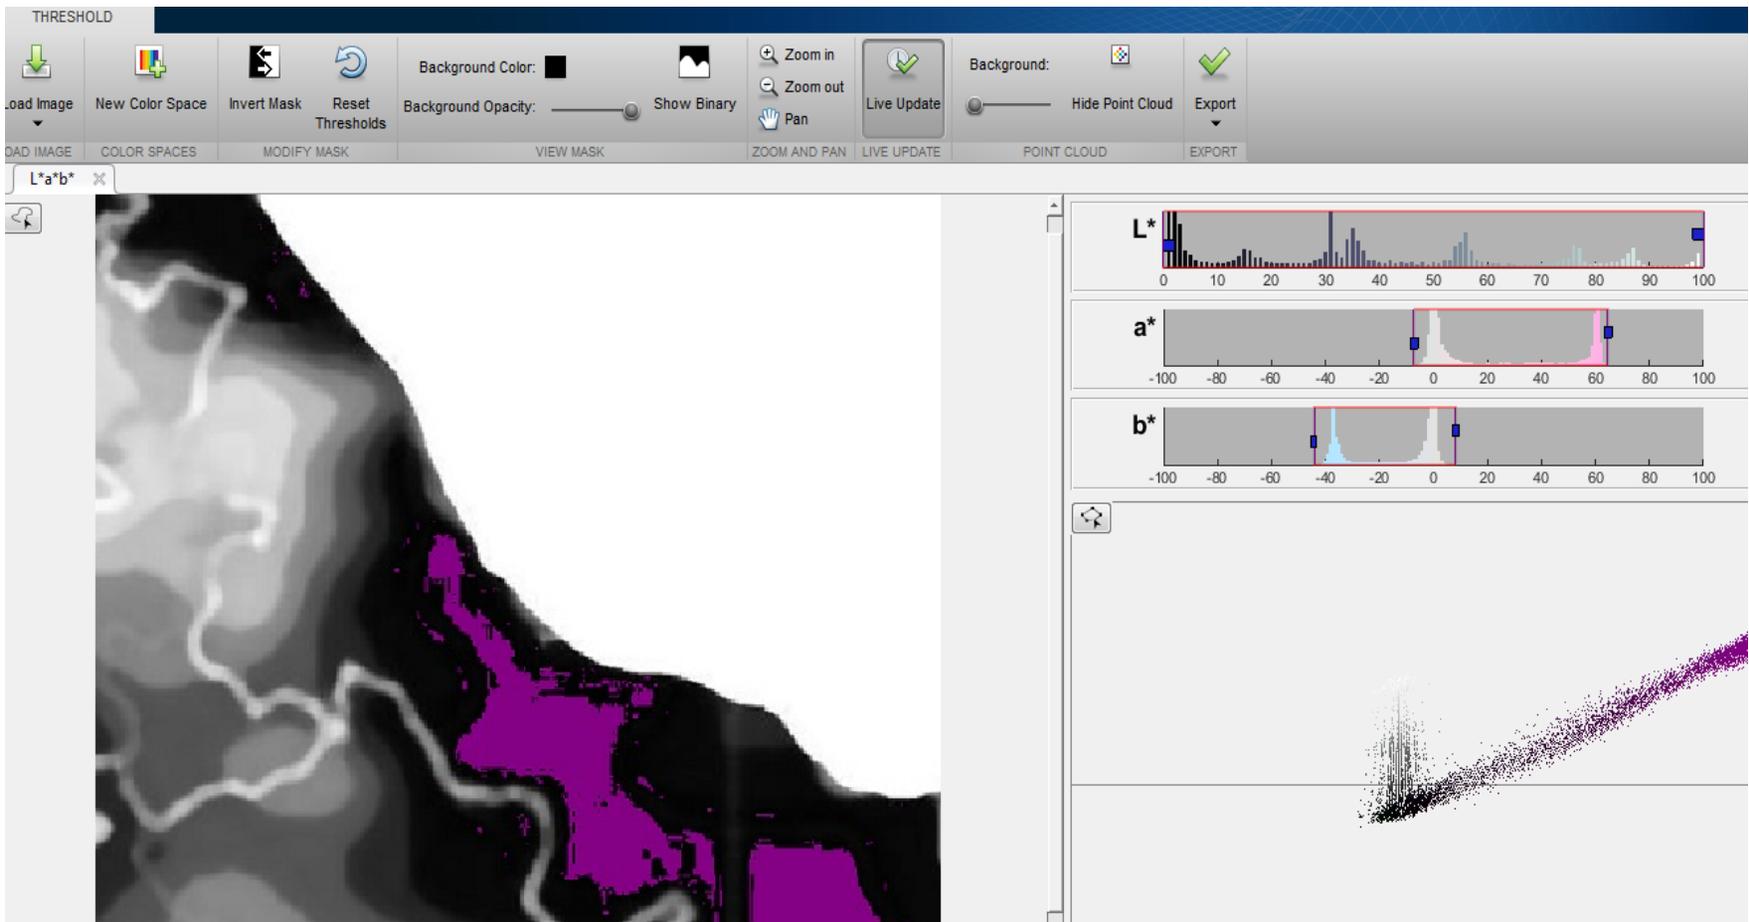


Figura 52 Implementación de *Thershold Mask* en la imagen de la variable temperatura

#### 4.4.3.4. Resolución de mejora de imagen

Finalmente, después de haber realizado el procesamiento de las imágenes se obtuvieron las características de interés, en este caso las zonas de riesgo para las variables: temperatura y precipitación. Para el proceso de obtención de información, una vez definido e identificado el objetivo, se procedió a realizar el mismo procedimiento para ambas variables; donde se realizaron 250 pruebas en diferentes imágenes con áreas de riesgo para determinar niveles de color estándar dentro del umbral  $L^*a^*b$ .

Dichos valores en el canal  $L^*a^*b$  representan la máscara, la cual permite identificar ciertas regiones de pixeles contenidas en la monocapa mediante la siguiente ecuación:

Ecuación 23

$$T_{global}(g) = \begin{cases} 0 & \text{if } g < t \\ 1 & \text{if } g \geq t \end{cases}$$

Donde,  $t$  es la máscara en el umbral de los niveles  $L^*a^*b$ .

La Figura 53, muestra la imagen correspondiente a la variable temperatura después de haber sido aplicada la máscara. Como se observa, el área sombreada en color morado representa las zonas de riesgo para el cultivo con temperaturas por encima de 35°C.

La Figura 54, muestra las zonas de riesgo para la caña de azúcar con respecto a niveles de precipitación observado. El color azul representa valores por debajo de 70 mm que podrían dificultar el crecimiento y reproducción del cultivo como resultado de la pérdida de fertilidad del suelo por la presencia y/o incremento de zonas áridas.

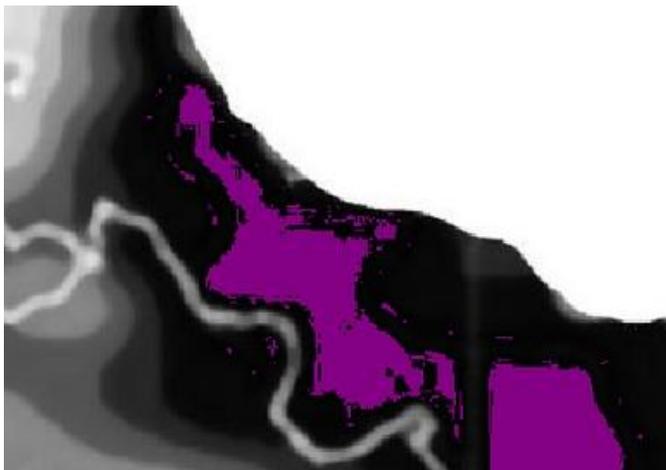


Figura 53 Imagen procesada de la variable temperatura

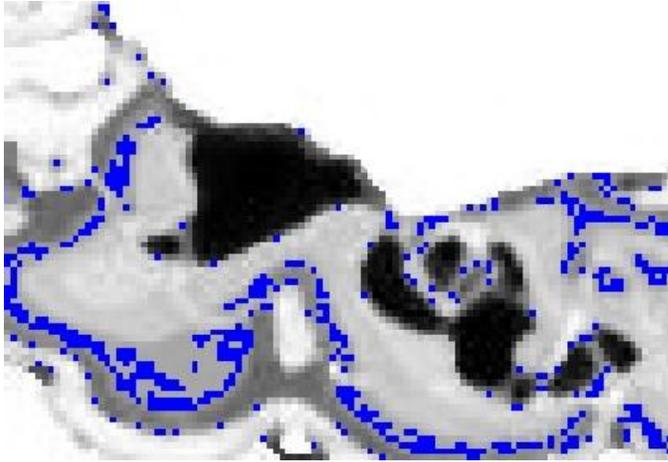


Figura 54 Imagen procesada de la variable precipitación

#### 4.4.3.5. Proceso de detección

Los sistemas que se basan en detección de imágenes generalmente se centran en la búsqueda y navegación dentro de una base de datos de imágenes, además del reconocimiento de ciertas características como color, textura y la ubicación espacial a nivel local o global dependiendo si se desea información de la imagen en su totalidad o de ciertas regiones. (Aparicio Martín de Loeches, 2014).

Dependiendo del método empleado, existen dos categorías: sistemas que asignan zonas de interés automáticamente (SDR) y sistemas con regiones de interés designadas por el usuario (UDR).

Ambos métodos tienen la capacidad de clasificar y recuperar información de ciertas regiones deseadas. Por su parte, los sistemas automáticos dividen las zonas de estudio a través de algoritmos para detectar picos; mientras que los sistemas manuales (UDR) se caracterizan por brindar alternativas para que el especialista sea quién seleccione la región de interés.

La problemática recurrente del uso de sistemas automáticos se basa en la presencia constante de ruido haciendo poco fiable la obtención de resultados. Mientras que la implementación de sistemas manuales permiten realizar modificaciones en el procesamiento de imágenes (binarización, reducción de ruido, suavizado, etc.) dependiendo de las necesidades y requerimientos del analista con el fin de obtener resultados más precisos y fiables.

Aún con el procesamiento de imágenes, existe la posibilidad de aparición de ruido en la imagen, por lo cual es necesaria la implementación de un algoritmo capaz de reducirlo al máximo. Existen técnicas de inteligencia artificial como el Deep Learning para el

reconocimiento objetivo a través grupos de imágenes, capaces de emular el proceso del aprendizaje humano. El proceso de DL se basa en el entrenamiento de Redes Neuronales Convolucionales (CNN's) las cuales extraen la información deseada.

Las CNN's se auxilian del Procesamiento Digital de Imágenes (DIP) para facilitar la extracción de información. La Figura 55 muestra las principales fases del DIP en la creación de una nueva imagen para conformar una nueva base de datos que servirá para entrenar la CNN.



Figura 55 Comparativa de las etapas del procesamiento de imágenes para la variable temperatura

El entrenamiento de las redes neuronales tienen como fin la extracción de ciertas características del objetivo como: posiciones, brillos, dimensiones, colores y formas. El Deep Learning emplea una red neuronal múltiple para extraer información mediante la interacción de pocas o cientos de capas aprendiendo a detectar diferentes características la imagen, esta red se le conoce como Red Neuronal Convolutiva.

#### 4.4.4. Desarrollo de la red neuronal convolucional (CNN)

La construcción de una red neuronal convolucional puede ser de dos formas; la primera *Training from scratch*, requiere de un nuevo algoritmo para detectar características específicas en una imagen y son necesarias miles o millones de imágenes para entrenar la red. La segunda es *Transfer Learning Training*, es a través del uso de una red previamente entrenada con una gran variedad de imágenes, la cual ha sido desarrollada para extraer información cuando se da el caso de tener un número limitado de imágenes; además, la principal ventaja es que el tiempo de entrenamiento es menor.

#### 4.4.4.1. Etiquetado de variables

En esta etapa se introducen las imágenes procesadas para etiquetar la zona de interés a través de la función *Image Labeler* en MatLab®. Para este proceso se etiquetaron 30 y 25 imágenes para las variables temperatura y precipitación, respectivamente.

Como se observa en la Figura 56, el procesamiento de imágenes permite la definición e identificación de la zona de interés (temperaturas por encima de 38° C) para obtener un etiquetado más preciso y confiable para la realización del entrenamiento de la red convolucional (CNN).

Para el etiquetado de la variable precipitación se empleó la misma función en MatLab® (Figura 56).

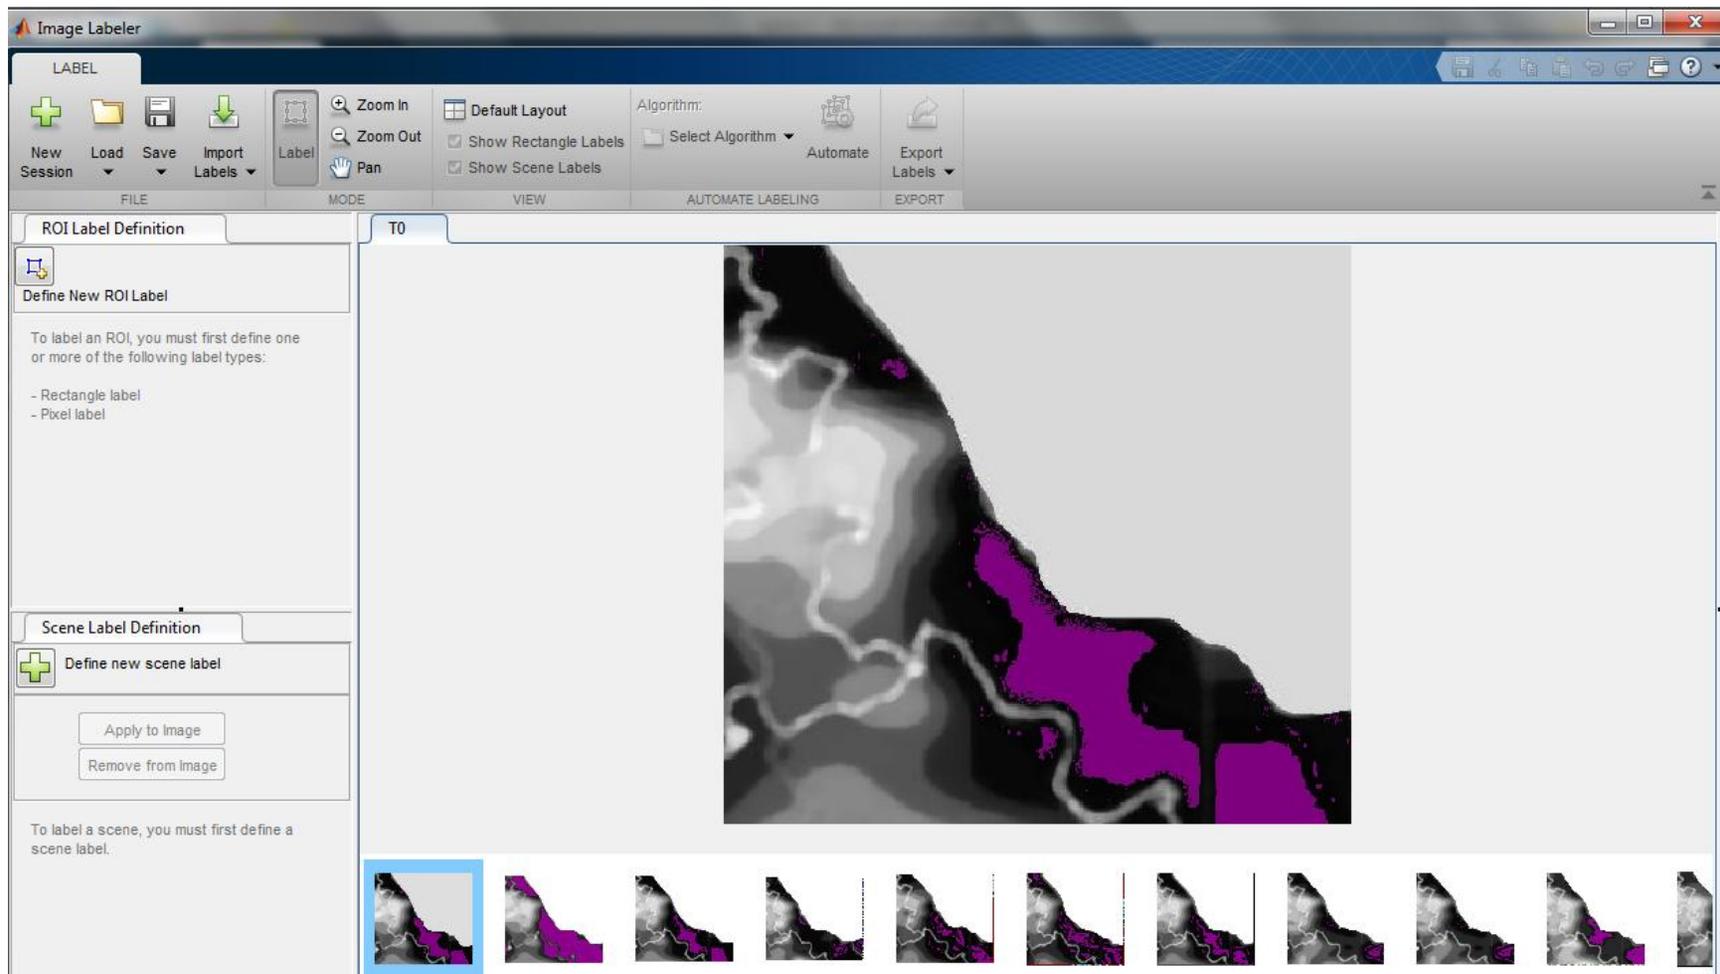


Figura 56 Definición de etiqueta para las variables (ejemplo variable temperatura)

Las Figura 57 y Figura 58 muestran la delimitación de etiquetas para ambas variables. Para cada zona de interés se asignó más de una etiqueta por imagen con el objetivo de tener una base de entrenamiento más robusta y facilitar el entrenamiento de la red.

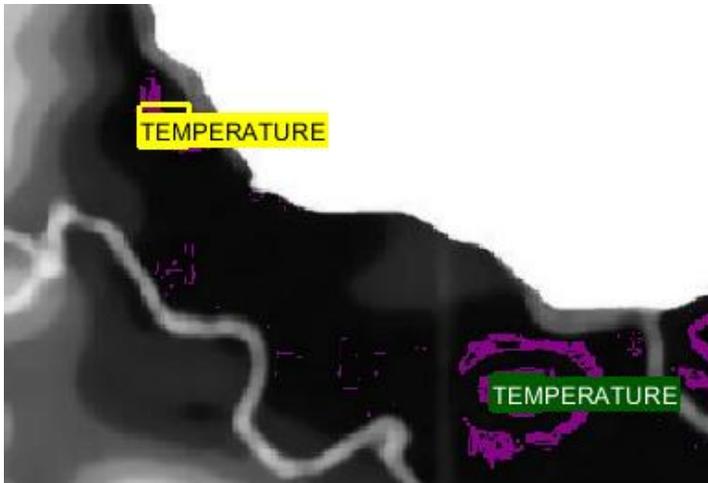


Figura 57 Asignación de etiquetas para la variable “Temperatura”

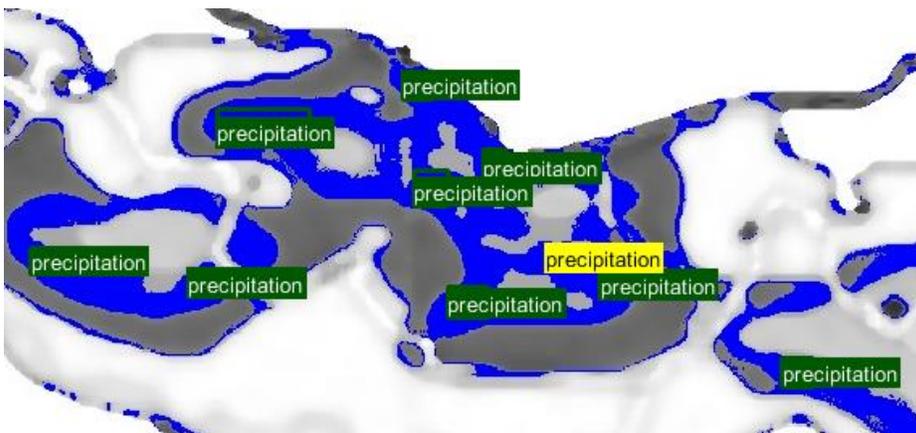


Figura 58 Asignación de etiquetas para la variable “Precipitación”

La asignación del etiquetado se realizó para las zonas más nítidas. Posteriormente, se guardaron las etiquetas para cada variable en formato de “tabla” exportándose al área de trabajo, posteriormente se entrenaron las redes. La Figura 59 muestra el proceso de exportación de la variable temperatura.

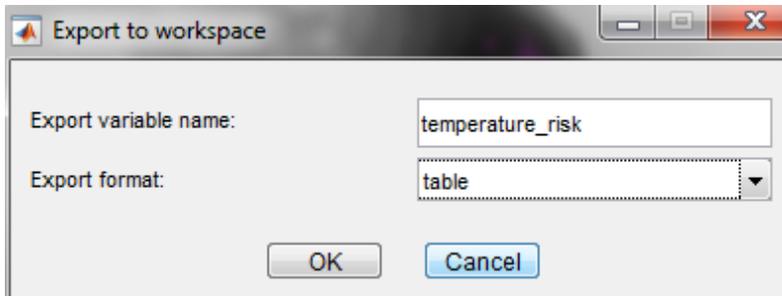


Figura 59 Exportación de la variable “Temperatura”

El código simplificado para la realización y entrenamiento de CNN se muestra a continuación. Para ambas redes se empleó el mismo código sustituyendo únicamente la variable deseada (temperatura/precipitación) en la detección del objetivo de entrenamiento.

```

"cc=alexnet;
ccl=cc.Layers;
cc=cc.Layers(1:23);
ccc=[cc
    fullyConnectedLayer(2)
    softmaxLayer()
    classificationLayer()];
options = trainingOptions('sgdm', ...
    'MiniBatchSize', 32, ...
    'InitialLearnRate', 1e-3, ...
    'MaxEpochs', 2);
rcnn1 = trainRCNNObjectDetector(temperature_risk / precipitation, ccc,
options, 'NegativeOverlapRange', [0 0.3]);"

```

Para el desarrollo de la CNN se empleó la extensión “alexnet”. AlexNet es una CNN que cuenta con 8 capas de profundidad; la cual, está “pre-entrenada” mediante una red conformada por más de un millón de imágenes ubicadas en “*ImageNet*”, en donde se pueden archivar más de mil categorías de imágenes de objetos.

