



UNIVERSIDAD AUTÓNOMA
DE AGUASCALIENTES

CENTRO DE CIENCIAS BÁSICAS

TESIS

**EVALUADOR DE AFECTACIONES CLIMÁTICAS EN EL DESARROLLO
FENOLÓGICO DE CULTIVOS MEDIANTE REDES NEURONALES**

PRESENTA

Jennifer Paola Aceves Serna

**PARA OBTENER EL GRADO DE MAESTRA EN CIENCIAS CON
OPCIONES A LA COMPUTACIÓN, MATEMÁTICAS APLICADAS.**

COTUTORES:

Dr. Ángel Eduardo Muñoz Zavala

Dr. Héctor De La Torre Gutiérrez

INTEGRANTES DE COMITÉ TUTORAL:

Dr. Jorge Eduardo Macías Díaz

Aguascalientes, Aguascalientes, noviembre 2025.

Autorizaciones

CARTA DE VOTO APROBATORIO

M.C. JORGE MARTÍN ALFÉREZ CHÁVEZ
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **DIRECTOR** designado del estudiante **JENNIFER PAOLA ACEVES SERNA** con ID 259706 quien realizó la tesis titulada: **EVALUADOR DE AFECTACIONES CLIMÁTICAS EN EL DESARROLLO FENOLÓGICO DE CULTIVOS MEDIANTE REDES NEURONALES**, un trabajo propio, innovador, relevante e inédito y con fundamento en la facción IX del Artículo 43 del Reglamento General de Posgrados, doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que *ella* pueda continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"

Aguascalientes, Ags., a 20 de noviembre de 2025.


Dr. Ángel Eduardo Muñoz Zavala
Director de tesis

c.c.p.- Interesado
c.c.p.- Coordinación del Programa de Posgrado

CARTA DE VOTO APROBATORIO

M.C. JORGE MARTÍN ALFÉREZ CHÁVEZ
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **CODIRECTOR** designado del estudiante **JENNIFER PAOLA ACEVES SERNA** con ID 259706 quien realizó la tesis titulada: **EVALUADOR DE AFECTACIONES CLIMÁTICAS EN EL DESARROLLO FENOLÓGICO DE CULTIVOS MEDIANTE REDES NEURONALES**, un trabajo propio, innovador, relevante e inédito y con fundamento en la facción IX del Artículo 43 del Reglamento General de Posgrados, doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que ella pueda continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"

Aguascalientes, Ags., a 21 de noviembre de 2025.

Dr. Héctor De La Torre Gutiérrez
Co director de tesis

c.c.p.- Interesado
c.c.p.- Coordinación del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión Integral.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 02
Emisión: 13/08/25

CARTA DE VOTO APROBATORIO

M.C. JORGE MARTÍN ALFÉREZ CHÁVEZ
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **ASESOR** designado del estudiante **JENNIFER PAOLA ACEVES SERNA** con ID 259706 quien realizó la tesis titulada: **EVALUADOR DE AFECTACIONES CLIMÁTICAS EN EL DESARROLLO FENOLÓGICO DE CULTIVOS MEDIANTE REDES NEURONALES**, un trabajo propio, innovador, relevante e inédito y con fundamento en la facción IX del Artículo 43 del Reglamento General de Posgrados, doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que *ella* pueda continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE

"Se Lumen Proferre"

Aguascalientes, Ags., a 21 de noviembre de 2025.

Jorge Eduardo Macías Díaz
Dr. Jorge Eduardo Macías Díaz
Asesor de tesis

c.c.p.- Interesado
c.c.p.- Coordinación del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado,
Revisado por: Depto. Control Escolar/Depto. Gestión Integral,
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 02
Emisión: 13/08/25



DICTAMEN DE LIBERACION ACADEMICA
PARA INICIAR LOS TRÁMITES DEL EXAMEN DE GRADO



Fecha de dictaminación (dd/mm/aaaa): 20/11/2025

NOMBRE: Jennifer Paola Aceves Serna ID: 259706

PROGRAMA: Maestría en Ciencias con Opciones a la Computación, Matemáticas Aplicadas LGAC (del posgrado): Computación- Inteligencia Artificial

MODALIDAD DEL PROYECTO DE GRADO: Tesis (X) *Tesis por artículos científicos () **Tesis por Patente () Trabajo Práctico ()

TITULO: Evaluador de Afectaciones Climáticas en el Desarrollo Fenológico de Cultivos Mediante Redes Neuronales

IMPACTO SOCIAL (señalar el impacto logrado): La investigación generó una metodología que puede ser utilizada para proyectar el desarrollo de los cultivos de jitomate bajo ambientes controlados, teniendo la capacidad de ser adaptado para otro tipo de cultivos; aportando así a la solución de uno de los objetivos globales definidos por la ONU.