#### 4.4.4.2. Prueba de la CNN

A continuación se muestra el código empleado para el proceso de prueba de la CNN. Para realizar la prueba se ingresaron imágenes de prueba para las variables “*temperatura*” y “*precipitación*” las cuales tuvieron un procesamiento previo. Las imágenes seleccionadas de prueba no fueron las empleadas en el etiquetado ni en el entrenamiento de las CNN’s con el objetivo de comprobar la certidumbre en las redes desarrolladas.

```
`test1=imread('PPrueba.jpg');  
[bbox, score, label] = detect(rcnn1, test1, 'MiniBatchSize',32);  
[score, idx] = max(score);  
bbox = bbox(idx, :);  
annotation = sprintf('%s: (Confidence = %f)', label(idx), score);  
detectedtest1 = insertObjectAnnotation(test1, 'Rectangle', bbox,  
annotation);  
  
figure  
  
imshow(detectedtest1)`
```

## Capítulo 5. Resultados

### 5.1. Perfil de cambio climático

La agricultura mexicana es vulnerable al cambio climático debido a diversos factores para los productores y campesinos agrícolas; lo cual, representa una amenaza latente en la seguridad alimentaria.

Las afectaciones generadas por cuestiones climáticas son distintas para cada región debido a sus características sociales, edáficas, económicas y ambientales. La implementación de medidas de adaptación es diferente para cada caso, pues la capacidad de respuesta varía en torno a las características de cada región.

Regiones ubicadas al norte de México presentan incremento en sequías resultado de temperaturas altas predominantes; por su parte la zona centro presenta incremento en eventos como inundaciones y heladas, mientras que en la zona sur prevalece la incidencia de lluvias extremas, huracanes y ciclones (Eakin, 2000). El incremento de este tipo de fenómenos advierte un panorama poco favorable para el sector agrícola.

Proyecciones desarrolladas muestran incrementos exponenciales en las temperaturas durante los próximos cien años tanto a nivel nacional como mundial (Solomon, S. et al., 2007). Estos incrementos de temperatura en regiones norte del país (Chihuahua, Aguascalientes, Nuevo León y Sonora) podrían alcanzar incrementos de  $\approx 2-4^{\circ}\text{C}$  trayendo consigo olas extremas de calor afectando gradualmente el rendimiento de cultivos y mortalidad en el sector pecuario. Sin embargo, regiones como Tlaxcala podrían verse beneficiadas por el aumento de temperaturas mínimas nocturnas dado que la presencia de heladas afecta gravemente los cultivos (Conde and Eakin, 2003).

En los niveles de precipitación, se esperan incrementos en la frecuencia de eventos de lluvias extremas, ciclones y huracanes originados principalmente por la retención y acumulación de agua en la atmósfera. Sin embargo; estos fenómenos podrían ser contrarrestados a través de la evapotranspiración, proceso en el cual la el agua de la superficie se evapora producto de altas temperaturas.

Estudios realizados por National Center for Atmospheric Research, NCAR (Centro Nacional para la Investigación Atmosférica de los Estados Unidos) en el año 2010, mostraron predicciones para zonas con declive pluvial y temperaturas altas, señalando presencia de “sequías de tipo cambio-global”; es decir, incremento sequías más prevalecientes e intensas. En la Figura 60 se puede observar la presencia de este tipo de “sequías severas” en México, así como una reducción en niveles de precipitación (Greenpeace, 2017).

El mapa emplea el “índice de severidad de sequía de Palmer”, el cual asigna valores positivos (+) cuando existen anomalías en la humedad para cierta región y valores negativos (-) cuando las zonas son extremadamente secas. Las zonas de color verde-azul tienen menor probabilidad de riesgo de sequía, las zonas rojas-moradas representan probabilidad alta de sequía extrema.

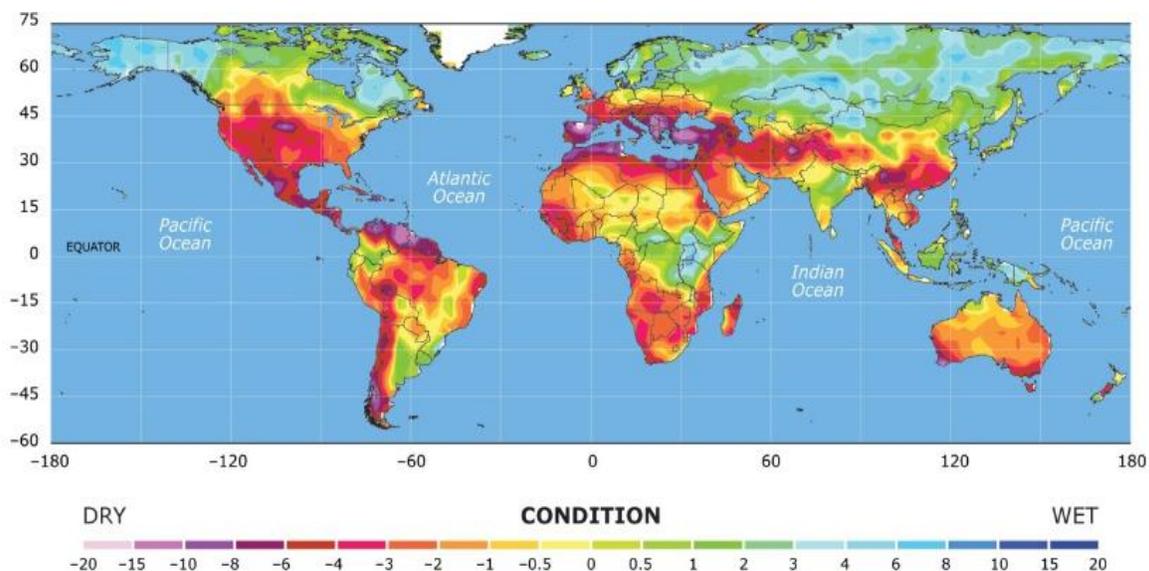


Figura 60 Sequías futuras. Fuente: (Greenpeace, 2017).

## 5.2. Resultados obtenidos en los modelos dinámicos

De acuerdo con Forrester y Senge (Forrester and Senge, 1980), los modelos de DS pueden ser verificados y validados a través de consistencia dimensional y prueba de condiciones extremas.

### 5.2.1. Análisis de sensibilidad

a) La consistencia dimensional se utiliza para analizar que las ecuaciones y series de tiempo estén conectados correctamente. En este caso los valores de salida de los submodelos utilizan kilogramos por hectárea (Kg/Ha) para determinar el rendimiento del cultivo agrícola; kilogramos por metro cúbico ( $\text{Kg/m}^3$ ) para determinar la eficiencia de los recursos hídricos en la agricultura; millones dólares para estimar el valor de la agricultura en relación al PIB; y gigatoneladas de dióxido de carbono equivalente ( $\text{Gt CO}_2\text{eq}$ ) para

medir la cantidad de emisiones GEI emitidas por el sector agrícola. A los valores de salida de cada submodelo se le asignó un factor de vulnerabilidad con escala de 0 a 1 para unificar los valores en términos de vulnerabilidad, siendo 1 la vulnerabilidad máxima esperada. Siendo el modelo consistente y verificado.

b) Las condiciones extremas permiten identificar errores en el modelo y analizar diferentes escenarios ante posibles variaciones. Para el análisis en condiciones extremas se modificaron las variables críticas del sistema: “*disponibilidad de agua a nivel nacional, tierra agrícola disponible, emisión de GEI y situación de riesgo o emergencia*”. Este tipo de análisis permite estimar el rendimiento de recursos hídricos en diferentes escenarios a través del tiempo. Las variables “*valor de la agricultura*” y “*rendimiento de tierras agrícolas*” pueden visualizarse mediante el análisis de sensibilidad sobre la variable “*disponibilidad de hectáreas agrícolas*”. Proyecciones en las emisiones GEI e incrementos en eventos hidrometeorológicos, permiten estimar la vulnerabilidad ambiental. Las variaciones del análisis se realizaron a través de cinco escenarios proyectando el valor de la tendencia registrada para el año 2018, la tendencia de los escenarios planteados se distribuyo: eliminado la tendencia (-100%), disminuyendo a la mitad la tendencia (-50%), siguiendo la tendencia actual sin modificaciones (0%) y para aumentos en la tendencia (+50% y +100%) . El análisis de sensibilidad se realizó en el software Stella™.

La Tabla 23 muestra los valores obtenidos después de realizado el análisis de sensibilidad. Como se observa para una disminución en la tendencia (-100% y -50%) los valores obtenidos al cabo de simular las variables críticas serán menores; esto puede resultar desfavorable en el uso de agua en la agricultura y en la superficie disponible para la agricultura haciendo el sistema más vulnerable; asimismo, la reducción de emisiones e incidencia de eventos de riesgo ayuda a disminuir la vulnerabilidad. Por lo contrario un aumento en la tendencia (50% y 100%) resulta benéfico para el desarrollo de actividades agrícola por la utilización adecuada de recursos hídricos y de tierras de cultivo; sin embargo, repercute negativamente en el entorno ambiental. Por lo cual un análisis de sensibilidad permite observar el comportamiento y dinamismo del sistema dando validez y robustez.

Tabla 23 Variables de interés para cada escenario

Variable	Valor				
	-100% Tendencia	-50% Tendencia	(0%) Tendencia	50% Tendencia	100% Tendencia
Eficiencia de recursos hídricos en la agricultura	1.34	1.51	1.69	1.88	2.06
Tierras agrícolas disponibles	4,896,459	5,496,168	6,095,876	6,695,585	7,295,293
Emisiones de GEI	70,397	121,396	172,396	223,395	274,394
Situación de riesgo o emergencia	4,808	6,371	7,935	9,498	11,061

La Figura 61 muestra el impacto de la variable “disponibilidad de agua a nivel nacional ( $Hm^3$ )” sobre comportamiento de la red Eficiencia de los recursos hídricos en la agricultura ( $Kg/m^3$ ) durante un tiempo de validación de doce ciclos. Los escenarios 1 y 2 muestran un decremento en la tendencia, el escenario 3 es la tendencia actual, y los escenarios 4 y 5 un aumento de la tendencia.

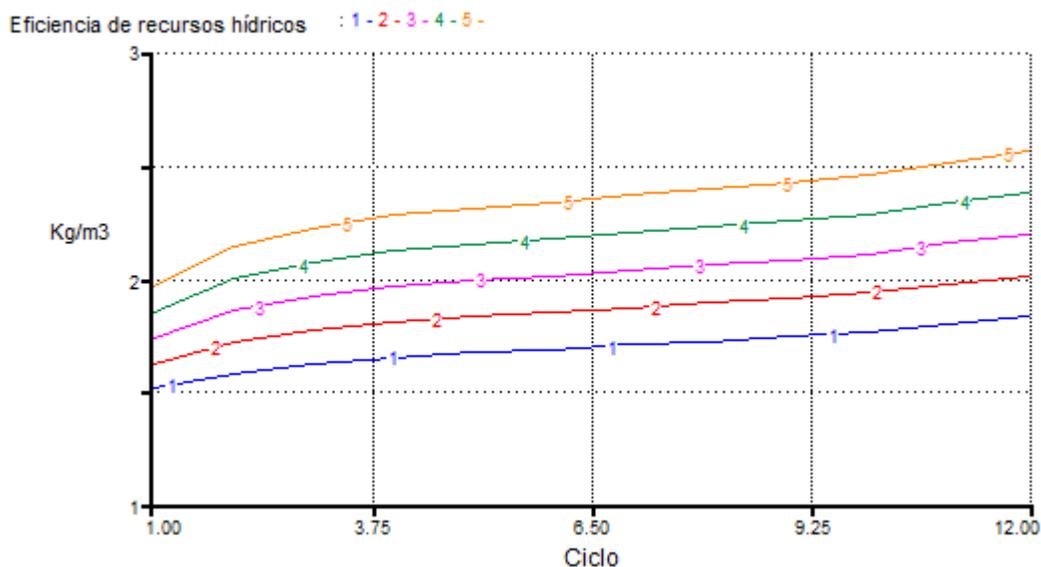


Figura 61 Análisis de sensibilidad para la variable crítica: Eficiencia de recursos hídricos en la agricultura.

La eficiencia en los “recursos hídricos” depende del volumen de agua disponible. Cerca del 76% del volumen nacional de agua es otorgada para actividades del rubro agropecuario. La eficiencia de los recursos hídricos en México tuvo una media de  $1.45 Kg/m^3$  para los años 1994-2016, siendo el año 2012 el año con mayor rendimiento con  $1.86 Kg/m^3$  (CONAGUA, 2018).

En la Figura 62 se puede observar el comportamiento en la eficiencia de recursos hídricos en relación al volumen de agua. Como se observa, a medida que aumenta la disponibilidad de agua la eficiencia de los recursos hídricos incrementa de igual manera.

Siguiendo la tendencia histórica, al cabo de la simulación de los doce ciclos se puede observar un aumento en la tendencia de disponibilidad de agua; sin embargo la eficiencia de los recursos hídricos se mantiene semi-constante (ciclos 10-12) por una disminución en los rendimientos de cosecha.

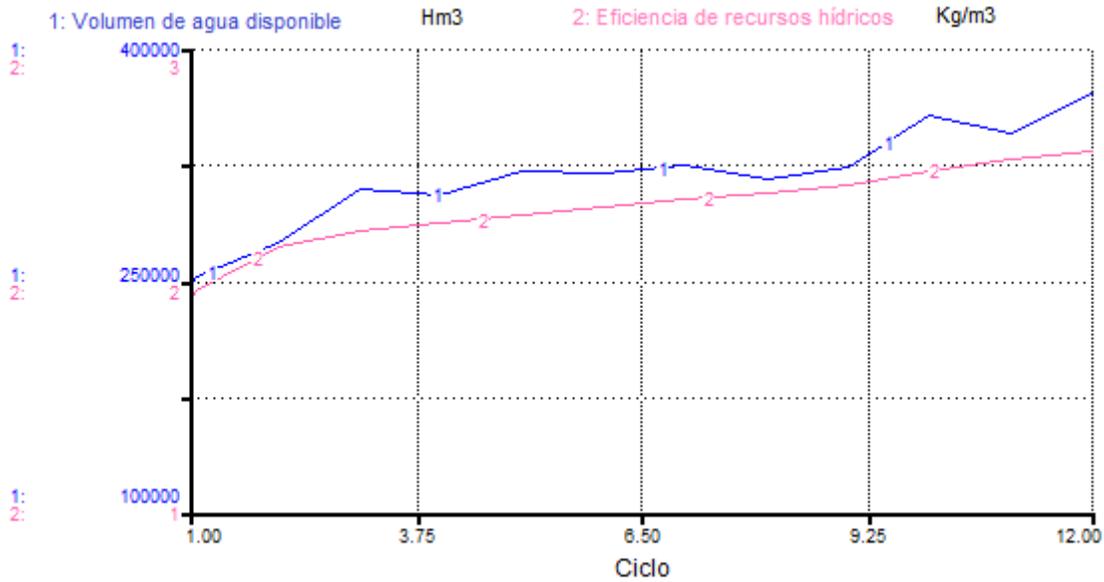


Figura 62 Proyección de las variables: Volumen de agua disponible para actividades agrícolas y Eficiencia de recursos hídricos en la agricultura.

En la validación de las redes “Rendimiento de tierras agrícolas y Valor de la agricultura” se modificó la tendencia de la variable “Extensión de tierras” debido a que un incremento o disminución en esta impacta directamente a la variable “Disponibilidad de tierras agrícolas”

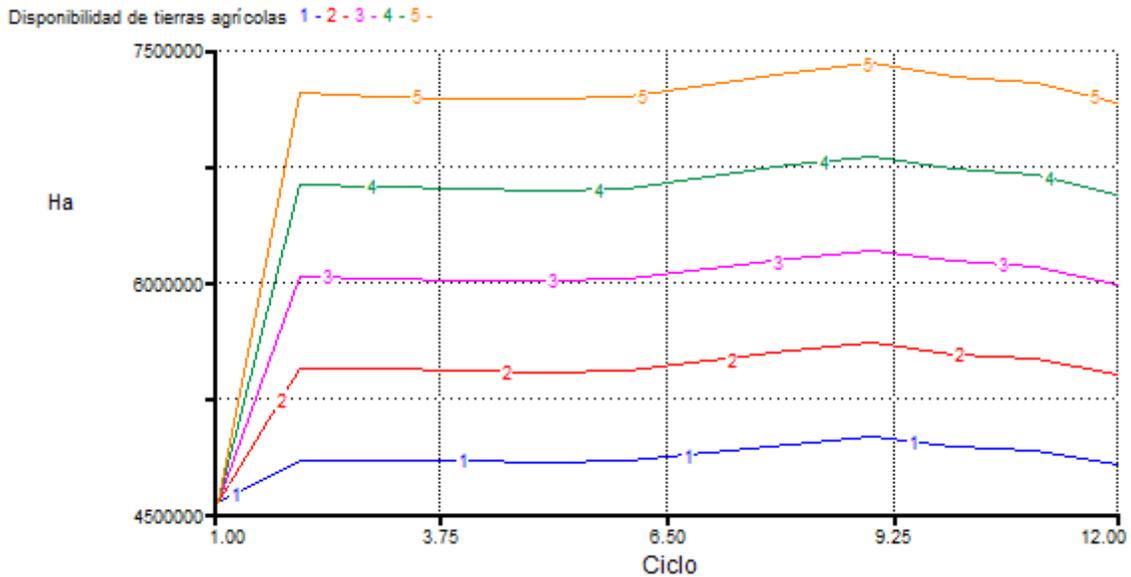


Figura 63). En análisis de sensibilidad muestra una disminución en los escenarios 1 y 2 dada la disminución de la tendencia, mientras que al aumentar la tendencia se incrementa el valor obtenido en los escenarios 4 y 5. Para la estimación de la variable “Disponibilidad de tierras agrícolas” se excluye la superficie incultivable originada por erosión de suelos y pérdida de cosecha producto de cuestiones medioambientales.

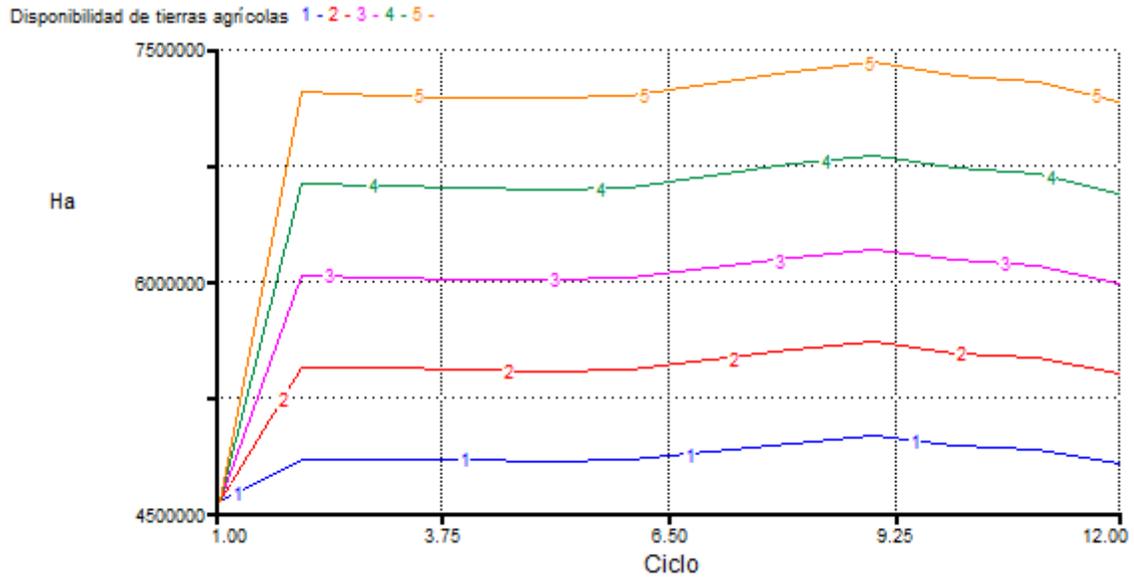


Figura 63 Análisis de sensibilidad para la variable crítica: Disponibilidad de tierras agrícolas.

A continuación se muestra los resultados proyectados para doce ciclos de cultivo siguiendo la tendencia actual del sistema (

Figura 64). Como se observa, un aumento en el rendimiento por hectárea cultivada eleva el valor de la agricultura, el escenario más prometedor es en el ciclo 4, con 3,806.64 Kg/Ha y 740,404.64 millones de dólares. La proyección de la variable “*Valor de la agricultura*” se tomó el valor del PIB obtenido durante el cuarto-trimestre para el año 2018 (INEGI, 2019).