INDICAR SEGÚN CORRESPONDA: SI, NO, NA (No Aplica)

Elementos para la revisión académica del trabajo de tesis o trabajo práctico:	
SI	El trabajo es congruente con las LGAC del programa de posgrado
SI	La problemática fue abordada desde un enfoque multidisciplinario
SI	Existe coherencia, continuidad y orden lógico del tema central con cada apartado
SI	Los resultados del trabajo dan respuesta a las preguntas de investigación o a la problemática que aborda
SI	Los resultados presentados en el trabajo son de gran relevancia científica, tecnológica o profesional según el área
SI	El trabajo demuestra más de una aportación original al conocimiento de su área
SI	Las aportaciones responden a los problemas prioritarios del país
NO	Generó transferencia del conocimiento o tecnológica
SI	Cumple con la ética para la investigación (reporte de la herramienta antiplagio)
El egresado cumple con lo siguiente:	
SI	Cumple con lo señalado por el Reglamento General de Posgrados
SI	Cumple con los requisitos señalados en el plan de estudios (créditos curriculares, optativos, actividades complementarias, estancia, predoctoral, etc.)
SI	Cuenta con los votos aprobatorios del comité tutorial
NA	Cuenta con la carta de satisfacción del Usuario (En caso de que corresponda)
SI	Coincide con el título y objetivo registrado
SI	Tiene congruencia con cuerpos académicos
SI	Tiene el CVU de la SECINTI actualizado
NA	Tiene el o los artículos aceptados o publicados y cumple con los requisitos institucionales (en caso de que proceda)
*En caso de Tesis por artículos científicos publicados (completar solo si la tesis fue por artículos):	
NA	Aceptación o Publicación de los artículos en revistas indexadas de alto impacto según el nivel del programa
NA	El (la) estudiante es el primer autor(a)
NA	El (la) autor(a) de correspondencia es el Director (a) del Núcleo Académico
NA	En los artículos se ven reflejados los objetivos de la tesis, ya que son producto de este trabajo de investigación.
NA	Los artículos integran los capítulos de la tesis y se presentan en el idioma en que fueron publicados
**En caso de Tesis por Patente	
NA	Cuenta con la evidencia de solicitud de patente en el Departamento de Investigación (anexarla al presente formato)

Con base en estos criterios, se autoriza continuar con los trámites de titulación y programación del examen de grado:

SI ☒ X
No ☐

Elaboró:

FIRMAS

*NOMBRE Y FIRMA DEL(LA) CONSEJERO(A) SEGÚN LA LGAC DE ADSCRIPCION:

Dr. Rogelio Salinas Gutiérrez

* En caso de conflicto de intereses, firmará un revisor miembro del NA de la LGAC, correspondiente distinto al director o miembros del comité tutorial, asignado por el Decano.

NOMBRE Y FIRMA DEL COORDINADOR DE POSGRADO:

Dra. Mariana Alfaro Gómez

Revisó:

NOMBRE Y FIRMA DEL SECRETARIO DE INVESTIGACIÓN Y POSGRADO:

Dr. Alejandro Padilla Díaz

Autorizó:

NOMBRE Y FIRMA DEL DECANO:

M. en. C. Jorge Martín Alfárez Chávez

Nota: procede el trámite para el Depto. de Apoyo al Posgrado

En cumplimiento con el Art. 24 Fracción V del Reglamento General de Posgrado, que a la letra señala entre las funciones del Consejo Académico: Proponer criterios y mecanismos de selección, permanencia, egreso y titulación de estudiantes para asegurar la eficiencia terminal y la titulación y el Art. 25 Fracción IV, atender, asesorar y dar el seguimiento del estudiantado desde su ingreso hasta su titulación.

Elaborado por: D. Apoyo al Posg.
Revisado por: D. Control Escolar/D. Gestión de Calidad.
Aprobado por: D. Control Escolar/ D. Apoyo al Posg.

Código: DO-SET-FO-15
Actualización: 02
Emisión: 12/08/25

Agradecimientos

En primer lugar, agradezco al tutor de tesis, el Dr. Ángel Eduardo Muñoz Zavala, por su invaluable paciencia, su constante apoyo y su orientación académica a lo largo del desarrollo de este trabajo. Sin su guía no hubiera sido posible finalizar esta tesis.