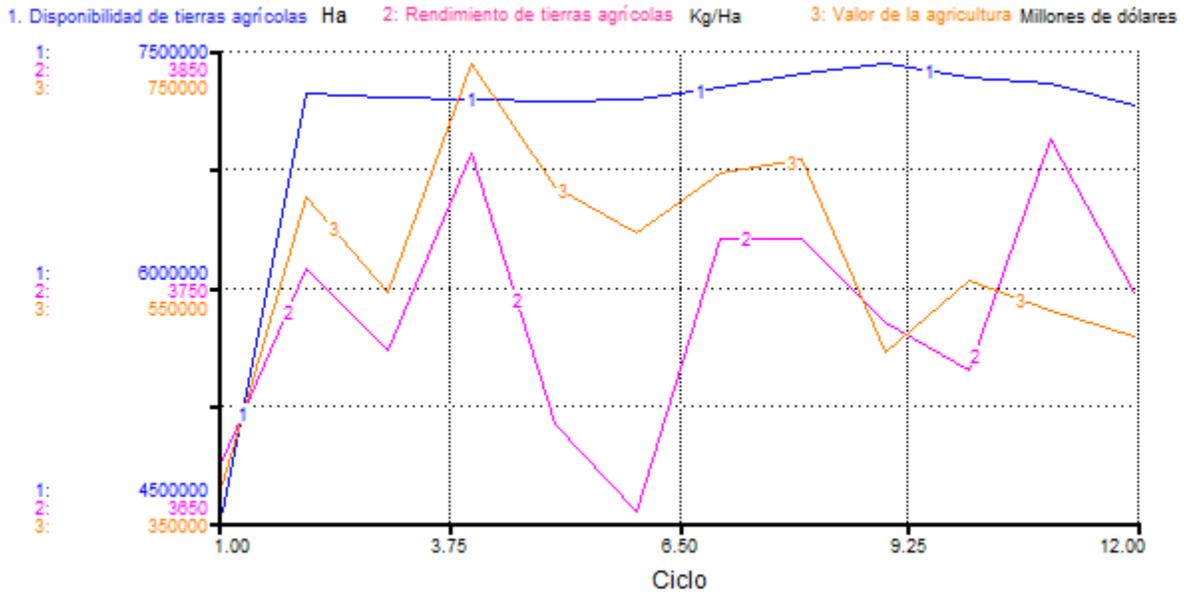


Figura 64 Proyección de las variables: Disponibilidad de tierra agrícola, Rendimiento de tierras agrícolas y Valor de la agricultura.

La red “*Contingencia ambiental*” está integrado por dos variables críticas: “*Emisiones de GEI y Situación de emergencia o riesgo*”. Las emisiones generadas por actividades agropecuarias representan el 12% del total de las emisiones GEI en México (INECC). El inventario nacional de emisiones para los principales rubros ambientales está clasificado por categoría y sector de acuerdo al protocolo de Kyoto (Pérez-Pérez and Nieto-Barajas, 2019): dióxido de carbono, óxido nitroso, perfluorocarbonos, metano, hexafluoruro de azufre y hidrofluorocarbonos (Reilly et al., 1999). Para la variable “*Situación de riesgo o emergencia*”, se contabilizaron el número de eventos dentro de esta clasificación reportados con información del CENAPRED.

Las Figura 65 y Figura 66 muestran los resultados del análisis de sensibilidad para un periodo de doce ciclos de cultivo.

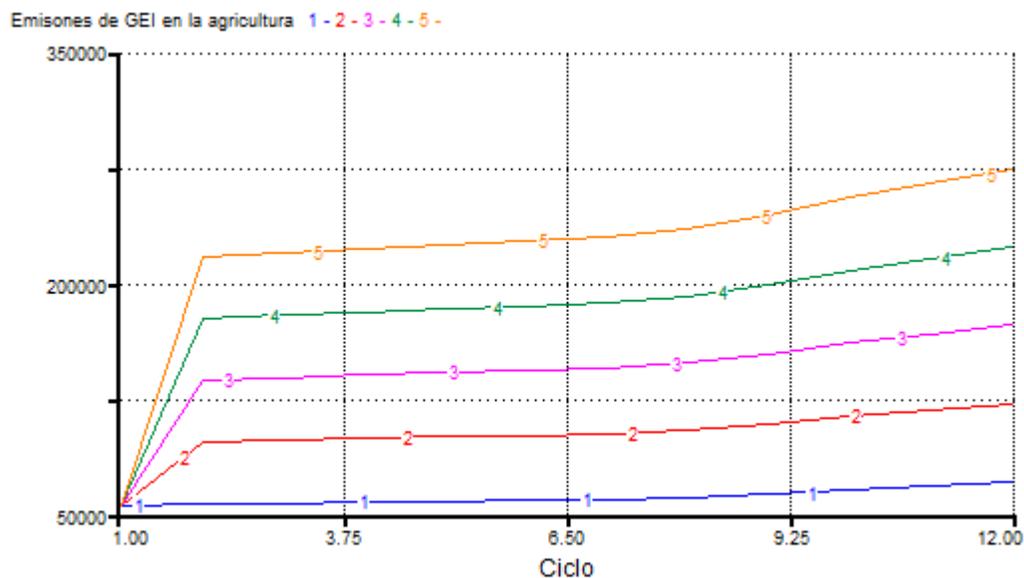


Figura 65 Análisis de sensibilidad para la variable crítica: Emisiones de gases de efecto invernadero (GEI)

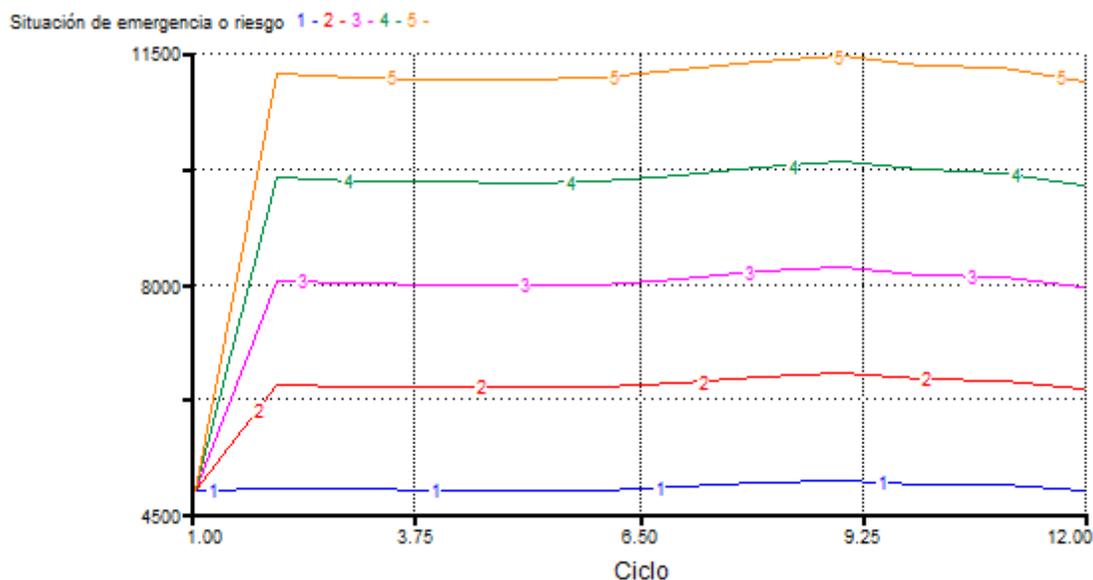


Figura 66 Análisis de sensibilidad de la variable crítica: Situación de emergencia o riesgo

Como se observa, en ambas figuras los escenarios 1 y 2 al disminuir la tendencia se obtienen una menor emisión de GEI y menor presencia de eventos que pongan en riesgo la cosecha agrícola; por lo contrario si la tendencia aumenta la contingencia ambiental aumentará. El análisis de sensibilidad muestra un comportamiento esperado en las redes con base al diagrama causal, con lo que se concluye que el modelo agente de indicadores de vulnerabilidad tiene robustez y validez.

La Figura 67 muestra los resultados en la simulación de las variables críticas de la red “Contingencia ambiental” para doce ciclos. Los valores esperados están sujetos a la proyección en la tendencia de datos históricos del 2001-2018. Con los resultados obtenidos, se puede observar un incremento exponencial en ambas series de tiempo. El aumento en la variable “Emisiones de GEI” al final de la simulación muestra un aumento del 21.5%, el aumento del total de emisiones emitidas por el sector agrícola está determinado por las emisiones fuentes provenientes de metano, oxido nitroso y dióxido de carbono (INECC, 2018).

La tendencia de los eventos de riesgo o emergencia oscila entre 9-11% entre cada ciclo; sin embargo se prevé que esta cifra siga en aumento debido al cambio en los factores climatológicos resultado del cambio climático; lo cual, podría traer repercusiones significativas en la cosecha para algunas regiones en México.

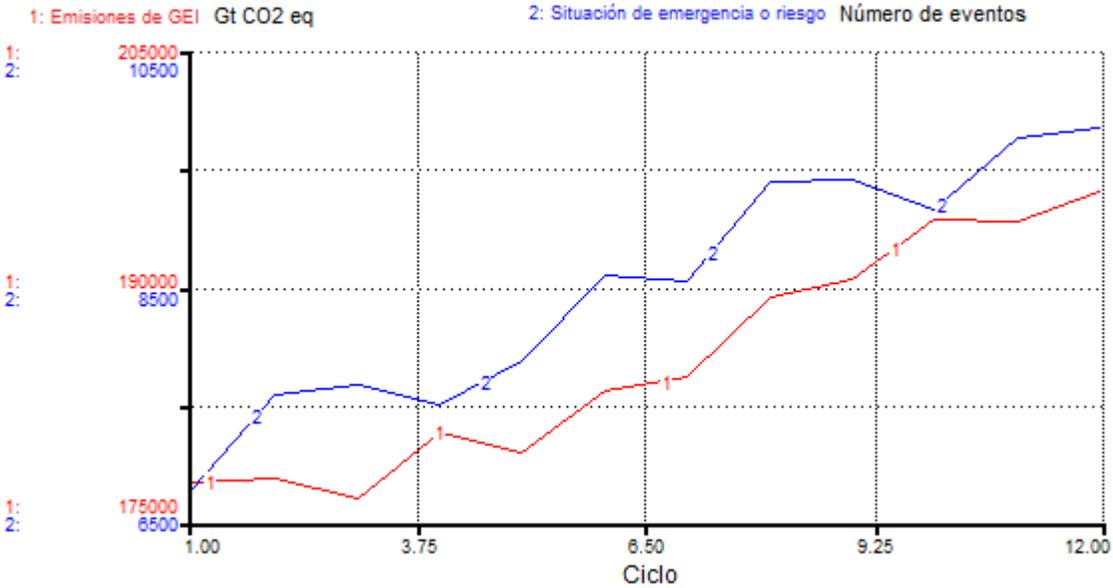


Figura 67 Proyección de las variables: Emisión de GEI y Situación de emergencia o riesgo

La Tabla 24 muestra el resultado de las variables de interés a lo largo de la simulación de doce ciclos. Los datos para la variable “Valor de la agricultura” están expresados en millones de dólares, tomando como referencia tipo de cambio al año 2018, para determinar el equivalente al porcentaje del PIB se tomo como base el cuarto-trimestre del mismo año.

Tabla 24 Variables de interés para cada ciclo de simulación

Variable	Volumen de agua disponible	Eficiencia de recursos hídricos	Disponibilidad de tierras	Rendimiento de tierra	Valor de la agricultura		Emisiones GEI	Situación de emergencia o riesgo
Unidad	Hm <sup>3</sup>	Hg/m <sup>3</sup>	Ha	Kg/Ha	Millones de dólares	% PIB	Gt CO <sub>2</sub> eq	Número de eventos
Ciclo: 1	251,773.89	1.45	7,227,184.35	3,676.06	18,743.80	2.060	159,964.05	6,774.44
2	273,972.29	1.64	7,206,865.98	3,757.75	30,735.37	3.379	166,960.44	7,570.99
3	309,046.29	1.71	7,190,620.79	3,722.91	26,778.92	2.944	173,457.32	7,660.92
4	304,838.15	1.75	7,182,446.01	3,806.64	36,383.52	4.000	177,753.08	7,493.91
5	321,256.42	1.79	7,195,389.17	3,691.39	31,181.25	3.428	176,422.15	7,866.49
6	319,024.29	1.82	7,275,353.99	3,653.58	29,259.90	3.216	180,710.70	8,598.80
7	324,990.54	1.85	7,362,793.28	3,770.19	31,747.40	3.490	179,379.77	8,547.41
8	315,145.00	1.88	7,425,284.69	3,770.10	32,340.86	3.555	183,372.56	9,395.35
9	324,001.19	1.92	7,333,854.86	3,734.56	24,244.44	2.665	184,259.85	9,408.19
10	356,892.50	1.97	7,295,293.55	3,714.15	27,219.68	2.992	189,287.81	9,151.24
11	345,194.27	2.02	7,157,878.98	3,802.90	25,964.10	2.854	190,470.86	9,767.92
12	371,708.19	2.06	7,103,162.95	3,747.27	24,884.65	2.735	194,315.76	9,857.86

### 5.3. Resultados obtenidos en los modelos difusos

Los parámetros de entrada para cada variable representan los datos reportados por el Ingenio Industrial Azucarero del caso de estudio. En la Tabla 25 se observan los parámetros de entrada para el modelo difuso “*Rendimiento de Cultivo*”.

Tabla 25 Parámetros de entrada del modelo difuso: Rendimiento de cultivo

Rendimiento de cultivo		
Variable	Valor	Unidad
V <sub>1</sub> Tipo de agricultura	Cielo abierto	Moda
V <sub>2</sub> Irrigación	Temporal	Moda
V <sub>3</sub> Sistema de irrigación	Ninguno	Moda
V <sub>4</sub> Plaguicida	Si	Aplicación
V <sub>5</sub> Insecticida	Si	Aplicación
V <sub>6</sub> Nitrógeno	60	Kg ha <sup>-1</sup>
V <sub>7</sub> Fósforo	12	Kg P <sub>2</sub> O <sub>5</sub> ha <sup>-1</sup>
V <sub>8</sub> Potasio	120	Kg K <sub>2</sub> O ha <sup>-1</sup>

Una vez introducidos los parámetros en el modelo difuso, el proceso de desfusificación se encarga de convertir los parámetros difusos de las variables de entrada en valores numéricos para las variables de salida mediante la asignación de pertenencia en los conjuntos difusos y la activación de las reglas de inferencia. El valor obtenido para el rendimiento de cultivo de caña de azúcar en el modelo difuso es de 65.1 Ton/Ha. La Figura 68 muestra una comparación entre los datos históricos emitidos por el SIAP y los obtenidos en el modelo difuso para los últimos doce ciclos.

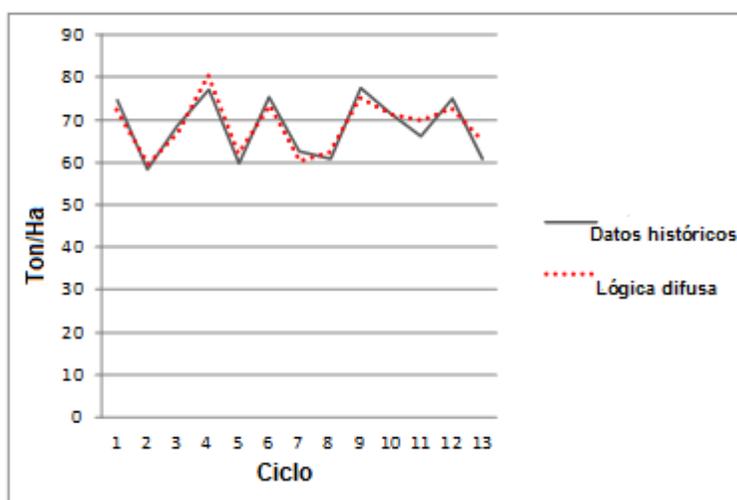


Figura 68 Rendimiento de la caña de azúcar: Datos históricos vs Resultados del modelo difuso

Los resultados obtenidos en la Figura 68 muestran correlación entre datos obtenidos por el modelo difuso y los datos históricos del rendimiento en el cultivo caña de azúcar. Se obtuvo un coeficiente de correlación de 94.65%. Los resultados presentados a continuación (Figura 69-71) muestran las superficies de respuesta obtenidas para una mayor obtención de rendimiento de cultivo.

El mayor rendimiento esperado oscila entre 76~81 Ton/Ha respecto a las variables N-P-K (nitrógeno, fósforo y potasio) relacionadas con la nutrición de suelos. La implementación de fertilizantes es vital para aumentar la productividad de las plantaciones. El uso de fertilizantes aporta aquellos nutrientes deficientes en el suelo agrícola originados por degradación de suelos o factores climáticos. El uso de fertilizantes evita pérdidas de los nutrientes por lixiviación y para contrarrestar efectos salinos que inhiban el crecimiento de la raíz.

La adición de nitrógeno (N) ayuda al proceso de formación del material vegetal (retoños) y estimula la fase del crecimiento intensivo. Una deficiencia de nitrógeno puede originar muerte prematura de hojas y decoloración de la lámina foliar (Figura 69).

El mayor valor esperado en el rendimiento del cultivo está relacionado con la adición de fósforo (P) al ser necesaria en mayor proporción durante la fase formativa del cultivo (Figura 70); sin embargo, si se exceden los niveles recomendados ( $>15 \text{ Kg P}_2\text{O}_5 \text{ ha}^{-1}$ ) se reduce el rendimiento, la concentración de azúcar, porcentaje de sacarosa de jugo y pureza del cultivo. (CONADESUCA, 2018).

El potasio (K) aumenta el crecimiento del tallo y la cantidad de azúcar; por su parte, decrementos en niveles de potasio disminuyen la concentración de azúcar en tallos degradando la calidad del cultivo (Figura 71).

En las superficies de respuesta, no existe interacción con la variable “*Sistema de irrigación*” debido a que el cultivo se produce bajo condición de “*Temporal*”. Las condiciones óptimas de precipitación para la producción de caña de azúcar oscilan en 1,500 mm ya que la planta emplea entre 50-100 m<sup>3</sup> de agua por tonelada de caña de azúcar (peso fresco).

Reportes emitidos por la Encuesta Nacional Agrícola (ENA) para el año 2017 manifestó que el 80% de los productores agrícolas de caña no presentaron problemas relacionados con disponibilidad de agua, por lo cual no fue necesaria la implementación de algún tipo de sistema de irrigación.

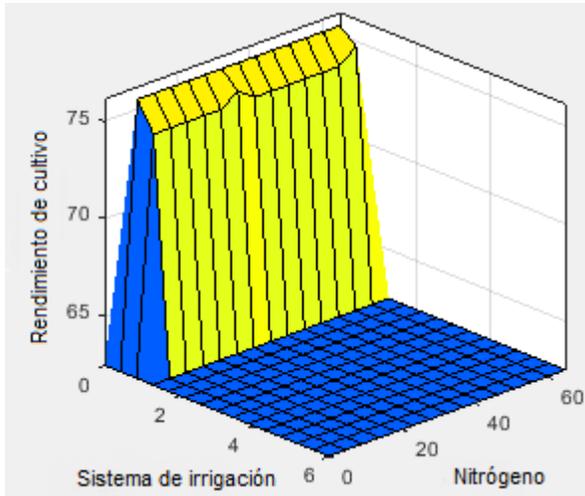


Figura 69 Variables de impacto: "Sistema de irrigación"- "Nitrógeno" del modelo: Rendimiento de cultivo

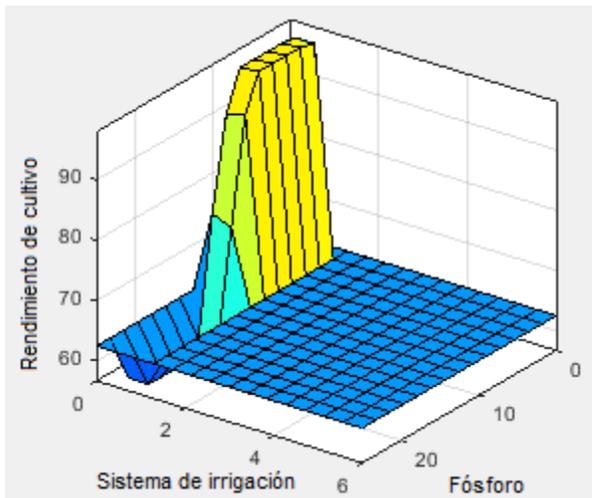


Figura 70 Variables de impacto: "Sistema de irrigación"- "Fósforo" del modelo: Rendimiento de cultivo

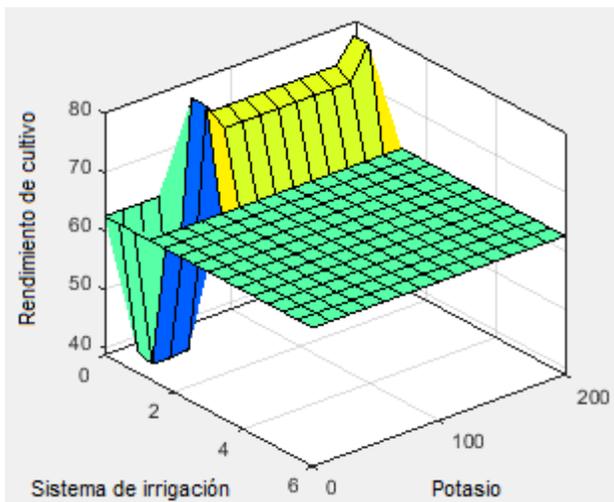


Figura 71 Variables de impacto: "Sistema de irrigación"- "Potasio" del modelo: Rendimiento de cultivo

En la Tabla 26 se muestran los parámetros de entrada para el modelo difuso “*Parámetros inciertos*”.

Tabla 26 Parámetros de entrada del modelo difuso: Parámetros inciertos

<b>Parámetros inciertos</b>		
<b>Variable</b>	<b>Valor</b>	<b>Unidad</b>
V <sub>9</sub> Eventos meteorológicos	35	Número de eventos*
V <sub>10</sub> Sequías	48	Número de eventos*
V <sub>11</sub> Vientos	38	Km/hr
V <sub>12</sub> Precipitaciones	166	mm/mes
V <sub>13</sub> Temperatura	27	°C

*\*Número de eventos reportados en el último ciclo*

El resultado obtenido después del proceso de desdifusificación es de un riesgo de cosecha de 0.21, considerado como un riesgo “*bajo*” categorizado dentro la etiqueta lingüística “*Inofensivo*”.

La Figura 72 muestra la interacción de las variables (“*Vientos*” y “*Temperatura*”) que potencialmente incrementan el riesgo de cosecha teniendo un valor de hasta 0.85 considerado como un riesgo “*alto*”. La temperatura es uno de los factores altamente asociado con el crecimiento de la plantación teniendo valores óptimos de entre 25~38 °C, valores fuera de este rango afectan negativamente el rebrote o germinación de la caña de azúcar.

Valores por encima de 38°C reducen el proceso de fotosíntesis del cultivo, alternado la concentración de sacarosa. Además de la temperatura, la velocidad de vientos es un factor determinante que incrementa el riesgo de cosecha. En áreas agrícolas con presencia de vientos fuertes la pérdida de agua es alta por la rápida evaporación producida a nivel del suelo. Los vientos con una velocidad por encima de aproximadamente ≈60 Km/hr destruyen la vegetación a través de la pérdida de hojas por la acción mecánica que ejercen en el cultivo.

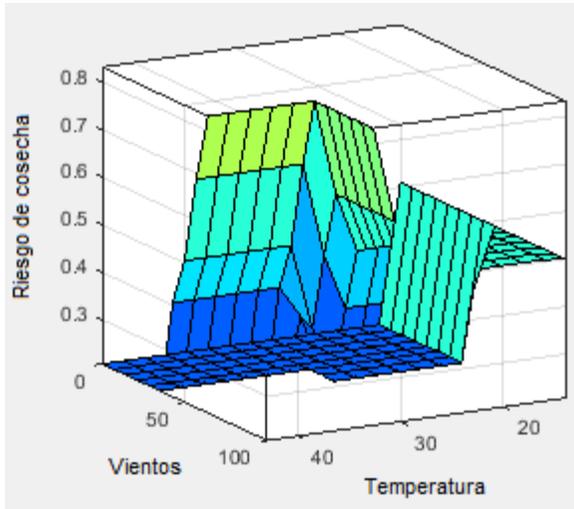


Figura 72 Variables de impacto: “Vientos” - “Temperatura” del modelo: Parámetros inciertos

Los requerimientos hídricos durante el crecimiento de la caña de azúcar son mayores en comparación con la mayoría de los cultivos. Entre el 50 - 70% de las raíces se distribuyen en los primeros 30 cm de profundidad, siendo ésta zona donde existe una mayor absorción de nutrientes y agua.

En periodos de sequía donde prevalecen condiciones con niveles de humedad baja, la raíz del cultivo tiende a crecer más en profundidad buscando recurso hídrico, lo cual origina que el agua se concentre mayormente en la raíz y en menor proporción en otras partes de la planta disminuyendo la capacidad productiva del cultivo.

La Figura 73 muestra la relación entre las variables “*Sequía-Lluvia*” donde se observan niveles de riesgo por encima de 0.45 considerado como un riesgo “moderado a alto”.

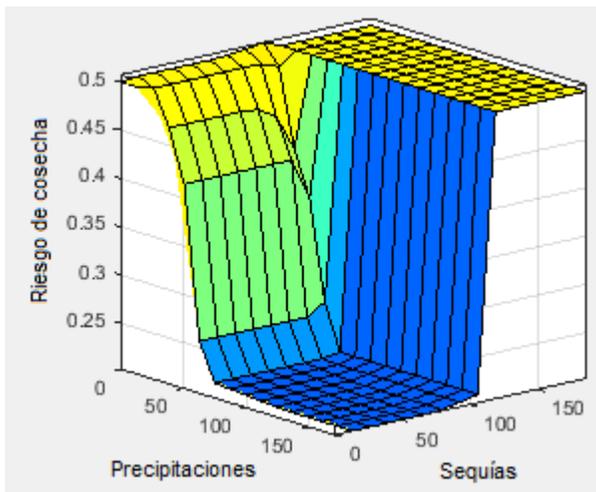


Figura 73 Variables de impacto: “Sequías”-“Precipitaciones” del modelo: Parámetros inciertos

Los fenómenos hidrometeorológicos (huracán, ciclones, tormentas tropicales) suelen ser acompañados de rachas de vientos por encima de  $\approx 120$  Km/hr además de ser acompañados de lluvias torrenciales, lo cual eleva el riesgo de cosecha debido a la acción mecánica ejercida sobre el cultivo.

La Figura 74 muestra la relación “Lluvia - Eventos Meteorológicos”, donde se observa que en escenarios con incidencia mayor a 160 eventos con declaratoria de emergencia y precipitaciones por encima de 100 mm el riesgo en la cosecha aumenta a un nivel “moderato – alto”.

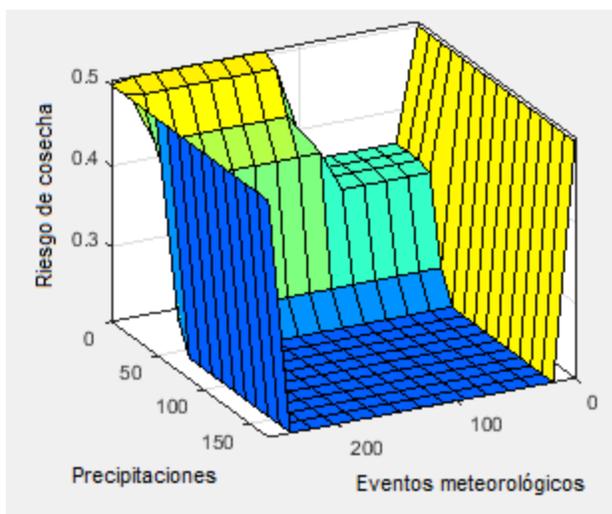


Figura 74 Variables de impacto: “Precipitaciones”-“Eventos meteorológicos” del modelo: Parámetros inciertos

La proporción de los eventos del área de estudio con respecto a los reportados a nivel nacional es de un 23.74% aproximadamente; sin embargo, en los años 2004, 2010 y 2013 hubo un incremento por la incidencia eventos hidrometeorológicos con declaratoria de “desastre” según reportes emitidos por CENAPRED.

Durante el 2004, se reportaron presencia de lluvias atípicas extremas; para el año 2010 presencia de lluvias severas a causa del huracán Karl y el ciclón tropical Mathew; mientras que el año 2013 se vio afectado por las tormentas tropicales Barry, Fernando y Manuel así como el huracán Ingrid. La Figura 75 muestra una comparativa entre datos históricos de eventos hidrometeorológicos de la región Tabasco-Veracruz y los reportados a nivel nacional en el periodo 2001-2016 (CENAPRED).

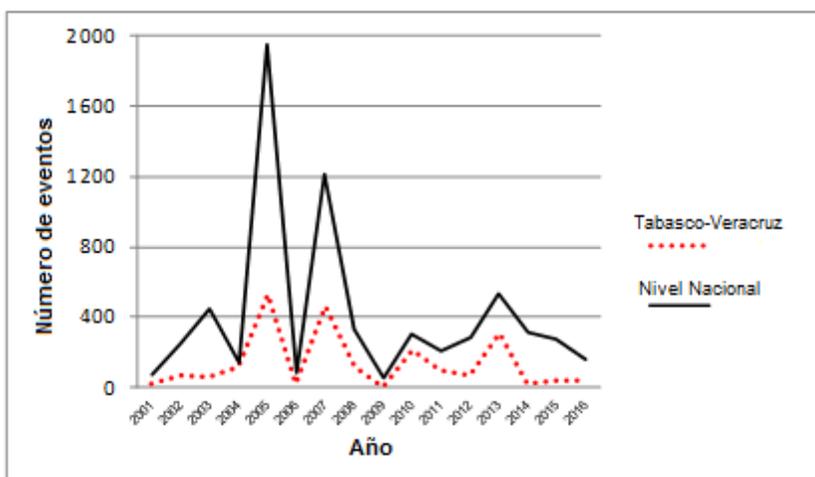


Figura 75 Número de eventos meteorológicos reportados en México en el periodo 2001-2016

Conociendo el rendimiento de la caña de azúcar (65.1 Ton/Ha) y el riesgo de cosecha (0.21) a través de los modelos difusos (“*Rendimiento de cultivo* y *Riesgo de Cosecha*”) y con datos de la producción agrícola de la caña de azúcar (“*Superficie plantada*”, “*Superficie cosechada*” y “*Valor de la producción*”) se determinó el grado de vulnerabilidad en el cultivo mediante el modelo difuso “*Vulnerabilidad de Cultivo*”. En la Tabla 27 se muestran los valores de entrada al modelo.

Tabla 27 Parámetros de entrada del modelo difuso: Vulnerabilidad de cultivo

Vulnerabilidad de cultivo		
Variable	Valor	Unidad
V <sub>14</sub> Superficie sembrada	2497	Ton
V <sub>15</sub> Superficie cosechada	2497	Ton
V <sub>16</sub> Valor de producción	139,607.67	Miles de dólares
O <sub>1</sub> Rendimiento de cultivo	65.1	Ton/Ha
O <sub>2</sub> Riesgo de cosecha	0.21	Nivel

La vulnerabilidad del cultivo obtenida en el modelo difuso es de 0.265 siendo una vulnerabilidad “baja-media”. En México existen 55 ingenios, de los cuales Veracruz cuenta con 20; posicionándose como el estado de mayor producción de azúcar (2, 620,194 Ton). Sin embargo, la producción de toneladas por hectárea de azúcar es menor con relación a la producida en estados como Morelos, Puebla, Michoacán, Jalisco, Chiapas y Colima; los cuales cuentan con 2, 2, 3, 6, 2 y 1 ingenios, respectivamente.

La Tabla 28 muestra las toneladas por hectárea de azúcar producida en México para la zafra 2012/2013.

Tabla 28 Producción de toneladas de azúcar por hectárea en México

<b>Estado</b>	<b>Azúcar Ton/Ha</b>
Morelos	14.97
Puebla	14.8
Michoacán	11.92
Jalisco	11.47
Chiapas	11.22
Colima	9.79
Tamaulipas	8.73
Veracruz	8.45
San Luis Potosí	8.43
Nayarit	8.42
Oaxaca	8.14
Sinaloa	6.53
Campeche	6.50
Tabasco	6.04
Quintana Roo	6.02

El rendimiento observado en la obtención de azúcar en el estado de Veracruz está intrínsecamente relacionado con cambios en las condiciones climáticas originados por el calentamiento global, tales como cambios en precipitaciones y fenómenos meteorológicos extremos produciendo efectos adversos en la producción agropecuaria e incrementando el riesgo en la cosecha.

La Figura 76 se puede observar la relación de las variables “*Rendimiento de cultivo*” y “*Riesgo de cosecha*”. En la superficie de respuesta se observa un incremento de vulnerabilidad en proporción a incrementos del riesgo de cosecha, mientras que el rendimiento por hectárea disminuye.

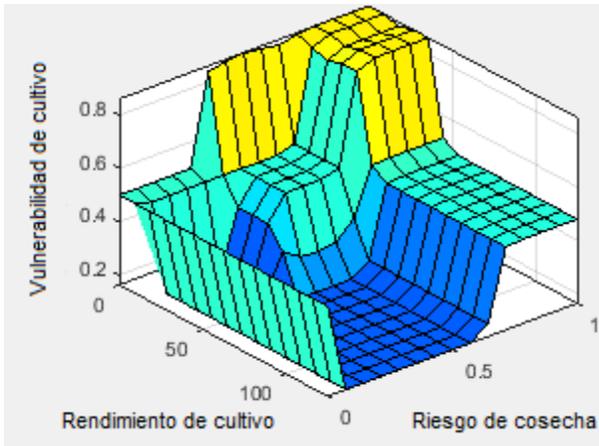


Figura 76 Variables de impacto: “Rendimiento de cultivo”-“Riesgo de cosecha” del modelo: Vulnerabilidad del cultivo

La incidencia de impactos originados por cambio climático, ha surgido la necesidad de desarrollar estrategias que incrementen la productividad y maximizar el potencial del sector agroalimentario. La relación entre la superficie cosechada y el rendimiento del cultivo de caña de azúcar no es proporcional; es decir, aunque la superficie plantada sea alta no asegura que el rendimiento del cultivo cosechado esperado sea igualmente alto (Figura 77), como se mencionó anteriormente, sino que depende de diversos factores relacionados con el buen manejo de prácticas agrícolas y factores climáticos, principalmente.

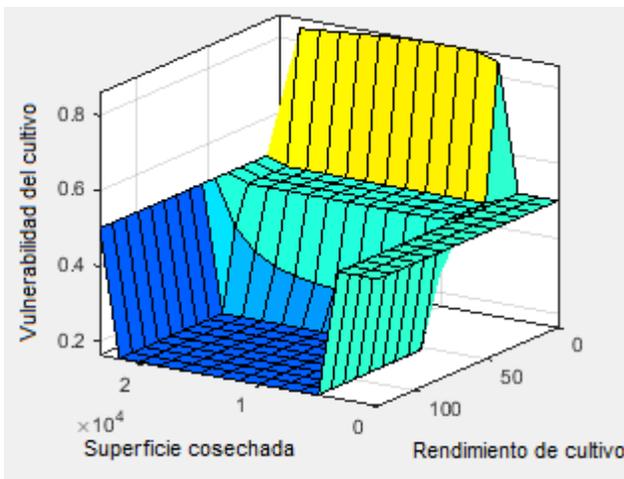


Figura 77 Variables de impacto: “Superficie cosechada”-“Rendimiento de cultivo” del modelo: Vulnerabilidad del cultivo

Uno de los principales retos que enfrenta el sector azucarero es la oferta a escala mundial originado por el incremento de competencia en el mercado por la producción de edulcorantes. Por lo que la industria de caña de azúcar se esmera por aumentar la rentabilidad y sustentabilidad para garantizar una oferta de calidad con capacidad

competitiva en el mercado para mantener un valor de producción estable. En la Figura 78 muestra la relación “Valor de producción – Rendimiento de cultivo”.

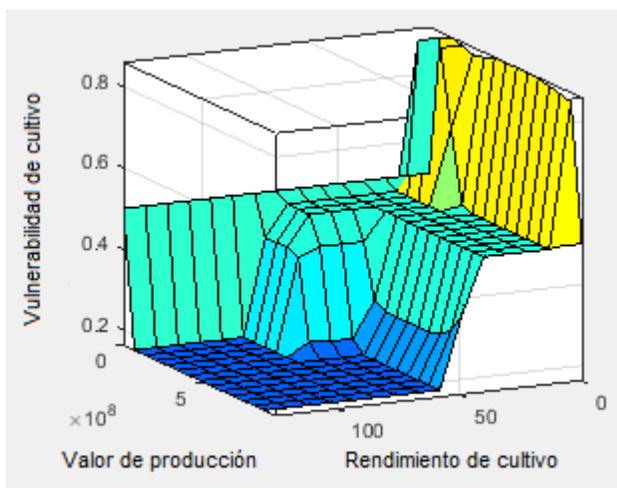


Figura 78 Variables de impacto: “Valor de producción”-“Rendimiento de cultivo” del modelo: Vulnerabilidad de cultivo

La cadena de suministro agrícola está sujeta a la variabilidad climática y otras fluctuaciones (Dieguez Camerón et al., 2014) originando cambios socioeconómicos y fluctuaciones en la demanda de alimentos e importaciones netas disminuyendo la eficiencia de la producción agrícola (Holman et al., 2017). Por otra parte, la posición geográfica de México y la incertidumbre sobre la magnitud y frecuencia de fenómenos extremos podrían incrementar significativamente la vulnerabilidad agrícola a mediano plazo (SAGARPA, 2013).

Ante un aumento en la vulnerabilidad en la caña de azúcar, el correcto manejo en los indicadores fisicoquímicos del ambiente edáfico puede aumentar el rendimiento por hectárea de la caña de azúcar.

El modelo difuso “*Desordenes no-nutrimientales*” tiene la función de agente reactivo, ya que permite modelar indicadores fisicoquímicos de la condición edáfica del ingenio para predecir la eficiencia del suelo agrícola; ayudado así, a contrarrestar la vulnerabilidad del cultivo.

En la Tabla 29 se muestran los parámetros de entrada del modelo difuso “*Eficiencia del Suelo*”.

Tabla 29 Parámetros de entrada del modelo difuso: Eficiencia del suelo (Agente Reactivo)

<b>Desordenes no nutrimentales</b>		
<b>Variable</b>	<b>Valor</b>	<b>Unidad</b>
V <sub>17</sub> Punto de marchitamiento (PMP)	23	PMP Level
V <sub>18</sub> Conductividad eléctrica (CE)	1.6	dS/m
V <sub>19</sub> pH	6.3	pH Level
V <sub>20</sub> Materia orgánica (MO)	10.3	%
V <sub>21</sub> Acidez intercambiable (Int.Acidez )	0.4	cMol*Kg <sup>-1</sup>

El valor obtenido para la eficiencia de tierras agrícola es de 0.783. El valor obtenido, con base al modelo difuso se considera una eficiencia “media a óptima”, debido a que los principales suelos que constituyen el terreno agrícola son vertisoles, gleysoles, cambisoles y litosoles. Los primeros son suelos característicos por ser muy duros con tendencia a generar grietas profundas durante los periodos de sequía; los gleysoles son suelos que tienden a la acumulación de agua durante periodos de mayor precipitación. Mientras que los cambisoles y litosoles son suelos altamente vulnerables a la erosión.

Los resultados obtenidos en las superficies de respuesta del modelo difuso muestran una mayor eficiencia ( $\approx > 0.77$ ) resultado de la interacción de las variables materia orgánica y pH (Figura 79). La materia orgánica permite la reducción de problemas relacionados con deficiencias nutrimentales en los suelos, puesto que el material orgánico aporta los micronutrientes necesarios ( $Mg^{2+}$ ,  $Cu^{2+}$ ,  $Fe^{2+}$ ,  $Mn^{2+}$  y  $Zn^{2+}$ ) para minimizar el déficit. El pH determina la disponibilidad de micronutrientes contenidos en la materia orgánica. Valores óptimos de pH en el suelo agrícola oscilan entre 4.8 y 7.2, valores de pH por debajo de 4 acidifican los suelos agrícolas por presencia de aluminio intercambiable alterando el desarrollo cultivo a nivel de raíz, mermando la productividad en la caña de azúcar. Como se observa en la Figura 80, valores de pH superiores a 4.5 elevan la eficiencia de suelos ( $>0.68$ ). Valores de pH entre 2.8~4 arrojan una eficiencia del suelo por debajo de 0.53.

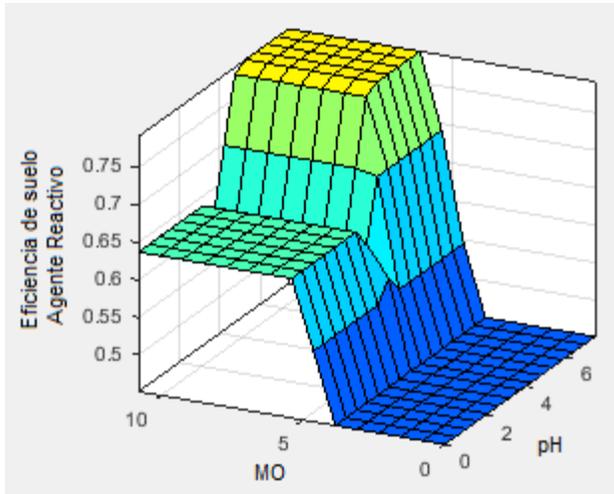


Figura 79 Variables de impacto: "Materia orgánica"- "pH" del modelo: Eficiencia de suelo

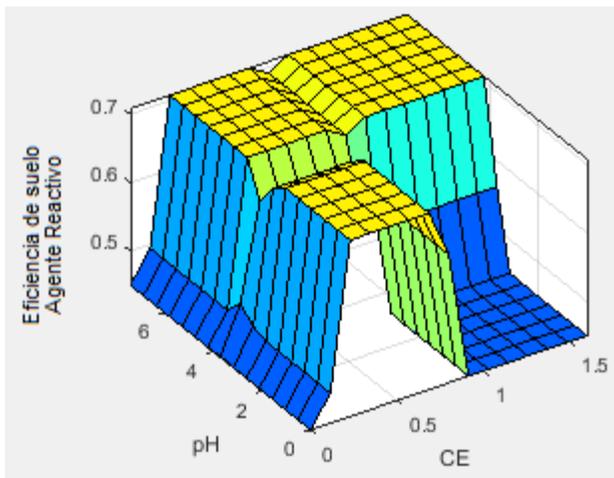


Figura 80 Variables de impacto: "pH"- "Conductividad eléctrica" del modelo: Eficiencia del suelo

La conductividad eléctrica es un indicador potencial para estimar los nutrientes contenidos en el suelo y sus propiedades. De acuerdo a (Simón, Mauricio.; Peralta, Nahuel; Costa, 2013) la conductividad eléctrica se puede definir como: *“Parámetro a través del cual es posible medir la concentración de sales solubles presentes en los suelos. Su valor es más alto cuanto más fácil se mueva dicha corriente a través del mismo suelo por una concentración más elevada de sales”*.

La Figura 81 se muestra la relación entre conductividad eléctrica y materia orgánica. Como se observa, las superficie de respuesta arroja una eficiencia de suelo alta (>0.8) superior a resultados obtenidos en la relación materia orgánica-pH (Figura 79).