Asimismo, agradezco a mi comité tutorial, conformado por el Dr. Héctor De La Torre Gutiérrez y el Dr. Jorge Eduardo Macías Díaz, por el apoyo y los valiosos conocimientos brindados a lo largo de este proceso. Sus aportaciones permitieron enriquecer ampliar el campo de investigación de la tesis presentada.

Agradezco al Consejo Nacional de Humanidades Ciencias y Tecnología, por el apoyo económico brindado por medio de la beca que permitió fuera posible el desarrollo de la investigación presentada en esta tesis.

Agradezco también a la Universidad Autónoma de Aguascalientes, institución que abrió sus puertas para brindarme la oportunidad de participar en el programa de maestría. Reconozco el valor de los nuevos conocimientos compartidos por el personal docente, los cuales enriquecieron mi perspectiva, parte fundamental para el desarrollo de este trabajo. Además, agradezco al personal administrativo por su apoyo constante para culminar exitosamente la tesis.

Extiendo mi agradecimiento a VERDUMEX, empresa que colaboró en este trabajo abriendo sus puertas y compartiendo información esencial sobre sus procesos agrícolas. Apoyo fundamental que dio inicio a este trabajo y que permitió el desarrollo de múltiples análisis basados en información y datos verídicos.

Finalmente, quiero expresar mi más sincero agradecimiento a toda mi familia, principalmente a mis padres, José Guadalupe Aceves Díaz y Ana Isabel Serna Figueroa, cuyo apoyo incondicional me ha impulsado a la búsqueda continua de conocimiento. Fue este impulso el que me llevo a comenzar esta nueva travesía de posgrado que concluye con la presentación de esta tesis.