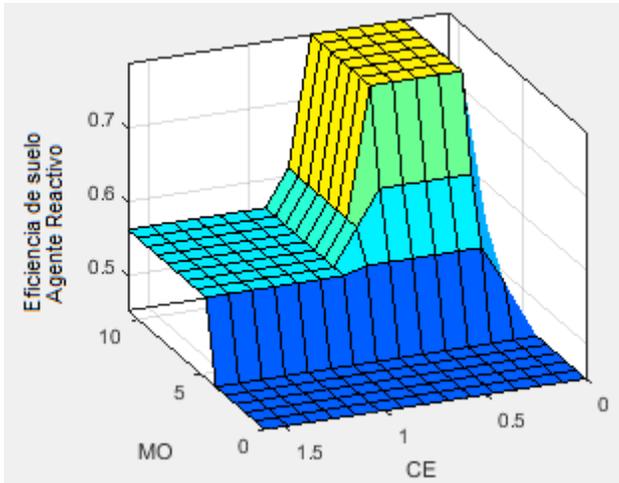


Figura 81 Variables de impacto: “Materia orgánica”-“Conductividad eléctrica” del modelo: Eficiencia del suelo

La reactividad de un agente inteligente se refiere “ a la capacidad de analizar el estado dentro del sistema inmerso para actuar respondiendo de manera adecuada a cambios producidos por el entorno ” (Li and Chan, 2013). La función del modelo difuso de agente reactivo es “activarse” para minimizar la vulnerabilidad cuando se obtengan valores de vulnerabilidad por encima de 0.54. La Tabla 30 muestra la eficiencia del suelo obtenida en el modelo difuso de agente reactivo (*Desordenes no-nutrimientales*) y los resultados en los escenarios de vulnerabilidad en un periodo de doce ciclos.

Tabla 30 Resultados los escenarios de la vulnerabilidad de cultivo

Ciclo	Escenario 1	Escenario 2	Agente Reactivo
1	0.45	0.45	0.73
2	0.22	0.22	0.79
3	0.57	0.49	0.6
4	0.32	0.32	0.78
5	0.3	0.3	0.74
6	0.32	0.32	0.62
7	0.28	0.28	0.66
8	0.54	0.5	0.81
9	0.49	0.49	0.69
10	0.59	0.53	0.67
11	0.4	0.4	0.78
12	0.31	0.31	0.59

***Agente: Vulnerabilidad de cultivo: 0.37***

En el escenario 1, se muestran los resultados de vulnerabilidad de cultivo a partir de los modelos difusos. En el escenario 2 se observa la interacción del agente reactivo para

disminuir la vulnerabilidad cuando sobrepasa valores de 0.54. Cuando los valores de vulnerabilidad son mayores de 0.54, el modelo difuso “*Eficiencia de suelo*” se activa para disminuir la vulnerabilidad (ciclos 3, 8 y 10). Cuando los valores de vulnerabilidad son menores a 0.54 el agente reactivo está inactivo. El valor final de vulnerabilidad para el modelo es de 0.37, lo cual indica una vulnerabilidad baja.

La Figura 82 muestra los resultados al término de la simulación de doce ciclos. Como se observa cuando los ciclos superan los niveles de vulnerabilidad óptimos, el agente reactivo se activa disminuyendo en un 8% ( $\pm 3\%$ ).

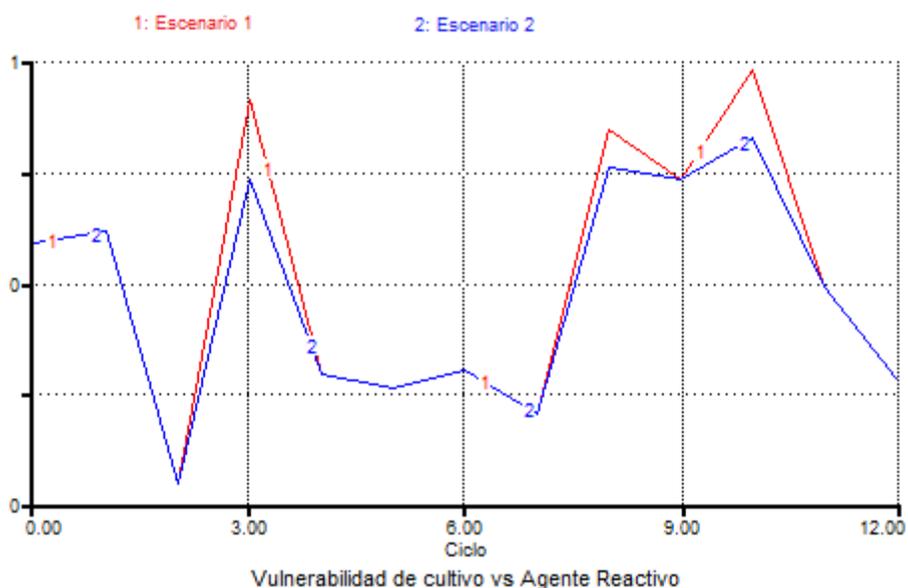


Figura 82 Comparación de los escenarios: Vulnerabilidad de cultivo vs Agente Reactivo

#### 5.4. Determinación de vulnerabilidad agrícola del sistema multi-agente

Con los resultados obtenidos en la etapa 1, se asignó un factor de vulnerabilidad para cada valor obtenido (Tabla 31). La ponderación de vulnerabilidad para los submodelos “*Rendimiento de tierras agrícolas y Valor de la agricultura*”, se asignaron con base al “*Rendimiento de cereales*” y “*Valor agregado de la agricultura*” a nivel mundial en el año 2017 reportado por la FAO (Food and Agriculture Organization, 2017) y el World Bank (World Bank, 2017). La asignación del valor de vulnerabilidad para los submodelos “*Eficiencia de los recursos hídricos y Contingencia ambiental*” se realizó de acuerdo a datos históricos observados de 2001-2018 (CENAPRED, 2018; CONAGUA, 2018, 2015; Inifap, 2018; SIAP, 2016b; SMN, 2017). A continuación se muestran la escala de vulnerabilidad para cada valor esperado de la variable de interés.

Tabla 31 Escala de vulnerabilidad de las redes

Vulnerabilidad		Rendimiento de tierra	Valor de la agricultura	Eficiencia de recursos hídricos	Emisiones GEI	Situación de riesgo ó emergencia
Escala	Etiqueta	Valor (Kg/Ha)	Valor (%PIB)	Valor (kg/m3)	Valor (Gt CO2 eq)	Valor (Eventos)
0 - 0.37	Baja	> 4,464	> 5.2	> 2.2	< 60,000	< 4,100
0.38 - 0.68	Media	3,262 - 4,464	3.4 - 5.2	1 - 2.2	60,000 - 190,000	4,100 - 15,950
0.69 - 1	Alta	< 3,262	< 3.4	< 1	> 190,000	> 15,950

Con base a la escala de vulnerabilidad para cada red, la Tabla 32 muestra los resultados de la ponderación de los submodelos en términos de vulnerabilidad al término de la simulación de doce ciclos, obteniéndose un valor de vulnerabilidad final de 0.56; por lo cual el modelo *Agente de indicadores de vulnerabilidad* tiene una vulnerabilidad “media”; la cual, está relacionada intrínsecamente con la contingencia ambiental y la disminución de recursos en el sector agrícola trayendo repercusiones en el rendimiento de la cosecha impactando en el valor de la agricultura.

Tabla 32 Resultados de vulnerabilidad

Rendimiento de tierras agrícolas	Valor de la agricultura	Eficiencia de recursos hídricos	Contingencia ambiental		
			Emisiones GEI	Situación de riesgo o emergencia	Valor final
0.58	0.89	0.59	0.58	0.43	0.49
0.56	0.69	0.51	0.58	0.45	0.51
0.56	0.73	0.47	0.66	0.47	0.55
0.53	0.38	0.46	0.67	0.47	0.55
0.58	0.64	0.45	0.66	0.47	0.55
0.59	0.71	0.44	0.68	0.49	0.57
0.55	0.64	0.42	0.67	0.48	0.56
0.55	0.61	0.42	0.68	0.5	0.58
0.57	0.78	0.42	0.68	0.5	0.58
0.56	0.73	0.4	0.68	0.5	0.58
0.53	0.75	0.39	0.69	0.51	0.59
0.57	0.79	0.39	0.70	0.51	0.59

***Agente indicadores de vulnerabilidad: 0.56***

Con los resultados obtenidos en las etapas 1 y 2, se tiene una vulnerabilidad total del sistema de 0.47, considerada como vulnerabilidad media.

Los resultados obtenidos en la etapa 2, en la determinación de la vulnerabilidad del cultivo, se obtuvieron valores por debajo de los obtenidos en la etapa 1. La principal ventaja de los sistemas multi-agente es la comunicación; es decir, la habilidad para interactuar entre sí. Esto se puede observar entre los valores de vulnerabilidad obtenidos en la etapa 1 y 2; al ser menor la vulnerabilidad en la etapa 2 indica que el cultivo tiene un riesgo de cosecha bajo dado por los aspectos climatológicos de la región y el buen manejo de prácticas agrícolas empleadas ayudan a minimizar el impacto generado por factores externos mencionados en la etapa 1.

Además de la comunicación, un agente inteligente es un “ente autónomo”; es decir, tienen la capacidad de actuar sin la intervención directa de otro agente. En este caso, el desempeño de “*Agente de indicadores de vulnerabilidad*” y “*Agente de rendimiento de cultivo*” no depende uno del otro, puesto que son independientes y cada agente tiene sus propias tareas; sin embargo, trabajan en conjunto por un mismo objetivo general (etapa 3) respondiendo de manera adecuada a posibles cambios del sistema (Agente Reactivo).

### 5.5. Resultados obtenidos del modelo de riesgo agrícola a través de procesamiento de imágenes

Posterior al procesamiento de imágenes realizado en la etapa 3 (ver sección 4.4) se obtuvo una base de datos para las variables temperatura y precipitación. Una vez que las imágenes han sido procesadas resaltando las características de interés, se realizó el entrenamiento de la red convolucional. La Figura 83, muestra la metodología empleada para el desarrollo de la CNN.

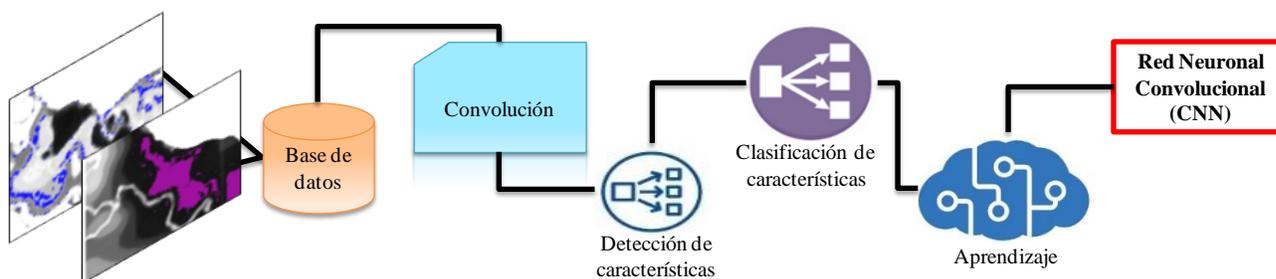


Figura 83 Metodología para la detección por Deep Learning

Las Figura 84 y Figura 85 muestran el proceso de entrenamiento de la CNN para la variable “*Temperatura*”. Como se observa, al cabo del segundo entrenamiento (Figura 85) se logró una precisión del 100% para el entrenamiento de la red, 6.25% más de efectividad en comparación del primer entrenamiento (Figura 84). Además de minimizar los tiempos de optimización de la red en un 24% equivalentes a 18 segundos.

```

Training on single CPU.
Initializing image normalization.
=====
| Epoch | Iteration | Time Elapsed | Mini-batch | Mini-batch | Base Learning |
|       |          | (hh:mm:ss)  | Accuracy   | Loss       | Rate          |
=====
| 1     | 1       | 00:00:11    | 25.00%    | 1.1441    | 0.0010       |
| 2     | 10      | 00:01:15    | 93.75%    | 0.3437    | 0.0010       |
=====

Network training complete.

Step 3 of 3: Training bounding box regression models for each object class...100.00%...done.

R-CNN training complete.
*****

```

Figura 84 Primer entrenamiento de la CNN (variable Temperatura)

```

|       |          | (hh:mm:ss)  | Accuracy   | Loss       | Rate          |
=====
| 1     | 1       | 00:00:06    | 46.88%    | 0.8845    | 0.0010       |
| 2     | 8       | 00:00:57    | 100.00%   | 0.0061    | 0.0010       |
=====

Network training complete.

Step 3 of 3: Training bounding box regression models for each object class...100.00%...done.
|
R-CNN training complete.
*****

```

Figura 85 Segundo entrenamiento de la CNN (variable Temperatura)

Las Figuras 86-90 muestran los resultados del entrenamiento de la CNN para la variable “Precipitación”. Como se observa al finalizar el primer entrenamiento se obtuvo una precisión de  $\approx 89.66\%$  en un tiempo de 39 segundos (Figura 86). Para en el segundo y tercer entrenamiento (Figura 87 y Figura 88) tuvo un incremento del 15% y 87% en el tiempo de entrenamiento en comparación con los resultados del primer entrenamiento lográndose aumentar hasta un 93.10% de precisión de la CNN (+3.44%).

Para elevar la precisión de la CNN, se optó por realizar dos entrenamientos más. Al cabo del cuarto y quinto entrenamiento (Figura 89 y Figura 90) se logró reducir el tiempo de entrenamiento a 33 segundos (45% menos) y se maximizó la exactitud y efectividad en la red obteniéndose 96.88% y 100%, respectivamente.

```

*****
Training an R-CNN Object Detector for the following object classes:

* precipitation

Step 1 of 3: Extracting region proposals from 25 training images...done.

Step 2 of 3: Training a neural network to classify objects in training data...

Training on single CPU.
Initializing image normalization.
=====
| Epoch | Iteration | Time Elapsed | Mini-batch | Mini-batch | Base Learning |
|       |          | (hh:mm:ss)  | Accuracy   | Loss       | Rate          |
|=====|=====|=====|=====|=====|=====|
|   1   |     1   | 00:00:06   | 37.50%    | 1.3408    | 0.0010       |
|   2   |     6   | 00:00:39   | 89.66%    | 0.4204    | 0.0010       |
|=====|=====|=====|=====|=====|=====|

Network training complete.

Step 3 of 3: Training bounding box regression models for each object class...100.00%...done.

R-CNN training complete.
*****

```

Figura 86 Primer entrenamiento de la CNN (variable Precipitación).

```

*****
Training an R-CNN Object Detector for the following object classes:

* precipitation

Step 1 of 3: Extracting region proposals from 25 training images...done.

Step 2 of 3: Training a neural network to classify objects in training data...

Training on single CPU.
Initializing image normalization.
=====
| Epoch | Iteration | Time Elapsed | Mini-batch | Mini-batch | Base Learning |
|       |          | (hh:mm:ss)  | Accuracy   | Loss       | Rate          |
|=====|=====|=====|=====|=====|=====|
|   1   |     1   | 00:00:06   | 27.59%    | 1.6754    | 0.0010       |
|   2   |     6   | 00:00:45   | 90.63%    | 0.1492    | 0.0010       |
|=====|=====|=====|=====|=====|=====|

Network training complete.

Step 3 of 3: Training bounding box regression models for each object class...100.00%...done.

R-CNN training complete.
*****

```

Figura 87 Segundo entrenamiento de la CNN (variable Precipitación).

```

*****
Training an R-CNN Object Detector for the following object classes:

* precipitation

Step 1 of 3: Extracting region proposals from 25 training images...done.

Step 2 of 3: Training a neural network to classify objects in training data...

Training on single CPU.
Initializing image normalization.
=====
| Epoch | Iteration | Time Elapsed | Mini-batch | Mini-batch | Base Learning |
|       |          | (hh:mm:ss)  | Accuracy   | Loss       | Rate         |
=====
| 1     | 1       | 00:00:11    | 56.25%    | 0.7466    | 0.0010      |
| 2     | 6       | 00:01:13    | 93.10%    | 0.1035    | 0.0010      |
=====

Network training complete.

Step 3 of 3: Training bounding box regression models for each object class...100.00%...done.

R-CNN training complete.
*****

```

Figura 88 Tercer entrenamiento de la CNN (variable Precipitación).

```

*****
Training an R-CNN Object Detector for the following object classes:

* precipitation

Step 1 of 3: Extracting region proposals from 25 training images...done.

Step 2 of 3: Training a neural network to classify objects in training data...

Training on single CPU.
Initializing image normalization.
=====
| Epoch | Iteration | Time Elapsed | Mini-batch | Mini-batch | Base Learning |
|       |          | (hh:mm:ss)  | Accuracy   | Loss       | Rate         |
=====
| 1     | 1       | 00:00:05    | 46.88%    | 0.7900    | 0.0010      |
| 2     | 6       | 00:00:33    | 96.88%    | 0.1640    | 0.0010      |
=====

Network training complete.

Step 3 of 3: Training bounding box regression models for each object class...100.00%...done.

R-CNN training complete.
*****

```

Figura 89 Cuarto entrenamiento de la CNN (variable Precipitación).

```

*****
Training an R-CNN Object Detector for the following object classes:

* precipitation

Step 1 of 3: Extracting region proposals from 25 training images...done.

Step 2 of 3: Training a neural network to classify objects in training data...

Training on single CPU.
Initializing image normalization.
=====
| Epoch | Iteration | Time Elapsed | Mini-batch | Mini-batch | Base Learning |
|        |           | (hh:mm:ss)  | Accuracy   | Loss       | Rate          |
=====
|    1   |    1     | 00:00:08    | 25.00%    | 1.6034     | 0.0010       |
|    2   |    6     | 00:00:33    | 100.00%   | 0.0169     | 0.0010       |
=====

Network training complete.

Step 3 of 3: Training bounding box regression models for each object class...100.00%...done.

R-CNN training complete.
*****

```

Figura 90 Quinto entrenamiento de la CNN (variable Precipitación).

La Figura 91 y Figura 92, muestran los resultados obtenidos en el periodo de prueba ó fase de aprendizaje de las CNN's. Como se observa en ambas figuras se obtuvo un alto nivel de concordancia, por lo que el desarrollo de redes es eficaz y robusto para la detección de las zonas de riesgo en términos de temperatura y precipitación, las cuales pudieran poner en riesgo el crecimiento y reproducción del cultivo.

La Figura 92, correspondiente a la prueba de la CNN para la variable “Precipitación” muestra un mayor nivel de confianza en comparación con la variable “Temperatura”, lo cual pudiera ser como resultado de que a la CNN de la variable de “Precipitación” se realizaron más entrenamientos.

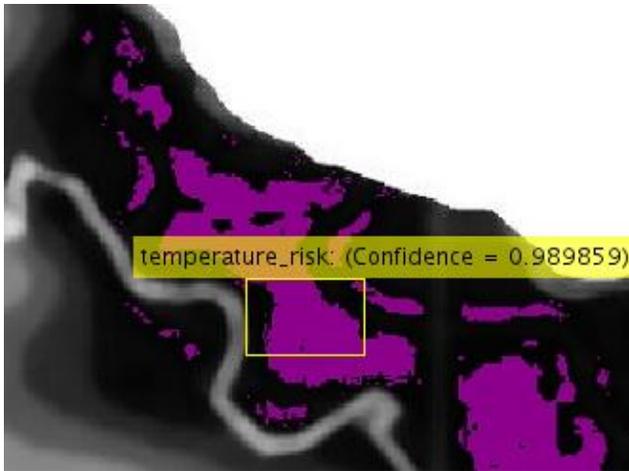


Figura 91 Nivel de confianza de la CNN de la variable Temperatura.

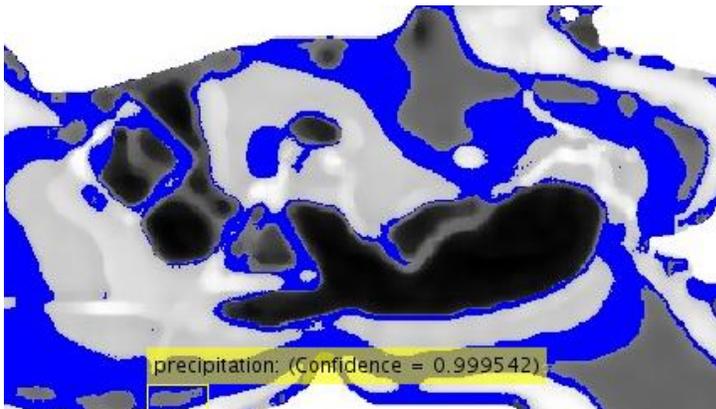


Figura 92 Nivel de confianza de la CNN de la variable Precipitación.

Para corroborar la efectividad de la predicción de la red convolucional mediante esta técnica se seleccionaron al azar un conjunto de 20 imágenes procesadas para cada variable, las cuales no fueron empleadas en el entrenamiento de la red convolucional para evitar predisposición por parte del software.

En las Figura 93 y Figura 94 se muestran los resultados obtenidos del nivel de confianza en la detección de la región de interés para la variable temperatura y precipitación, respectivamente. Las imágenes seleccionadas muestran regiones de diferentes tamaños en las zonas de riesgo detectadas por la CNN para verificar que las redes son capaces de detectar zonas de riesgo a menor y mayor escala para cada variable. Como se muestra en la Figura 93, se obtuvo un nivel de detección de entre 0.955 y 0.989 para la predicción de zonas de temperatura con riesgo para el cultivo; mientras que para la variable precipitación (Figura 94) se obtuvo un nivel de detección de 0.989 y 0.999.