TESIS

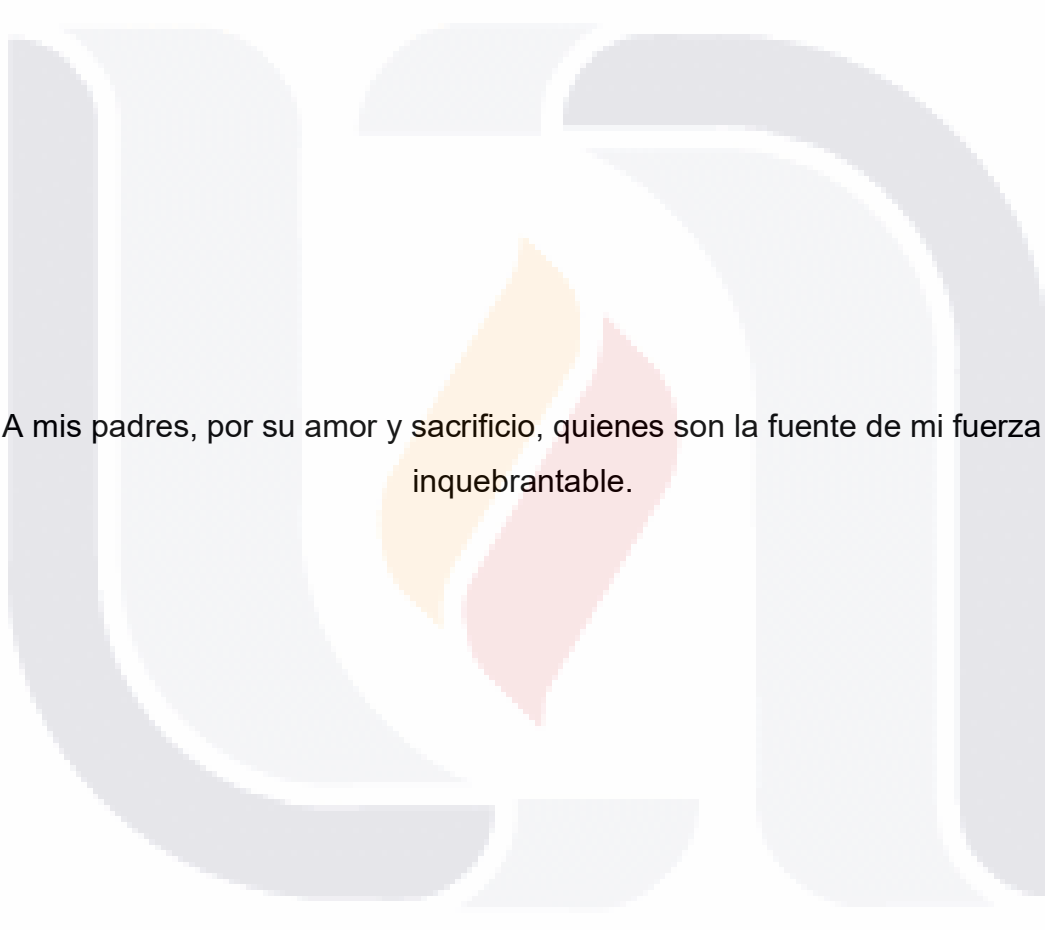
TESIS

TESIS

TESIS

TESIS

Dedicatorias



A mis padres, por su amor y sacrificio, quienes son la fuente de mi fuerza
inquebrantable.

TESIS

TESIS

TESIS

TESIS

TESIS


Índice General

Índice de Tablas.....	3
Índice de Gráficas y Figuras.....	4
Resumen	7
Abstract	9
Introducción	10
Capítulo 1. Definición de proyecto.....	14
1.1 Problemática.....	14
1.2 Objetivo.....	14
1.3 Hipótesis.....	15
1.4 Preguntas de investigación.....	15
1.5 Contribución.....	16
1.6 Impacto.....	16
Capítulo 2. Antecedentes.....	17
Capítulo 3. Metodología.....	21
3.1 Conceptos introductorios.....	21
3.2 Metodologías usadas en la predicción.....	23
3.2.1 Regresión lineal.....	24
3.2.2 Series temporales.....	24
3.2.3 Análisis Bayesiano.....	26
3.2.4 Machine learning.....	26
3.2.5 Árboles de decisiones.....	28
3.2.6 Redes neuronales.....	28
Capítulo 4. Exploración de datos y ajuste de modelo.....	37
4.1 Modelado de variables climáticas.....	38
4.1.1 Caso de estudio 1: Estación Meteorológica Automática de Aguascalientes (SMN-ESMA). 38	
4.1.2 Caso de estudio 2: Estación Meteorológica Aguascalientes Sur.....	39

4.1.3	Caso de estudio 3: Estación Meteorológica La Boquilla (860030).	39
4.2	Ajuste de modelo.	39
4.2.1	Red neuronal: Feedforward.	39
4.2.2	Red neuronal recurrente (RNN).	44
4.2.3	Redes de función base radial (RBFN).	47
4.2.4	Red convolucional (CNN).	50
4.2.5	Mapas Autoorganizado (SOM).	53
Capítulo 5.	Caso de estudio VERDUMEX.	59
5.1	Predicción de variables climáticas VERDUMEX.	61
5.1.1	Feedforward.	61
5.1.2	RNN.	63
5.1.3	RBFN (regresión generalizada).	64
5.1.4	RBFN (proceso incremental).	65
5.1.5	CNN.	66
5.1.6	SOM.	67
5.1.7	SVM.	68
5.2	Implementación de las redes neuronales en el análisis fenológico del cultivo.	69
5.2.1	Análisis fenológico Invernadero #5.	70
	Discusión de Resultados.	72
	Conclusión.	82
	Glosario.	85
	Referencias.	89

Índice de Tablas

Tabla 1 MSE y tiempo del caso de estudio SMN-ESMA.	41
Tabla 2 Resultados de predicción caso de estudio Estación Meteorológica Sur...	43
Tabla 3 Resultados de predicción cado de estudio Estación La Boquilla.	44
Tabla 4 Variables registradas por VERDUMEX.	60
Tabla 5 Errores y tiempos obtenidos para el Invernadero #3.	72
Tabla 6 Errores y tiempo obtenido para el Invernadero #5.	74
Tabla 7 Errores y tiempo de RNN para cosechas.	78