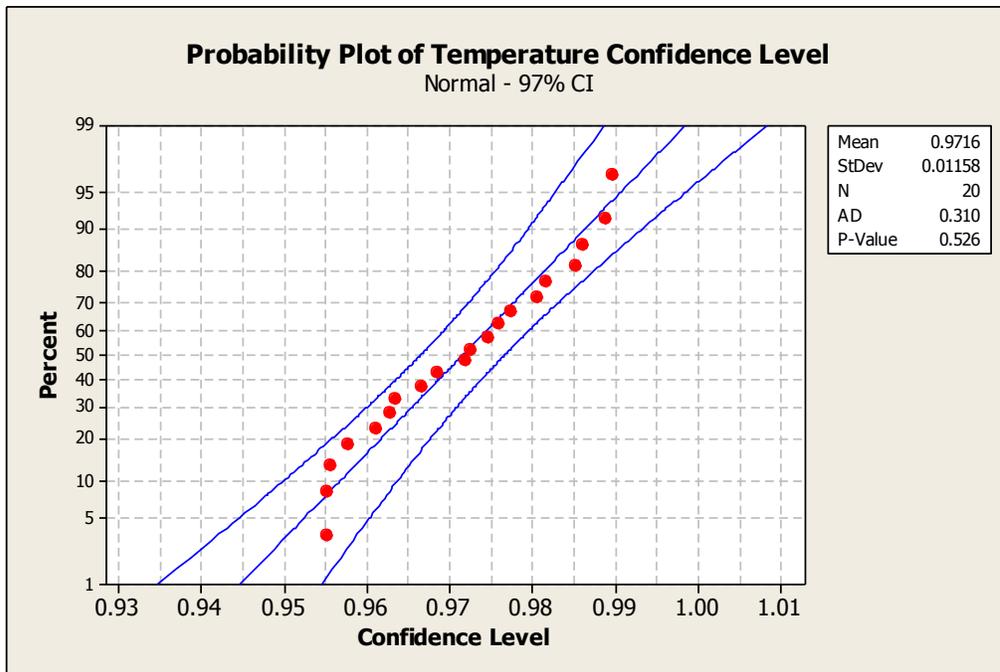


Figura 93 Probabilidad de detección de la variable Temperatura.

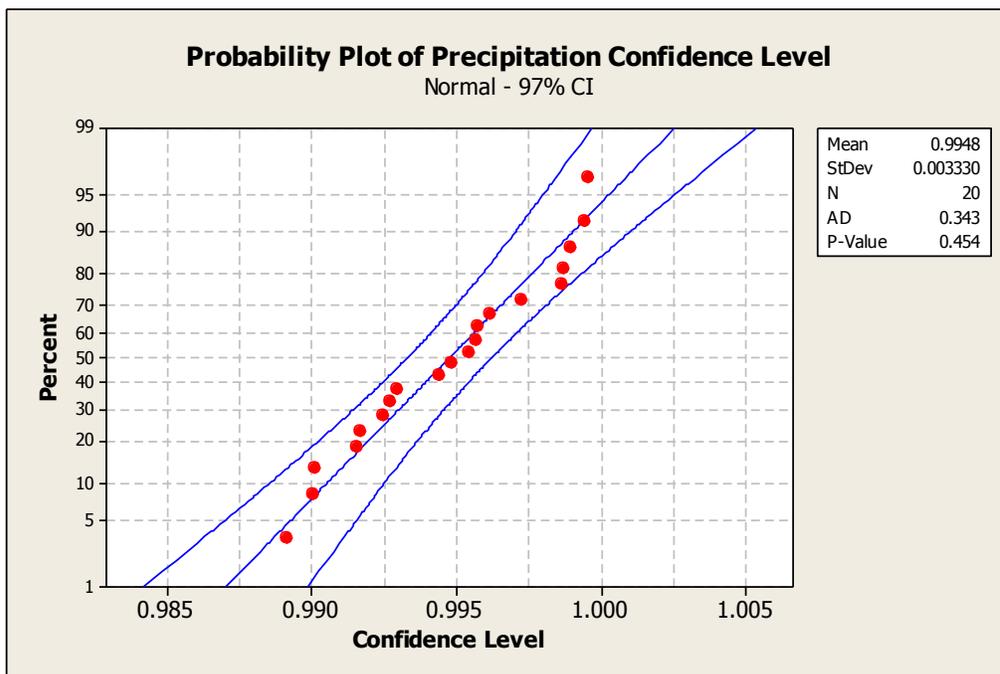


Figura 94 Probabilidad de detección de la variable Precipitación.

Como se observa en las figuras anteriores, los resultados mostrados por las redes neuronales convolucionales (CNN's) cumplen con las características necesarias para la detección de zonas que representen riesgo en la cosecha de caña en el área de estudio.

Con el desarrollo de este proceso se corrobora la efectividad de las CNN's, siendo una base sólida para poder detectar temperaturas superiores a 38°C, dado que a estos niveles de temperatura el proceso de fotosíntesis del cultivo es reducido, alterando la concentración de sacarosa y afectando el rebrote y/o germinación de caña de azúcar.

La red convolucional desarrollada para la detección de la variable precipitación es eficaz para detectar zonas con niveles de precipitación por debajo de 70 mm, los cuales originan que el agua se concentre en la raíz del cultivo y en menor proporción en la planta, reduciendo la capacidad productiva del cultivo.

## 5.6. Esquemas de trabajo

En esta sección, con base a los resultados obtenidos en la vulnerabilidad del cultivo de caña de azúcar, se presentan tres esquemas de trabajo que consideren acciones de adaptación cuando los niveles de vulnerabilidad en el cultivo aumentan, disminuyendo el rendimiento del cultivo a nivel cosecha y valor de la producción.

De acuerdo a la Figura 95, los principales componentes del sistema de producción, no sólo del cultivo de caña de azúcar, sino de la mayoría de los cultivos; está integrado por factores climatológicos, suelo y manejo. Los factores climáticos y los relacionados con el suelo son considerados parámetros inciertos; debido a que, aunque factores como el uso y fertilidad de suelo son ocasionados tanto por condiciones climáticas como por acciones antropogénicas, en este caso los indicadores de vulnerabilidad desarrollados en las redes de dinámica de sistemas consideran la degradación de suelos como factores relacionados por condiciones climatológicas. Por lo que los esquemas de trabajo son planteados con base a los posibles cambios y mejoras en el manejo de prácticas agrícolas.

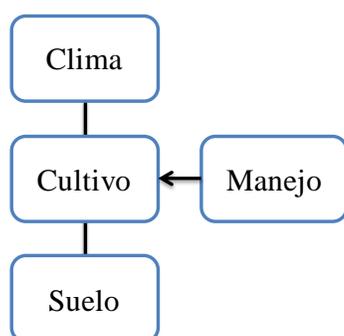


Figura 95 Esquema simplificado de los componentes del sistema de producción (PRONAC, 2009)

Con base a estudios reportados por el Programa Nacional de la Agroindustria de la Caña de Azúcar (PRONAC, 2009), encuestas realizadas a productores de caña de azúcar, el

46.9% de las observaciones señalaron que su principal rubro o aspecto para la producción de la caña de azúcar se centra en el uso y aplicación de fertilizantes y nitrificación de suelos al ser uno de los inconvenientes más frecuentes en el desarrollo del cultivo.

Los aspectos a considerar son la frecuencia de aplicación de fertilizantes en la caña de azúcar, la cual debe efectuarse dentro de los 12-16 meses de edad de la planta puesto que en ese tiempo la planta alcanza la concentración de sacarosa y pureza en su jugo. Además de la madurez de la caña, se deben considerar el rebrote de la caña durante varios ciclos con el fin de reducir los costos de producción; sin embargo, es necesario realizar una adecuada nutrición del suelo ya que a través de los ciclos se puede observar una disminución en el rendimiento del cultivo.

Asimismo, se evalúa si el suelo en el terreno de cultivo ha presentado algún tipo de empobrecimiento por sequía, de ser así, se recomienda optar por algún tipo de sistema de irrigación ya sea por gravedad, goteo o por aspersion; de lo contrario se puede continuar con sistema de riego temporal como comúnmente se maneja el cultivo de caña de azúcar en la región de estudio.

Para el desarrollo de los esquemas de trabajo se considera la fertilización foliar, es decir, a nivel del follaje de la planta; esto con el fin de reducir los problemas relacionados con la nutrición de suelo. Por lo que se considera la distribución de frecuencia de los nutrientes N-P-K por  $\text{Kg ha}^{-1}$  en dos diferentes cargas:  $\leq 50$  y 50-100 por tener una distribución proporcional en porcentaje de cada compuesto (N,  $\text{P}_2\text{O}_5$ ,  $\text{K}_2\text{O}$ ).

La aplicación de los fertilizantes a lo largo de cada ciclo ayuda a disminuir pérdidas por lixiviación, evitar salinización que inhiba el crecimiento de raíz. Es importante resaltar que el nitrógeno a menudo se aplica en dos o tres rondas durante el ciclo por su alta movilidad en el suelo (PRONAC, 2009; PRONAC et al., 2009).

La Figura 96, muestra el primer esquema de trabajo para el manejo del cultivo de caña de azúcar bajo condiciones de adaptación cuando los niveles de vulnerabilidad superan los valores obtenidos en la Tabla 30.

En el primer esquema se considera una aplicación de fertilizantes de los ciclos 1 a 5 debido a que dentro de este periodo la necesidad de plantar nuevamente es más baja según reportes generados por PRONAC. Como se observa en la figura, se muestran las proporciones (%) de la adición de nutrientes N-P-K para una carga de 50 a  $100 \text{ Kg ha}^{-1}$ . Únicamente son consideradas dos aplicaciones de fertilizantes ya que la distancia entre los ciclos es corta ( $<5$ ).

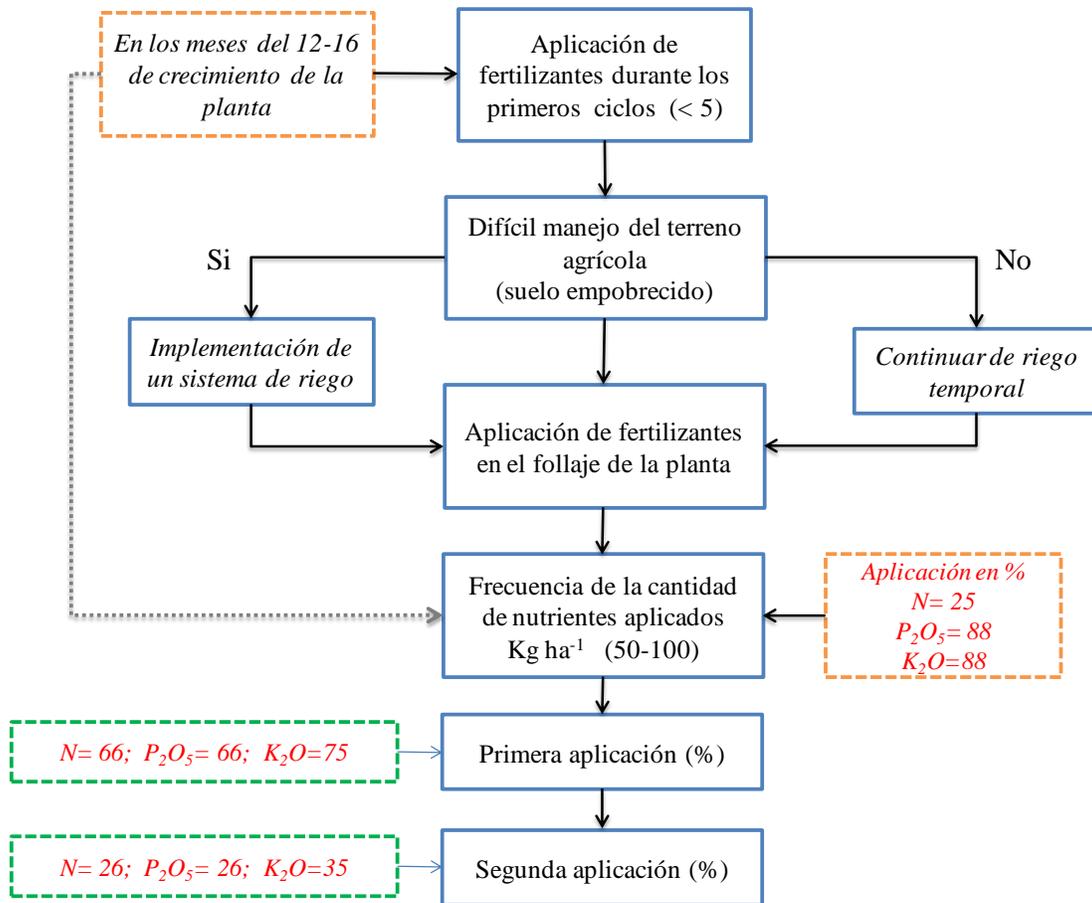


Figura 96 Primer esquema de adaptación para el cultivo de caña de azúcar

En el segundo esquema, se muestra una aplicación de fertilizantes cada 8 periodos o más debido a que la necesidad de plantar es media ( $\approx 35\%$ ) según datos reportados por PRONAC; de igual manera como en el primer esquema, se considera una carga de nutrientes N-P-K de 50 a 100  $\text{Kg ha}^{-1}$ . Debido a que la plantación entre los ciclos es más distante ( $>8$ ) se consideran tres aplicaciones de fertilizantes.

La Figura 97 muestra los parámetros descritos anteriormente y la proporción de cada nutriente para cada aplicación.

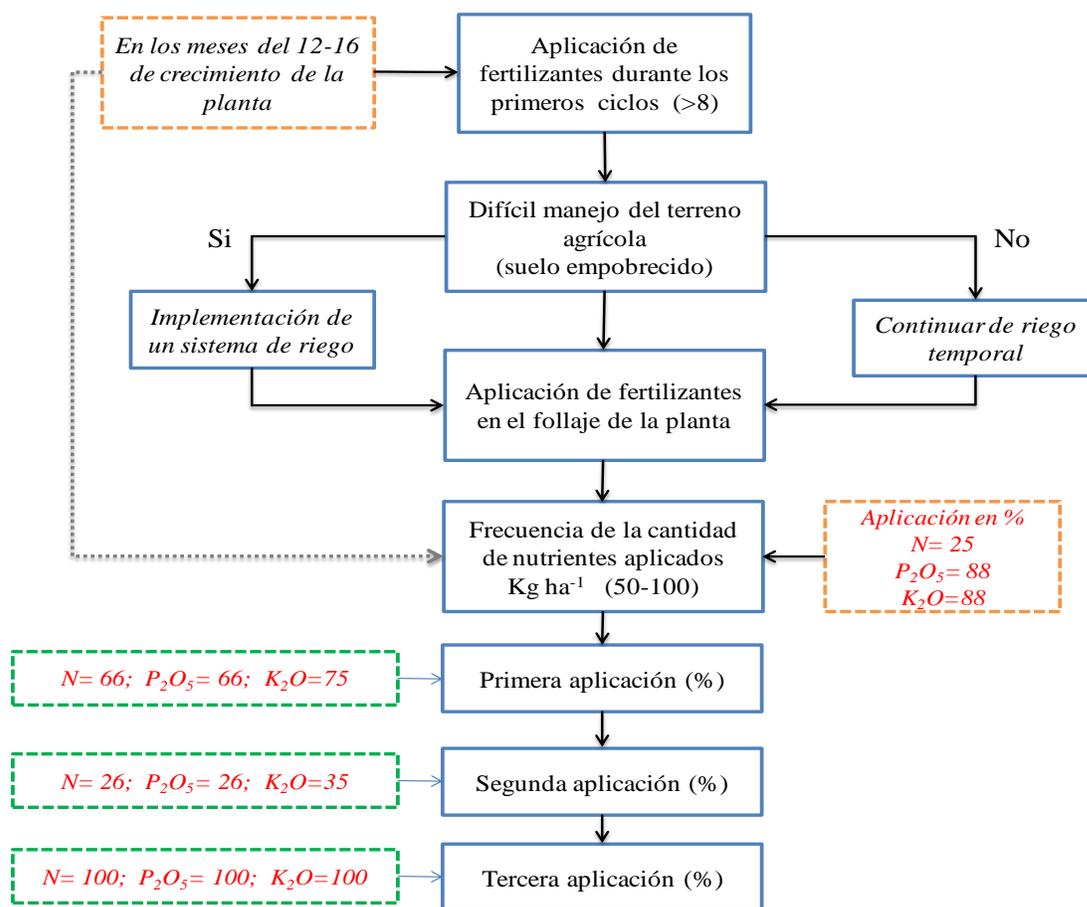


Figura 97 Segundo esquema de adaptación para el cultivo de caña de azúcar

La Figura 98, muestra el tercer esquema de trabajo considera una aplicación de fertilizantes durante los primeros 5 ciclos, considerando una carga menor a los 50 Kg ha<sup>-1</sup>, por lo que la aplicación de fertilizantes será a dos aplicaciones con una concentración inicial mayor.

A continuación se muestran los parámetros para la adición de fertilizantes en el tercer esquema<sup>1</sup>.

<sup>1</sup> Los valores establecidos para la aplicación de fertilizantes para los esquemas: 1, 2 y 3 son establecidos con base a datos abiertos proporcionados por el Programa Nacional de la Agroindustria de la Caña de Azúcar (PRONAC).

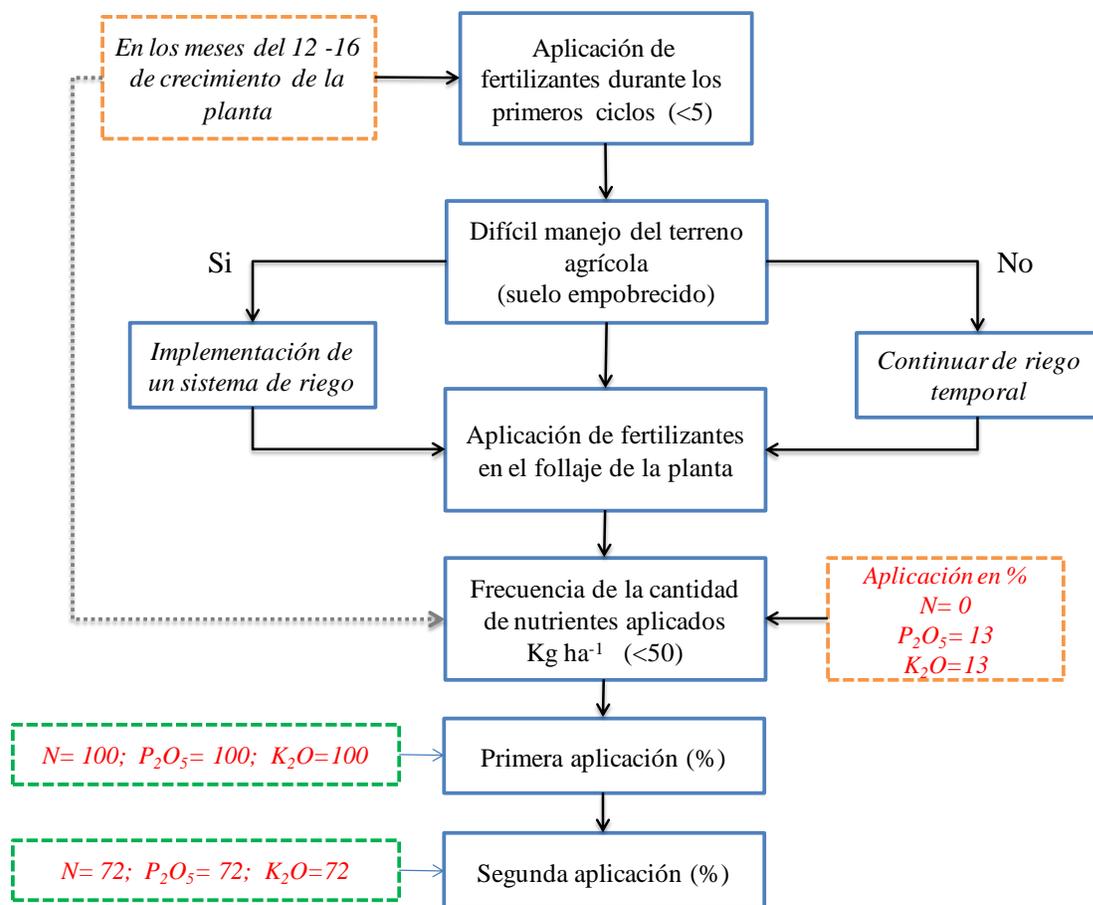


Figura 98 Tercer esquema de adaptación para el cultivo de caña de azúcar

Los esquemas anteriores tienen características similares, únicamente se realizan ciertos cambios en el porcentaje de adición de fertilizantes el cual varían en función de los tiempos de adición entre cada ciclo y la carga ( $\text{Kg ha}^{-1}$ ) dependiendo de los requerimientos del suelo y el cultivo.

## 5.7. Discusión de resultados

La incertidumbre juega un papel importante al momento de realizar proyecciones y estimaciones climáticas de vulnerabilidad (Nelson et al., 2009). La modelación de los parámetros inciertos permite hacer estimaciones en su comportamiento y en la manera que puedan impactar al sistema.

De acuerdo con (Li and Chan, 2013), “los sistemas basados en agentes se caracterizan por comprender varios agentes virtuales que son en mayor o menor grado autónomos, heterogéneos e independientes, que muestran cada uno sus propias metas y objetivos”.

Puesto que; un modelo basado en agentes es un modelo que contiene agentes heterogéneos que actúan en un mismo entorno, el uso de técnicas de IA (dinámica de sistemas y lógica difusa) en los modelos basado en agentes permite, bajo un enfoque sistémico el estudio del comportamiento y efectos resultado de las múltiples interacciones entre las variables.

Dentro de los resultados obtenidos en el sistema multi-agente, el agente de indicadores de vulnerabilidad se determinó un mayor impacto proveniente de la contingencia ambiental como resultado del incremento en emisiones GEI del sector agrícola ( $\text{SF}_6$ , PFC,  $\text{N}_2\text{O}$ ,  $\text{CO}_2$ ,  $\text{CH}_4$ , HFC) y el crecimiento exponencial en la incidencia de fenómenos meteorológicos que afectan la cosecha agrícola. En este sentido, factores como pérdida en las cosechas, disminución de recursos, poca fertilidad de terrenos agrícola, el bajo índice de productividad, ponen en riesgo el buen desarrollo de las actividades agrícolas afectando el valor de las actividades agrícolas haciendo más vulnerable el sector agrícola.

La industria cañera trae consigo impactos negativos al medio ambiente; razón por la cual ha optado por la incursión de prácticas sustentables en el desarrollo del cultivo, administración eficiente de recursos, manejo adecuado de residuos y emisiones. Sin embargo, aún con la implementación de éstas medidas, es un sector vulnerable caracterizado por factores climatológicos y por el manejo de economías a escala dado el volumen de cosecha obtenido durante el periodo de zafra; el cual, ha sido un factor determinante para elevar los costos de producción ante la creciente tendencia de la demanda de superficie de cosecha, originando una disminución en el rendimiento de la caña de azúcar.

Con la obtención de superficies de respuesta a través de lógica difusa en el “*Agente vulnerabilidad de cultivo*” se determinaron las áreas con mayor probabilidad de vulnerabilidad del sistema mediante la comparación de las variables del plano X, Y, Z, con lo cual se determinó que el rendimiento observado de la producción de azúcar en el estado de Veracruz está intrínsecamente relacionado con cambios en las condiciones climáticas originados por el calentamiento global, tales como cambios en precipitaciones y fenómenos meteorológicos extremos produciendo efectos adversos en la producción agropecuaria e incrementando el riesgo en la cosecha.

Con el desarrollo de modelos basados en agentes (ABM) se obtuvo una vulnerabilidad de 0.47 considerada moderada. La categorización de vulnerabilidad es vital en la toma de decisiones, pues permite conocer el grado de vulnerabilidad-riesgo existente en el sistema, permite determinar qué medidas de adaptación serán las más efectivas para mitigar el impacto.

Actualmente se han desarrollado modelos y metodologías (Eza et al., 2015; Fourcade, 2016; Mitter et al., 2015; Popke et al., 2016) para determinar la vulnerabilidad ante cambio climático por medio de indicadores agroclimáticos, centrándose en la parte ambiental.

La metodología de la presente investigación involucra las etapas de: análisis, desarrollo y simulación a través de un sistema basado en agentes inteligentes para modelar sistemas complejos integrados por redes, que a su vez son conformadas por un número de entidades (variables socioeconómicas y ambientales) que trabajan de manera conjunta por un objetivo; permitiendo alcanzar una comprensión estructural del sistema. El modelo propuesto involucra variables externas (etapa 1) e internas muy específicas del caso de estudio (etapa 2) inmersas en un entorno caracterizado por incertidumbre y dinamismo; además de caracterizarse por flexibilidad (intervención de agentes reactivos) y adaptabilidad para conducirse ante cambios inesperados en escenarios, ya sea por cambios en la tendencia esperada ó en el objeto de estudio.

Un sistema multi-agente permite caracterizar un sistema de estudio complejo (Pino et al., 2010), principalmente cadenas de suministro donde intervienen diversos actores o agentes. La implementación de un sistema multi-agente para la estimación de vulnerabilidad proporciona:

- i. Dinamismo, puesto que el estudio de sistemas complejos aborda problemas a micro-nivel, por la relación causa y efecto definidos en el diagrama causal (Figura 21); y macro-nivel, donde se estudian las relaciones entre los subsistemas elementales (Figura 22, Figura 23, Figura 24 y Figura 25).
- ii. Flexibilidad, en este caso la interacción de un agente reactivo proporciona flexibilidad al sistema multi-agente para realizar cambios dentro del sistema para el cumplimiento del objetivo; además de la facultad de desarrollar esquemas de trabajo que conlleven a acción de adaptación (Figuras 96-98). En la etapa 2, al ejecutar el agente reactivo (*modelo de desordenes no nutrimentales*) es posible reducir la vulnerabilidad (Figura 82).
- iii. Adaptabilidad. El sistema multi-agente al ser un modelo genérico, proporciona las bases para evaluar la vulnerabilidad de cultivos con características semejantes al cultivo de estudio (caña de azúcar) a través de variaciones en las variables dinámicas del modelo referente a las características del cultivo, zona de estudio; mientras que para los modelos difusos es necesario hacer cambios las reglas de inferencia, principalmente.

El desarrollo del modelo de riesgo a través de procesamiento de imágenes permite funcionalidades de presentación, búsqueda y navegación a través de un repositorio de imágenes para las variables de interés: temperatura y precipitación. El sistema se basa en la

identificación y reconocimiento de ciertas características como el color y zona de estudio, las cuales permiten detectar el riesgo en la cosecha. Las características fueron evaluadas manualmente a escala local, debido a que sólo se analizó una zona de interés. La implementación de sistemas manuales permiten realizar modificaciones en el procesamiento de imágenes (binarización, reducción de ruido, suavizado) dependiendo de las necesidades y requerimientos del analista, con el fin de obtener resultados más precisos y fiables.

Asimismo, el desarrollo de la red neuronal convolucional (CNN) permite emular el proceso de aprendizaje humano gracias al entrenamiento de un repositorio de imágenes previamente procesadas. Para el entrenamiento de cada red neuronal convolucional, se empleó una base de datos conformada por 25 imágenes procesadas de cada variable. Las CNN's se apoyan en el Proceso Digital de Imágenes (DIP) y Deep Learning para extraer información de las características deseadas más eficiente.

Con la fase de "*prueba de efectividad*" de las CNN's, se obtuvo una detección de 0.989859 y 0.999542 para la evaluación de riesgo de los parámetros temperatura y precipitación, respectivamente. Posteriormente, en el proceso de validación de CNN's se realizaron 20 pruebas para cada una, en donde se obtuvieron valores medios de detección de temperaturas de 0.9716 y precipitación de 0.9948; por lo que las redes cumplen con las características necesarias para la detección de zonas que representen riesgo para la cosecha de caña de azúcar en la zona de estudio.

## Conclusiones

Los sistemas agrícolas se encuentran en continua evolución por su capacidad de respuesta ante cambios climáticos, sociales y económicos. La modelación de parámetros inciertos permite realizar estimaciones en los patrones de comportamiento y los posibles impactos dentro del sistema; en este sentido, la vulnerabilidad debe analizarse como una condición sistémica y dinámica (IPCC, 2007).

Los modelos basados en agentes (ABM) tienen la capacidad de analizar y simular propiedades emergentes del sistema agrícola mediante el flujo de información e interacción de agentes virtuales. El ABM desarrollado está integrado por redes de agentes diseñadas a través de técnicas de IA que permiten el estudio del comportamiento y las interacciones de los agentes que integran las redes.

El agente de indicadores de vulnerabilidad mostró un mayor impacto proveniente de la contingencia ambiental por aumento de emisiones GEI, así como el crecimiento exponencial de fenómenos meteorológicos que ponen en riesgo la cosecha agrícola. Asimismo, factores como pérdida en las cosechas, disminución de recursos, pérdida de fertilidad de suelo, ponen en riesgo el buen desarrollo de las actividades agrícolas afectando el valor de la agricultura, y por consiguiente, haciendo más vulnerable al sector agrícola.

El agente vulnerabilidad de cultivo mostró las condiciones óptimas de producción relacionadas con prácticas agrícolas y nutrición de suelos para lograr un mayor rendimiento del cultivo de caña de azúcar. El mayor rendimiento esperado oscila entre 76~81 Ton/Ha con relación a las variables N-P-K (nitrógeno, fósforo y potasio) relacionadas con la nutrición de suelos. La implementación de fertilizantes es decisiva para la productividad de las plantaciones; ya que aporta aquellos nutrientes deficientes en el suelo agrícola originados por degradación de suelos o por efectos del cambio climático, contrarrestando efectos salinos que inhiban el crecimiento de caña de azúcar.

El agente reactivo permite modelar indicadores fisicoquímicos de la condición edáfica en el área de abasto del ingenio para predecir la eficiencia del suelo agrícola; ayudado así, a contrarrestar la vulnerabilidad del cultivo, logrando una disminución del 8% de vulnerabilidad del cultivo de caña de azúcar. El modelo basado en agentes se obtuvo una vulnerabilidad de 0.47, considerada moderada.

El modelo de riesgo a través de procesamiento de imágenes permite búsqueda y detección de las zonas que podrían potencialmente representar un riesgo en la cosecha. Las variables de interés a detectar mediante el procesamiento de imágenes son: Temperatura y Precipitación. La red neuronal convolucional (CNN) desarrollada para la variable temperatura permite detectar temperaturas superiores a 38°C, dado que a estos niveles de

temperatura el proceso de fotosíntesis del cultivo es reducido, alterando la concentración de sacarosa y afectando el rebrote y/o germinación de caña de azúcar. Asimismo, la CNN desarrollada para la detección de la variable precipitación es eficaz para detectar zonas con niveles de precipitación por debajo de 70 mm, los cuales originan que el agua se concentre en la raíz de la caña y en una menor proporción en la planta, reduciendo la capacidad productiva de la caña de azúcar.

Las CNN's se desarrollaron a través Proceso Digital de Imágenes (DIP) y Deep Learning para facilitar la extracción de información de las características deseadas. El proceso de entrenamiento de las CNN's se alimentó de un repositorio de imágenes previamente procesadas; posteriormente se realizó la "fase de prueba" para determinar la certeza de detección de cada red, obteniéndose valores medios de detección de 0.9716 y 0.9948 para las variables temperatura y precipitación, respectivamente. Por lo que, este proceso corrobora la efectividad de las CNN's siendo una base sólida para poder detectar de zonas que representen riesgo para la cosecha de caña de azúcar en la zona de estudio.

- **Evolución del estado del arte**

El objetivo del análisis del estado del arte de esta investigación es el estudio del riesgo y vulnerabilidad en sistemas agrícolas a través de técnicas de inteligencia artificial y procesamiento de imágenes para evaluar impactos originados por cambio climático en sistemas agrícolas.

Principalmente se abordan estudios de los impactos en la agricultura producto de cambio climático, los cuales emplean metodologías y modelos de simulación como herramienta para representar sistemas agrícolas y poder realizar estimaciones cuantitativas de futuros impactos y consecuencias para la productividad y otros servicios agrícolas; por otro lado, existen modelos que por su parte se centran en realizar estimaciones sobre la producción o rendimiento agrícola (Eza et al., 2015; Paloviita et al., 2016).

Los modelos desarrollados conforman sistemas de información basados en indicadores ambientales, que en su mayoría excluyen variables socioeconómicas y sólo buscan la caracterización ambiental. Éstos indicadores ambientales, son desarrollados para detectar los riesgos relacionados con el clima durante la gestión de la actividad agrícola, los indicadores empleados, contemplan variables como longitud de las ondas de calor, número de días de heladas, cálculo de precipitaciones durante periodos específicos y precipitación (López Guevara, 2015; Moreno Reséndez et al., 2011; Popke et al., 2016). Otros trabajos realizados por (de Carvalho-Pinto et al., 2007; Espínola et al., 2016; Fourcade, 2016; Maguire, 2013) comprenden el uso de nuevas tecnologías, como sistemas de posicionamiento global (GPS), sensores e imágenes satelitales y aéreas, sistemas de

información geográfica (GIS); este tipo de herramientas son aplicadas en el área agrícola y recursos naturales para analizar la evolución del cambio climático en una región geográfica en particular y poder realizar proyecciones futuras para prevención de desastres.

A su vez, se han realizado estudios sobre el análisis del desarrollo de sistemas multi-agente, los cuales son empleados en la modelación del uso de tierras, cobertura de suelos y en el intercambio de información a través de redes integradas por agentes, en donde los agentes interactúan directamente para modelar variables de decisión (Bousquet and Le Page, 2004; Kremmydas et al., 2018; O'Sullivan et al., 2016; Schlüter et al., 2017).

- **Aportación al conocimiento científico**

La contribución al estado del arte y al conocimiento es un modelo basado en agentes que sirva como apoyo a la decisión, aportando principalmente en los siguientes aspectos:

- i. Modelo integrado por indicadores agroclimáticos de vulnerabilidad capaz de representar causas estructurales del sistema bajo condiciones de incertidumbre y dinamismo.
- ii. El sistema de estudio está modelado por series de tiempo, dinámica de sistemas, parámetros inciertos, minería de datos y expertís; facilitando el estudio, comprensión y análisis del objeto de estudio permitiendo evaluar distintos escenarios resultado de variaciones en la tendencia en aspectos como la producción agrícola, incidencia de fenómenos meteorológicos, reducción de recursos, etc.
- iii. El desarrollo e implementación del modelo basado en agentes (ABM) permite la capitalización del conocimiento mediante características como habilidad social y autonomía de los agentes modelados a través de técnicas de inteligencia artificial.
- iv. El desarrollo del agente reactivo mostró una disminución en los niveles de vulnerabilidad como se muestra en la Tabla 30; por lo que el ABM no sólo busca la caracterización del sistema para determinar la vulnerabilidad existente, sino que además permite tomar decisiones para lograr minimizar niveles de vulnerabilidad para aumentar el rendimiento de la cosecha y valor de producción.

- **Aportación al desarrollo tecnológico**

La aportación al desarrollo tecnológico de esta investigación es un Sistema de Apoyo a la Decisión (SAD) integrado por una plataforma de Modelado Basado en Agentes desarrollados por técnicas de Inteligencia Artificial para determinar la vulnerabilidad y el riesgo agrícola del cultivo de caña de azúcar mediante la determinación de las principales variables socioeconómicas y ecológicas.

Dentro de las principales ventajas que ofrece el SAD, se encuentran:

- i. El desarrollo del SAD servirá como herramienta para agricultores a menor, mediana y mayor escala. Para el propósito y validación de ésta investigación el SAD fue diseñado para un ingenio ubicado en Lerdo de Tejada, Veracruz; sin embargo, el SAD bien puede ser utilizado por un organismo a menor escala.
- ii. El empleo del SAD puede realizarse a través del conocimiento de información particular (condiciones edáficas del área de cultivo, manejo de prácticas agrícolas, requerimientos nutricionales, hectáreas sembradas y cosechadas) e información general (condiciones climáticas).
- iii. El escalamiento de SAD para la determinación de vulnerabilidad y riesgo puede realizarse con información actualizada en los indicadores desarrollados en el Modelo Agentes de Vulnerabilidad, la cual fue obtenida por organismos abiertos como señalan las Tabla 7, Tabla 8 y Tabla 9. Asimismo, el SAD puede adaptarse a otra región de estudio y tipo de cultivo; para ello, es necesario actualizar información relacionada a condiciones edáficas de la región deseada, terrenos agrícolas, disponibilidad de recursos hídricos y frecuencia en la incidencia de fenómenos climáticos. Estas modificaciones deben realizarse en las redes: rendimiento de tierra agrícola, eficiencia de los recursos hídricos y situación de riesgo o emergencia; ya que las redes incluyen valores referente a datos del estado de Veracruz.
- iv. El propósito del SAD es ayudar a los usuarios a maximizar el rendimiento del cultivo a través de generar esquemas de trabajo que conlleven al desarrollo de acciones de adaptación y/o mitigación para hacer frente al cambio climático.

## Referencias

- Alder, J., Benin, S., Cassman, K. G., Cooper, H. D., Johns, T., Gaskell, J., ... Devendra, C. (2005). Food. In A. M. Balisacan & P. Gardine (Eds.), M.E.A.W.I.P., Alder, J., Benin, S., Cassman, K. G., Cooper, H. D., Johns, T., Gaskell, J., ... Devendra, C. (2005). <https://doi.org/10.1073/pnas.1219441110>
- Aparicio Martín de Loeches, A.F.G.L., 2014. Reconocimiento óptico de caracteres en imágenes digitales de contadores de gas. Univ. Complut. MADRID.
- Araus, J.L., Slafer, G.A., Royo, C., Serret, M.D., 2008. Breeding for yield potential and stress adaptation in cereals. *CRC. Crit. Rev. Plant Sci.* <https://doi.org/10.1080/07352680802467736>
- Barnabás, B., Jäger, K., Fehér, A., 2008. The effect of drought and heat stress on reproductive processes in cereals. *Plant, Cell Environ.* <https://doi.org/10.1111/j.1365-3040.2007.01727.x>
- Barr, R., Fankhauser, S., Hamilton, K., 2010. Adaptation investments: A resource allocation framework. *Mitig. Adapt. Strateg. Glob. Chang.* <https://doi.org/10.1007/s11027-010-9242-1>
- Bastida Tapia, A., 2017. Evolución y Situación Actual de la Agricultura Protegida en México. *Memorias, sexto Congr. Int. Investig. ciencias básicas y agronómicas* 281–294.
- Below, T.B., Mutabazi, K.D., Kirschke, D., Franke, C., Sieber, S., Siebert, R., Tscherning, K., 2012. Can farmers' adaptation to climate change be explained by socio-economic household-level variables? *Glob. Environ. Chang.* <https://doi.org/10.1016/j.gloenvcha.2011.11.012>
- Bousquet, F., Le Page, C., 2004. Multi-agent simulations and ecosystem management: A review. *Ecol. Modell.* <https://doi.org/10.1016/j.ecolmodel.2004.01.011>
- Campuzano-Bolarín, F., Martínez-Caro, E., Ros-McDonell, L., 2010. Cadenas de suministro tradicionales y colaborativas. (Spanish). *DYNA - Ing. e Ind.*
- Cardona, O., 2001. Vulnerabilidad y el riesgo desde una perspectiva holística, in: *Estimación Holística Del Riesgo Sísmico Utilizando Sistemas Dinámicos Complejos.*
- Cedillo-Campos, M.G., 2008. *Análisis dinámico de sistemas industriales*, First Edit. ed. Trillas, México.
- CENAPRED, 2018. Centro Nacional de Prevención de Desastres [WWW Document]. URL <https://www.gob.mx/cenapred>
- Chavez Guillén, R.M., 2010. *Dinámica de sistemas. Diagramas causales.*
- CONADESUCA, 2018. Programa Nacional de la Agroindustria de la Caña de Azúcar.
- CONADESUCA, n.d. Comité Nacional para el Desarrollo Sustentable de la Caña de Azúcar [WWW Document]. URL <https://www.gob.mx/conadesuca/>
- CONAFOR, 2016. Comisión Nacional Forestal [WWW Document]. URL <https://www.gob.mx/conafor>
- CONAGUA, 2018. Comisión Nacional del Agua [WWW Document]. URL <https://smn.conagua.gob.mx/es/climatologia/informacion-climatologica/informacion-estadistica-climatologica>
- CONAGUA, 2015. *Atlas de vulnerabilidad hídrica en México ante el cambio climático.*
- Conde-Álvarez, A.C., 2003. Cambio y variabilidad climáticos, dos estudios de caso en México. *Posgrado en Ciencias de la Tierra UNAM.*
- CONDE, C., 2011. *MEXICO Y EL CAMBIO CLIMÁTICO.* SEMARTNAT.
- Conde, C., Eakin, H., 2003. Adaptation to climatic variability and change in Tlaxcala, Mexico, in: *Climate Change, Adaptive Capacity and Development.* [https://doi.org/10.1142/9781860945816\\_0011](https://doi.org/10.1142/9781860945816_0011)
- CONEVAL, 2018. Consejo Nacional de Evaluación de la Política de Desarrollo Social [WWW Document]. *Pobr. en México 2008-2018.* URL <https://www.coneval.org.mx/Medicion/Paginas/PobrezaInicio.aspx>
- Connor, R.F., Hiroki, K., 2005. Development of a method for assessing flood vulnerability. *Water Sci. Technol.* <https://doi.org/10.2166/wst.2005.0109>
- Dalal, N., Triggs, B., 2005. Histograms of oriented gradients for human detection, in: *Proceedings -*

- 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005. <https://doi.org/10.1109/CVPR.2005.177>
- de Carvalho-Pinto, F. de A., de Queiroz, D.M., Chartuni, E., Ruz, E., 2007. Agricultura de precisión: nuevas herramientas para mejorar la gestión tecnológica en la empresa agropecuaria. *Rev. Palmas*.
- Díaz Caravantes, R.E., 2018. Vulnerabilidad y riesgo como conceptos indisociables para el estudio del impacto del cambio climático en la salud. *región y Soc.* 30. <https://doi.org/10.22198/rys.2018.73.a968>
- Dieguez Cameroni, F.J., Terra, R., Tabarez, S., Bommel, P., Corral, J., Bartaburu, D., Pereira, M., Montes, E., Duarte, E., Morales Grosskopf, H., 2014. Virtual experiments using a participatory model to explore interactions between climatic variability and management decisions in extensive grazing systems in the basaltic region of Uruguay. *Agric. Syst.* <https://doi.org/10.1016/j.agsy.2014.07.002>
- Eakin, H., 2000. Smallholder maize production and climatic risk: A case study from Mexico. *Clim. Change.* <https://doi.org/10.1023/A:1005628631627>
- El Economista, 2015. Desastres Naturales [WWW Document]. *Desastr. Nat. cuestan a México.* URL <https://www.economista.com.mx/sectorfinanciero/Desastres-naturales-cuestan-a-Mexico-2942-mdp--20150304-0089.html>
- ENA, n.d. Encuesta Nacional Agropecuaria [WWW Document]. URL <https://datos.gob.mx/busca/dataset/encuesta-nacional-agropecuaria-ena>
- Espínola, M., Piedra-Fernández, J.A., Ayala, R., Iribarne, L., Leguizamón, S., Wang, J.Z., 2016. Simulating rainfall, water evaporation and groundwater flow in three-dimensional satellite images with cellular automata. *Simul. Model. Pract. Theory.* <https://doi.org/10.1016/j.simpat.2016.07.003>
- Eza, U., Shtiliyanova, A., Borrás, D., Bellocchi, G., Carrère, P., Martin, R., 2015. An open platform to assess vulnerabilities to climate change: An application to agricultural systems. *Ecol. Inform.* <https://doi.org/10.1016/j.ecoinf.2015.10.009>
- Food and Agriculture Organization, 2017. Indicator [WWW Document]. *Cereal yield (kg per hectare).* URL <https://datos.bancomundial.org/indicador/AG.YLD.CREL.KG?view=chart> (accessed 10.21.19).
- Forrester, J.W., Senge, P.M., 1980. Tests for building confidence in system dynamics models. *TIMS Stud. Manag. Sci.*
- Fourcade, Y., 2016. Comparing species distributions modelled from occurrence data and from expert-based range maps. Implication for predicting range shifts with climate change. *Ecol. Inform.* <https://doi.org/10.1016/j.ecoinf.2016.09.002>
- Fowler, H.J., Kilsby, C.G., O'Connell, P.E., 2003. Modeling the impacts of climatic change and variability on the reliability, resilience, and vulnerability of a water resource system. *Water Resour. Res.* <https://doi.org/10.1029/2002WR001778>
- G.A., M., P., M., R., P., D., S., H., P., H., H., 1999. Guidelines for applying multi-criteria analysis to the assessment of criteria and indicators, Guidelines for applying multi-criteria analysis to the assessment of criteria and indicators. <https://doi.org/10.17528/cifor/000769>
- García, J.M., 2017. Curso online de creación de modelos de simulación con Dinámica de Sistemas. *Ejercicios avanzados en Dinámica de Sistemas.* Atc-Innova.Com.
- Gay, C., Estrada, F., 2010. Objective probabilities about future climate are a matter of opinion. *Clim. Change.* <https://doi.org/10.1007/s10584-009-9681-4>
- Gay, C., Estrada, F., Conde, C., 2007. Some implications of time series analysis for describing climatologic conditions and for forecasting. An illustrative case: Veracruz, México. *Atmosfera.*
- Gay, C., Estrada, F., Conde, C., Eakin, H., 2004. Impactos Potenciales del Cambio Climático en la Agricultura: Escenarios de Producción de Café para el 2050 en Veracruz (México). *El clima entre el Mar y la Montaña.*