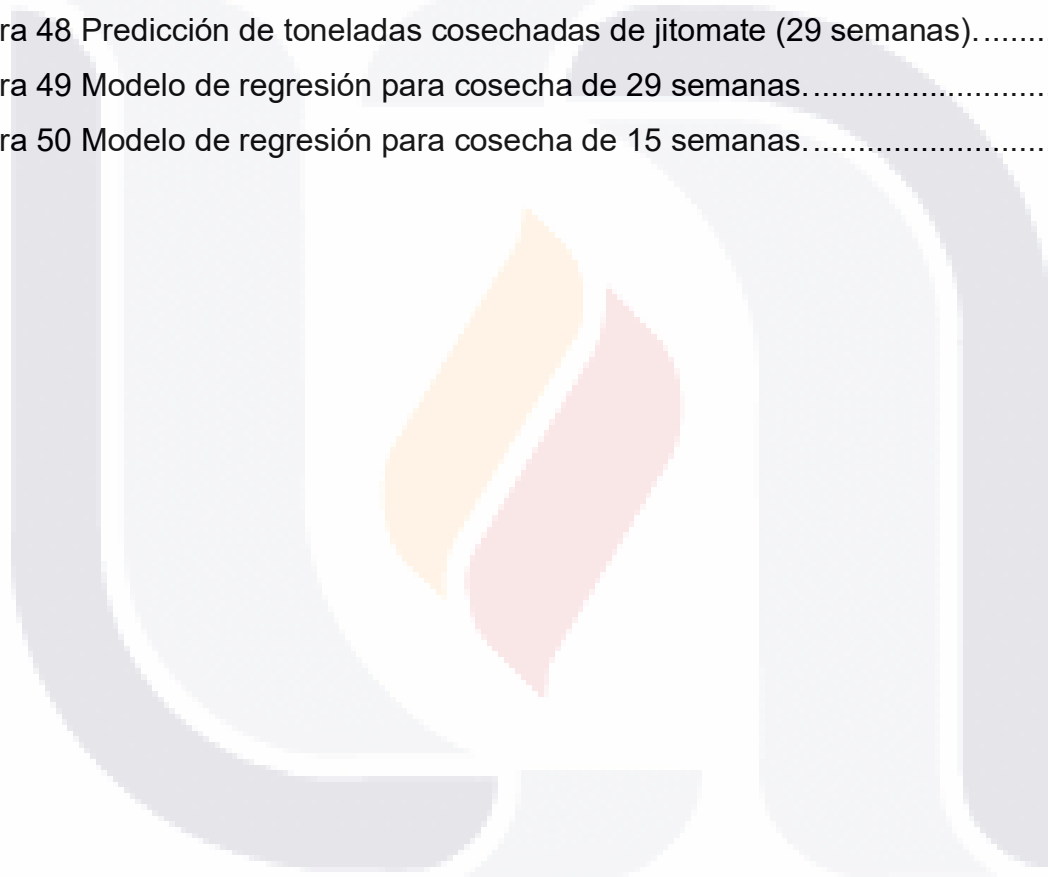


Índice de Gráficas y Figuras

Figura 1 Elementos de serie temporal.....	25
Figura 2 Modelo por Machine Learning.....	27
Figura 3 Gráfica de función lineal.....	30
Figura 4 Gráfica de función sigmoide.....	31
Figura 5 Gráfica de función hiperbólica.....	32
Figura 6 Gráfica de función ReLu.....	32
Figura 7 Gráfica de función softmax.....	33
Figura 8 Gráfica de función base radial.....	34
Figura 9 Estructura de red neuronal 1.....	40
Figura 10 Resultados de predicción caso de estudio SMN-ESMA.....	41
Figura 11 Resultados de predicción caso de estudio Estación Meteorológica Sur.	42
Figura 12 Resultados de predicción caso de estudio Estación La Boquilla.....	43
Figura 13 Arquitectura de red neuronal recurrente.....	44
Figura 14 Predicción de temperatura por RNN para Estación Automática de Aguascalientes.....	45
Figura 15 Predicción de temperatura máxima por RNN para Estación Sur Aguascalientes.....	46
Figura 16 Predicción de radiación solar por RNN para Estación La Boquilla.....	46
Figura 17 Arquitectura de red neuronal de función base radial.....	47
Figura 18 Predicción de temperatura por RBFN para Estación Automática de Aguascalientes.....	48
Figura 19 Predicción de temperatura máxima por RBFN para Estación Sur Aguascalientes.....	49
Figura 20 Predicción de radiación solar por RBFN para Estación La Boquilla.....	50
Figura 21 Predicción de temperatura por CNN para Estación Automática de Aguascalientes.....	51
Figura 22 Predicción de temperatura máxima por CNN para Estación Sur Aguascalientes.....	52

Figura 23 Predicción de radiación solar por CNN para Estación La Boquilla.	52
Figura 24 Arquitectura de SOM.	53
Figura 25 Predicción de temperatura por SOM para Estación Automática de Aguascalientes.	54
Figura 26 Predicción de temperatura máxima por SOM para Estación Sur Aguascalientes.	54
Figura 27 Predicción de radiación solar por SOM para Estación La Boquilla.	55
Figura 28 Predicción de temperatura por SVM para Estación Automática de Aguascalientes.	56
Figura 29 Predicción de temperatura máxima por SVM para Estación Sur Aguascalientes.	57
Figura 30 Predicción de radiación solar por SVM para Estación La Boquilla.	57
Figura 31 VERDUMEX.	59
Figura 32 Temperatura mínima real y predicha por red feedforward en Invernadero #3.	62
Figura 33 Temperatura mínima real y predicha por red feedforward en invernadero 5.	62
Figura 34 Temperatura mínima real y predicha por red recurrente en invernadero 3.	63
Figura 35 Temperatura mínima real y predicha por red recurrente en invernadero 5.	63
Figura 36 Temperatura mínima real y predicha por red base radial (RG) en invernadero 3.	64
Figura 37 Temperatura mínima real y predicha por red base radial (RG) en invernadero 5.	64
Figura 38 Temperatura mínima real y predicha por red base radial (PI) en Invernadero #3.	65
Figura 39 Temperatura mínima real y predicha por red base radial (PI) en Invernadero #5.	65
Figura 40 Temperatura mínima real y predicha por red convolucional en Invernadero #3.	66

Figura 41 Temperatura mínima real y predicha por red convolucional en Invernadero #5.	66
Figura 42 Temperatura mínima real y predicha por SOM en Invernadero #3.	67
Figura 43 Temperatura mínima real y predicha por SOM en Invernadero #5.	68
Figura 44 Temperatura mínima real y predicha por SVM en Invernadero #3.	68
Figura 45 Temperatura mínima real y predicha por SVM en Invernadero #5.	69
Figura 46 Predicción de fenología Invernadero #5	71
Figura 47 Predicción de toneladas cosechadas para 15 semanas.	77
Figura 48 Predicción de toneladas cosechadas de jitomate (29 semanas).	78
Figura 49 Modelo de regresión para cosecha de 29 semanas.	79
Figura 50 Modelo de regresión para cosecha de 15 semanas.	80



Resumen

Las redes neuronales son utilizadas en la actualidad para múltiples tareas, una de ellas la predicción de fenómenos sociales y naturales. Considerando su eficacia en tareas de predicción y su capacidad de modelar sistemas de manera robusta, es que se plantea el objetivo de evaluarlas como método de predicción de variables fenológicas esperando demostrar su utilidad en situaciones de riesgo y aprovecharla en casos reales, para poder utilizarlas en la optimización y la adaptación de la agricultura ante situaciones de riesgo, con el fin de que se pueda tomar una mejor decisión agrónoma sobre los cultivos y aumentar con esto la producción de alimentos, disminuyendo pérdidas y a su vez, con esto, costos que afectan tanto a la economía de los agricultores como a la de todos los consumidores.

Para realizar una evaluación rigurosa se toman en consideración distintas redes neuronales como: red feedforward, red recurrente, red de función base radial, red convolucional y mapas autoorganizados, comparando la eficiencia de cada una de ellas de acuerdo a los datos que se analizan y las variables que se predicen, realizando la comparativa por medio del error absoluto, el error mínimo cuadrado, el coeficiente de determinación, el sesgo y el tiempo de ejecución, teniendo con ello una vista general de cada una de las redes neuronales.

A su vez, se realiza la comparación contra otros métodos, una máquina de soporte vectorial y, principalmente, contra los modelos tomando como referencia los modelos ARIMA, para poder revisar si las redes son opciones contra métodos más robustas que ellas.

Para poder realizar todo el análisis de estas herramientas se presenta un caso de estudio en Aguascalientes, en VERDUMEX con el cultivo de jitomates, sin embargo, se propone como un modelo fácilmente replicable para enfrentar las situaciones de riesgo actuales: tanto climáticas como alimentarias.

Dada la situación actual de riesgo climático y alimentario se evalúan las redes neuronales como una alternativa clave en la predicción fenológica mostrando a lo

TESIS TESIS TESIS TESIS TESIS

largo del documento comparaciones de pruebas para validar su funcionamiento y eficiencia, logrando mostrar la calidad de las predicciones hechas útiles en la adaptación de los cultivos.



Abstract

The neural networks have been applied for a lot of different tasks, prediction as one of them. With the objective of analyzing their performance in a real and practical case of study related to agriculture and phenological risks, they will be used as a tool for optimize the harvest, improving the production, and decreasing the wastage of crops, and as consequence decreasing the economic losses of agricultural producers and consuming public.