- Gobierno de la República Mexicana, 2014. Programa Especial de Cambio Climático 2014-2018 (PECC). Plan Nac. Desarro. 2013-2018.
- Greenpeace, 2017. La agricultura mexicana y el cambio climático [WWW Document]. La Agric. Mex. y el cambio climático. URL <https://agua.org.mx/wp-content/uploads/2017/09/La-agricultura-mexicana-y-el-cambio-climático.pdf>
- Grosan, C., Abraham, A., 2011. Fuzzy Expert Systems. *Intell. Syst. Ref. Libr.* [https://doi.org/10.1007/978-3-642-21004-4\\_9](https://doi.org/10.1007/978-3-642-21004-4_9)
- Hípola Ruiz, P., Vargas Quesada, B., 1999. Agentes inteligentes: definición y tipología. *Los agentes de información. El Prof. la Inf.* 8.
- Holman, I.P., Brown, C., Janes, V., Sandars, D., 2017. Can we be certain about future land use change in Europe? A multi-scenario, integrated-assessment analysis. *Agric. Syst.* <https://doi.org/10.1016/j.agry.2016.12.001>
- IFAD, 2010. Evidence from the Intergovernmental Panel on Climate Change. *Livest. Themat. Pap.* Enabling poor Rural people to overcome poverty.
- IMCO, 2017. Instituto Mexicano para la Competitividad [WWW Document]. *Energía y Medio Ambient.* URL <https://imco.org.mx/area/energia-y-medio-ambiente/>
- INECC, 2018. Instituto Nacional de Ecología y Cambio Climático [WWW Document]. URL <https://www.gob.mx/inecc>
- INEGI, 2019. INSTITUTO NACIONAL DE GEOGRAFÍA Y ESTADÍSTICA [WWW Document]. PIB y cuentas Nac. URL <https://www.inegi.org.mx/temas/pib/> (accessed 9.20.09).
- INEGI, 2018a. Encuesta Nacional Agropecuaria ENA 2017 Conociendo el campo de México Resultados Conferencia de prensa 25 de julio de 2018.
- INEGI, 2018b. Instituto Nacional de Estadística Geografía e Información.
- INEGI, 2017. Encuesta Nacional Agropecuaria ENA 2017 Conociendo el campo de México Resultados Conferencia de prensa 25 de julio de 2018 41.
- Inifap, 2018. Instituto Nacional de Investigaciones Forestales Agrícolas y Pecuarias [WWW Document]. URL <https://www.gob.mx/inifap>
- Ippc, 2007. *Climate Change 2007: impacts, adaptation and vulnerability: contribution of Working Group II to the fourth assessment report of the Intergovernmental Panel*, Ginebra, Suíza. <https://doi.org/10.1256/004316502320517344>
- IPCC, I.P.O.C.C., 2007. *Climate Change 2007 - The Physical Science Basis: Working Group I Contribution to the Fourth Assessment Report of the IPCC. Science (80-. )*. <https://doi.org/volume>
- Jay Forrester (1918), ingeniero eléctrico, 1961. *Dinamica-de-Sistemas - ¿Qué es la dinámica de sistemas?* [WWW Document]. First Ed.
- Jensen, B.A., Joseph, B., Lipták, B.G., 2005. Expert systems, in: *Instrument Engineers Handbook, Fourth Edition: Process Control and Optimization*. <https://doi.org/10.4135/9781452226620.n23>
- Jones, J.W., Antle, J.M., Basso, B., Boote, K.J., Conant, R.T., Foster, I., Godfray, H.C.J., Herrero, M., Howitt, R.E., Janssen, S., Keating, B.A., Munoz-Carpena, R., Porter, C.H., Rosenzweig, C., Wheeler, T.R., 2017. Toward a new generation of agricultural system data, models, and knowledge products: State of agricultural systems science. *Agric. Syst.* <https://doi.org/10.1016/j.agry.2016.09.021>
- Kremmydas, D., Athanasiadis, I.N., Rozakis, S., 2018. A review of Agent Based Modeling for agricultural policy evaluation. *Agric. Syst.* <https://doi.org/10.1016/j.agry.2018.03.010>
- Li, J., Chan, F.T.S., 2013. An agent-based model of supply chains with dynamic structures. *Appl. Math. Model.* <https://doi.org/10.1016/j.apm.2012.10.054>
- Liao, S.H., 2005. Expert system methodologies and applications-a decade review from 1995 to 2004. *Expert Syst. Appl.* <https://doi.org/10.1016/j.eswa.2004.08.003>
- Ligon, E., Schechter, L., 2003. Measuring vulnerability. *Econ. J.* <https://doi.org/10.1111/1468-0297.00117>

- López Guevara, J.M., 2015. Análisis de riesgos climáticos sobre los componentes, recursos y medios de vida de los sistemas alimentarios del departamento de Copán en el año 2014. *Rev. Cienc. y Tecnol.* <https://doi.org/10.5377/rct.v0i16.2180>
- Magaña, V., 2012. Guía Metodológica para la Evaluación de la Vulnerabilidad ante Cambio Climático. Inst. Nac. Ecol. y Cambio Climático México (INECC), Programa las Nac. Unidas para el Desarro.
- Magaña, V., Zermeno, D., Neri, C., 2012. Climate change scenarios and potential impacts on water availability in northern Mexico. *Clim. Res.* <https://doi.org/10.3354/cr01080>
- Maguire, M.C., 2013. An analysis of specialist and non-specialist user requirements for geographic climate change information. *Appl. Ergon.* <https://doi.org/10.1016/j.apergo.2013.03.029>
- Martinez Bahena, G., 2012. La inteligencia artificial y su aplicación al campo del Derecho. Alegatos.
- Matthews, R.B., Gilbert, N.G., Roach, A., Polhill, J.G., Gotts, N.M., 2007. Agent-based land-use models: A review of applications. *Landsc. Ecol.* <https://doi.org/10.1007/s10980-007-9135-1>
- Mendel, J.M., 1995. Fuzzy Logic Systems for Engineering: A Tutorial. *Proc. IEEE.* <https://doi.org/10.1109/5.364485>
- Ministerio de Ambiente, V. y D. territorial, 2012. Guía Metodológica para la Evaluación de la Vulnerabilidad ante Cambio Climático Guía Metodológica para la Evaluación de la Vulnerabilidad ante Cambio Climático elaborado por Instituto Nacional de Ecología 60.
- Mitter, H., Heumesser, C., Schmid, E., 2015. Spatial modeling of robust crop production portfolios to assess agricultural vulnerability and adaptation to climate change. *Land use policy.* <https://doi.org/10.1016/j.landusepol.2015.01.010>
- Monterroso, A., Conde, A., Gómez, J., López, J., 2007. Vulnerabilidad y Riesgo en Agricultura por cambio climático en la Región Centro del Estado de Veracruz , México. *Zo. Áridas.*
- Monterroso, A., Conde, C., Gay, C., Gómez, J., López, J., 2013. INDICADORES DE VULNERABILIDAD Y CAMBIO CLIMÁTICO EN LA AGRICULTURA DE MÉXICO. *Cent. Ciencias la Atmósfera e Inst. Geogr. - UNAM.*
- Montoya Holguin, C., Cortés Osorio, J.A., Chaves Osorio, J.A., 2014. Sistema automático de reconocimiento de frutas basado en visión por computador. *Ingeniare. Rev. Chil. Ing.* <https://doi.org/10.4067/s0718-33052014000400006>
- Moreno Reséndez, A., Durón, J.A., Luévano González, A., 2011. Characteristics of protected agriculture and their environment in Mexico. *Rev. Mex. Agronegocios.*
- Munarriz, A., 1994. Fundamentos de la Inteligencia Artificial. C.E.S.
- Nedjah, N., Sandres, P.R.S.S., De Macedo Mourelle, L., 2014. Customizable hardware design of fuzzy controllers applied to autonomous car driving. *Expert Syst. Appl.* <https://doi.org/10.1016/j.eswa.2014.05.032>
- Nelson, G., Rosegrant, M., Koo, J., Robertson, R., Sulser, T., Zhu, T., Ringler, C., Msangi, S., Palazzo, A., Batka, M., Magalhaes, M., Valmonte-Santos, R., Ewing, M., Lee, D., 2009. Cambio climático. El impacto en la agricultura y los costos de adaptación. <https://doi.org/DOI:10.2499/0896295370>
- O'Brien, K., Leichenko, R., Kelkar, U., Venema, H., Aandahl, G., Tompkins, H., Javed, A., Bhadwal, S., Barg, S., Nygaard, L., West, J., 2004. Mapping vulnerability to multiple stressors: Climate change and globalization in India. *Glob. Environ. Chang.* <https://doi.org/10.1016/j.gloenvcha.2004.01.001>
- O'Sullivan, D., Evans, T., Manson, S., Metcalf, S., Ligmann-Zielinska, A., Bone, C., 2016. Strategic directions for agent-based modeling: avoiding the YAAWN syndrome. *J. Land Use Sci.* <https://doi.org/10.1080/1747423X.2015.1030463>
- Paloviita, A., Kortetmäki, T., Puupponen, A., Silvasti, T., 2016. Vulnerability matrix of the food system: Operationalizing vulnerability and addressing food security. *J. Clean. Prod.* <https://doi.org/10.1016/j.jclepro.2016.07.018>
- Pérez-Pérez, C.S., Nieto-Barajas, L.E., 2019. Hierarchical Analysis of Greenhouse Gas Emissions

- in Mexico. REALITY, DATA Sp. Int. J. Stat. Geogr. 10.
- Pielke, R.A., Wilby, R., Niyogi, D., Hossain, F., Dairuku, K., Adegoke, J., Kallos, G., Seastedt, T., Suding, K., 2013. Dealing with Complexity and Extreme Events Using a Bottom-Up, Resource-Based Vulnerability Perspective, in: Extreme Events and Natural Hazards: The Complexity Perspective. <https://doi.org/10.1029/2011GM001086>
- Pino, Raúl; Gómez, Alberto; de Abajo, N., 2007. Introducción a la ingeniería Artificial: Sistemas Expertos, Redes Neuronales Artificiales y Computación Evolutiva, Instituto Tecnológico de Nuevo Laredo.
- Pino, R., Fernández, I., de la Fuente, D., Parreño, J., Priore, P., 2010. Supply chain modelling using a multi-agent system. J. Adv. Manag. Res. <https://doi.org/10.1108/09727981011084968>
- Ponce Cruz, P., 2010. Inteligencia Artificial con aplicaciones a la ingeniería, Alfaomega, México.
- Popke, J., Curtis, S., Gamble, D.W., 2016. A social justice framing of climate change discourse and policy: Adaptation, resilience and vulnerability in a Jamaican agricultural landscape. Geoforum. <https://doi.org/10.1016/j.geoforum.2014.11.003>
- PRONAC, 2009. Programa Nacional de la Agroindustria de la Caña de Azúcar [WWW Document]. Diagnóstico, Model. y Recom. la Fertil. suelos del campo cañero. URL [http://www.cndsca.gob.mx/documentoseficproductiva/8.PRONAC/PRONAC 2014-2018.pdf](http://www.cndsca.gob.mx/documentoseficproductiva/8.PRONAC/PRONAC%202014-2018.pdf)
- PRONAC, P.N. de la A. de la C. de A., SIAP, S. de I.A. y P., COLPOS, C. de P., 2009. Digitalización del Campo Cañero en México para Alcanzar la Agricultura de Precisión de la Caña de Azúcar. Desarrollo de un Modelo Integral de Sistema de Información Geográfica y Edáfica.
- Pulighe, G., Lupia, F., 2016. Mapping spatial patterns of urban agriculture in Rome (Italy) using Google Earth and web-mapping services. Land use policy. <https://doi.org/10.1016/j.landusepol.2016.08.001>
- Reilly, J., Prinn, R., Harnisch, J., Fitzmaurice, J., Jacoby, H., Kicklighter, D., Melillo, J., Stone, P., Sokolov, A., Wang, C., 1999. Multi-gas assessment of the Kyoto protocol. Nature. <https://doi.org/10.1038/44069>
- Reséndez, M., Durón, A., González, L., 2011. Redalyc Characteristics of protected agriculture and their environment in Mexico 763–774.
- Reyes Anistro, G.I., Adame Martínez, S., Cadena Vargas, E., 2018. Vulnerabilidad ante la variabilidad climática en los cultivos de maíz Zea mays. Soc. y Ambient. <https://doi.org/10.31840/sya.v0i17.1842>
- Riveraa, N.R., 2012. Defining and measuring social vulnerability. Towards a normative approach. Defin. Meas. Soc. vulnerability. Towar. a Norm. approach.
- SAGARPA, 2018. Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación [WWW Document]. URL <https://www.gob.mx/agricultura>
- SAGARPA, 2013. Programa Sectorial de Desarrollo Agropecuario, Pesquero y Alimentario.
- SAGARPA, 2012. México: el sector agropecuario ante el desafío del cambio climático. Sagarpa I, 439.
- Sarbjit Kaur, sarbjitkhinda1991@gmail.com, 2016. An automatic number plate recognition system under image processing. Int. J. Intell. Syst. Appl. <https://doi.org/10.5815/ijisa.2016.03.02>
- Schlüter, M., Baeza, A., Dressler, G., Frank, K., Groeneveld, J., Jager, W., Janssen, M.A., McAllister, R.R.J., Müller, B., Orach, K., Schwarz, N., Wijermans, N., 2017. A framework for mapping and comparing behavioural theories in models of social-ecological systems. Ecol. Econ. <https://doi.org/10.1016/j.ecolecon.2016.08.008>
- SEMAR, 2105. EVISMAR [WWW Document]. Estac. Virtual Imágenes Satelitales. URL <https://www.gob.mx/semar/acciones-y-programas/estaciones-satelitales>
- SEMARNAT, 2016. Secretaría del Medio Ambiente y Recursos Naturales [WWW Document]. URL <https://www.gob.mx/semarnat>
- SEMARNAT, 2014. El medio ambiente en México [WWW Document]. Atmósfera. Cambio

- Climático. URL [https://apps1.semarnat.gob.mx:8443/dgeia/informe\\_resumen14/05\\_atmosfera/5\\_2\\_3.html](https://apps1.semarnat.gob.mx:8443/dgeia/informe_resumen14/05_atmosfera/5_2_3.html)
- Semenov, M.A., Halford, N.G., 2009. Identifying target traits and molecular mechanisms for wheat breeding under a changing climate, in: *Journal of Experimental Botany*. <https://doi.org/10.1093/jxb/erp164>
- Seminis, 2016. Seminis [WWW Document]. *Inf. Espac. para el campo Mex.* URL <https://www.seminis.mx/blog-informacion-geoespacial-para-el-campo-mexicano/>
- Shokouhyar, S., Seifhashemi, S., Siadat, H., Ahmadi, M.M., 2019. Implementing a fuzzy expert system for ensuring information technology supply chain. *Expert Syst.* 36. <https://doi.org/10.1111/exsy.12339>
- Shukla, S., 2016. Measuring vulnerability of agricultural sector towards climate change in Gujarat. *Trans. Inst. Indian Geogr.*
- SIAP, 2018. Servicio de Información Agroalimentaria y Pesquera. [WWW Document]. *Estadística Prod. Agrícola*. URL <http://infosiap.siap.gob.mx/gobmx/datosAbiertos.php>
- SIAP, 2016a. Información Geoespacial [WWW Document]. URL <https://www.gob.mx/siap/acciones-y-programas/informacion-geoespacial-32571>
- SIAP, 2016b. Servicio de Información Agroalimentaria y Pesquera [WWW Document]. URL <https://www.gob.mx/siap>
- SIAP, n.d. Servicio de Información Agroalimentaria y Pesquera [WWW Document]. URL <https://www.gob.mx/siap>
- Simón, Mauricio.; Peralta, Nahuel.; Costa, J.L., 2013. Relationship between apparent electrical conductivity with soil properties and nutrients. *Cienc. del Suelo*.
- Sivanandam, S.N., Sumathi, S., Deepa, S.N., 2007. Introduction to fuzzy logic using MATLAB, *Introduction to Fuzzy Logic using MATLAB*. <https://doi.org/10.1007/978-3-540-35781-0>
- SMN, 2017. Servicio Meteorológico Nacional [WWW Document]. URL <https://smn.conagua.gob.mx/es/>
- Solomon, S., D., Qin, M., Manning, Z., Chen, M., Marquis, K.B., Averyt, M.T., Miller HL, Solomon, S., Qin, D., Manning, M., Chen, Z., Marquis, M., Averyt, K.B., Tignor, M., Miller, H.L., 2007. Summary for Policymakers. In: *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. D Qin M Manning Z Chen M Marquis K Averyt M Tignor HL Mill. New York Cambridge Univ. Press pp. <https://doi.org/10.1038/446727a>
- Sosa Sierra, M., 2011. Inteligencia artificial en la gestión financiera empresarial. *Rev. científica Pensam. y Gestión*.
- Sterling, L.S., Taveter, K., 2018. *The Art of Agent-Oriented Modeling, The Art of Agent-Oriented Modeling*. <https://doi.org/10.7551/mitpress/7682.001.0001>
- Stockdale, E.A., Watson, C.A., 2009. Biological indicators of soil quality in organic farming systems. *Renew. Agric. Food Syst.* <https://doi.org/10.1017/S1742170509990172>
- Sullivan, C., Meigh, J., 2005. Targeting attention on local vulnerabilities using an integrated index approach: The example of the climate vulnerability index. *Water Sci. Technol.* <https://doi.org/10.2166/wst.2005.0111>
- The World Bank, n.d. The World Bank [WWW Document]. URL <https://data.worldbank.org/indicator>
- Torres Lima, P., Cruz Castillo, J.G., Acosta Barradas, R., 2011. Vulnerabilidad agroambiental frente al cambio climático. *Agendas de adaptación y sistemas institucionales. Política y Cult.*
- UNDRR, 2004. *Vivir con el Riesgo: informe mundial sobre iniciativas para la reducción de desastres*. United Nations Off. Disaster Risk Reduct.
- Universidad de Chile, 2006. *Estudio de la variabilidad climática en Chile para el siglo XXI*. Inf. para CONAMA.
- Vázquez, H.I.C., Ordóñez, Y.M.F., Ruiz, J.S., Maurice, M.J.E., 2015. Enfoque metodológico para la construcción de una Geobase como apoyo a la investigación en agricultura y recursos

- naturales. *Investig. Geogr.* <https://doi.org/10.14350/rig.37303>
- Verisk Maplecroft, 2017. Risk indices [WWW Document]. Risk indices. URL <https://www.maplecroft.com/risk-indices/>
- Wang, Y.-Q., 2014. An Analysis of the Viola-Jones Face Detection Algorithm. *Image Process. Line.* <https://doi.org/10.5201/ipol.2014.104>
- Wedding, D.K., 1997. Fuzzy sets and fuzzy logic: Theory and applications. *Neurocomputing.* [https://doi.org/10.1016/s0925-2312\(97\)88327-0](https://doi.org/10.1016/s0925-2312(97)88327-0)
- Wheeler, D., 2012. Quantifying Vulnerability to Climate Change: Implications for Adaptation Assistance. *SSRN Electron. J.* <https://doi.org/10.2139/ssrn.1824611>
- World Bank, 2017. Indicator [WWW Document]. Agric. For. fishing, value added (% GDP). URL <https://datos.bancomundial.org/indicador/NV.AGR.TOTL.ZS> (accessed 9.25.19).
- Yancato Gurmán, J., 2012. Agentes inteligentes. *fiis uni.*
- Zadeh, L., 1996. Nacimiento y evolución de la lógica borrosa, el soft computing y computación con palabras: un punto de vista personal. *Psicothema.*
- Zadeh, L.A., 2013. Fuzzy logic, in: *Computational Complexity: Theory, Techniques, and Applications.* [https://doi.org/10.1007/978-1-4614-1800-9\\_73](https://doi.org/10.1007/978-1-4614-1800-9_73)
- Zadeh, L.A., 2008. Is there a need for fuzzy logic? *Inf. Sci. (Ny).* 178. <https://doi.org/10.1016/j.ins.2008.02.012>