The thorough analysis involves the exploration of different neural networks as: Feedforward Network (FFN), Recurrent Neural Network (RNN), Radial Basis Function Network (RBFN), Convolutional Neural Network (CNN), and Self-Organized Map (SOM). The efficiency is proved by analyzing the MSE, Absolute Error, coefficient of determination, Bias and execution time.

Also, the neural networks are also compared against other methods: the Support Vector Machine (SVM), and the ARIMA models. This comparison makes possible to determine if the neural networks are an alternative against more robust models and finally to infer about their efficacy in the cases of study.

The case of study where the investigation is applied is in VERDUMEX, a Mexican company located in Aguascalientes, where the information about tomato crops is used to predict about the need of the crop. Although, it can be replicated and applied which is the main characteristic that the project is trying to reach due to the meteorological and food supply risks.

Are the neural networks the tool that is needed to adapt the agriculture to the new worldwide changes? This document validates the importance of the neural networks and how easily they can be modified to be adapted to the different model being a great option to overcome the risks.

Introducción

A lo largo de la historia la humanidad se ha enfrentado a diversos problemas para lograr satisfacer sus necesidades básicas y por lo tanto lograr su supervivencia teniendo que adaptarse a su entorno y a los recursos disponibles, desarrollando en el proceso técnicas y tecnologías que le permitían seguir adelante. Esa es una lucha que prevalece hoy en día, donde si bien hay una gran cantidad de avances que han traído consigo comodidad para la humanidad, siguen existiendo más y nuevos retos a los que enfrentarse para satisfacer las necesidades básicas de la población.

La comida es algo que hoy en día se suele dar por sentado, en gran medida por su aparente fácil acceso que vuelve que su valor sea meramente superfluo. Si se tiene hambre, bajo el contexto mexicano, basta con acudir a un mercado a conseguir frutas, verduras, cereales o carne, pero ese alimento que parece fácil de conseguir o de valor insignificante tiene en realidad un valor monumental. Se sabe que comer es una actividad básica y necesaria, pues en promedio una persona puede vivir únicamente ocho semanas sin consumir alimento, como mencionan Sáiz Peiro y Ortiz Lucas (2007) quienes al detallar la fisiología de las personas hablan de entre 40 y 60 días de ayuno máximo, a pesar de esto no es un recurso de fácil acceso en todo el mundo, una muestra de esto son las cifras de desnutrición a nivel mundial, donde retomando datos aportados por la Organización de las Naciones Unidas (ONU) existen más de 691 millones de personas que pasan hambre con todas las consecuencias de esto, esta situación es conocida como inseguridad alimentaria (United Nations, n.d.).

Es aquí donde se llega al primer punto importante que sirve de base para el desarrollo de esta tesis: la agricultura.

El desarrollo de la agricultura permitió que el hombre comenzara a asentarse en comunidades, esto gracias a la posibilidad de cultivar su propio alimento y de cultivar alimento que uso para la domesticación de animales que servirían de igual forma como fuente de alimentación, prevaleciendo hasta la actualidad como una actividad necesaria para la alimentación a nivel mundial, sirviendo no sólo como fuente de

alimento, sino como materia prima para el acceso a otros recursos y como una actividad económica importante (De Agricultura Y Desarrollo Rural, n.d.), tal es el caso de países como México donde se cultivan e importan diversos alimentos producto de esta actividad. Sin embargo, por numerosas razones la agricultura se encuentra en constante peligro, ya sea por el crecimiento de ciudades que desplazan los campos y zonas de cultivos, donde la sociedad se enfoca cada vez más en el desarrollo industrial y tecnológico dejando este tipo de actividades básicas en segundo plano. De la mano de esto hay muchos más factores riesgo cuyas afectaciones son más delicadas o preocupantes puesto que provocan una completa incertidumbre para los propios cultivos, tal es el caso del cambio climático (De Información Agroalimentaria Y Pesquera, n.d.).

El cambio climático, el calentamiento global, y el efecto invernadero, han sido temas de interés en investigación y discusión viéndose potenciados por factores como la contaminación que afecta directamente en ellos, del mismo modo se ha hecho énfasis en las implicaciones que esto podría traer a futuro como desastres naturales tales como sequías, olas de calor, inundaciones, huracanes y demás. Todo eso que se preveía ha comenzado a suceder de manera claramente alarmante no solo para los humanos, sino para la vida en general dentro del planeta, muestra de esto fue el año 2023, año durante el cual se experimentaron las temperaturas más altas en el planeta de manera histórica a nivel global, como se menciona en diversos artículos, algunos de ellos de National Geographic, cada mes de dicho año presentó un nuevo récord en temperaturas altas, trayendo con esto la espera de que durante el año 2024 se volviera a repetir esta historia (Parra, 2024). ¿Pero que implicaciones pueden tener estas situaciones extremas en la agricultura?

Para poder llevar a cabo la agricultura se debe contar con ciertos elementos específicos que permitan el desarrollo de las plantas, no es lo mismo plantar un manzano que crece naturalmente en zonas frías que intentar tener un cafetal que se produce en zonas tropicales, condiciones como la humedad, las temperaturas máximas y mínimas, el pH del suelo, entre otros, elementos derivados del clima que ofrecen a cada especie las condiciones necesarias para que nazcan y se desarrollen

al punto de ser cosechadas y por tanto consumidas (FAO, 2000). Sin estas condiciones el simple hecho de producir resulta un reto enorme para todos los agricultores, haciendo de suma importancia para ellos el invertir en herramientas que permitan hacer adecuaciones pertinentes a las condiciones mundiales, así como herramientas cuyo uso permita eficientar los recursos y poder llevar a término cada uno de los cultivos.

Debido a lo anterior es que existen diversas organizaciones que buscan influir o invertir en estos esfuerzos por disminuir los efectos negativos sobre la agricultura, trabajando en el desarrollo de tecnologías sustentables y sostenibles que permitan que la agricultura prevalezca y que sea útil en la alimentación mundial intentado disminuir a la vez los efectos adversos que pueda tener la práctica de la agricultura en el medio ambiente, así como para disminuir el impacto de los efectos del cambio climático o la falta de acceso a recursos en la producción de cultivos, buscando en el proceso aumentar la producción y calidad de estos de manera que ayude en la disminución de la desnutrición a nivel global. Ejemplo de esto es la Organización de las Naciones Unidas, la cual desarrolló la Agenda 2030 para el Desarrollo Sostenible, la cual plantea 17 objetivos que pretenden, al ser cumplidos, disminuir el hambre a nivel mundial (planteado dentro del objetivo 2 “hambre cero”), promoviendo la producción y el consumo responsables (objetivo 12 de la agenda de desarrollo sostenible), donde la inseguridad alimentaria se busca satisfacer por medio de prácticas sostenibles en los sistemas de agricultura, mediante el desarrollo y el apoyo al desarrollo de técnicas y sistemas que ayuden en este proceso (Desarrollo Sostenible, 2017). Tomando información de la propia agenda de desarrollo sostenible, de manera más específica por medio del objetivo 2 hambre cero se propone tener un mundo libre de hambre sin inseguridad alimentaria destacando como factores de riesgo conflictos, enfermedades, desigualdad y cambio climático, marcando como una guía para lograr el hambre cero la necesidad de buscar y apoyar los sistemas sostenibles de alimentos, y teniendo como algunas de sus metas el duplicar la productividad agrícola al incluir prácticas sostenibles que sean capaces de adaptarse al cambio climático (Moran, 2024b). Por otro lado, el objetivo 12 “producción y consumos responsables” marca como problemática la falta

de recursos y como solución el hacer uso responsable de ellos, teniendo entre esta lista de recursos los alimentos; y dentro de sus metas se plantea reducir el desperdicio de alimentos, el uso adecuado de productos químicos, la inversión en la tecnología que permita una producción sostenible y el buen uso de recursos naturales (Moran, 2024a).

Ahora, como se mencionó antes, dentro de México la agricultura es una actividad de suma importancia, razón por la cual existen organizaciones como la Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación (SAGARPA), la cual intenta prevenir los efectos del cambio climático y de los desastres naturales en el área agroalimentaria, contando por ello con diversos apoyos y programas dedicados al impulso agrícola, bajando así hasta el nivel estatal. Dentro de Aguascalientes existe la Secretaría de Desarrollo Rural y Agroempresarial (SEDRAE) una secretaría que busca el desarrollo del sector agroalimentario mediante la puesta en práctica de medidas sostenibles y responsables.

Todo esto demuestra la importancia que tiene el tomar medidas dentro de esta área, dando con esto sentido a los objetivos de esta tesis, es por esto que se llega al caso de estudio que permite el desarrollo de la tesis planteada en este documento. Dentro del estado de Aguascalientes existe Verduras Mexicanas la Boquilla, quienes en su búsqueda por disminuir el impacto climático dentro de sus cultivos y el aumento de su productividad permitirán la implementación de este caso de estudio, donde se pretenden implementar diversas técnicas y tecnologías para la evaluación y predicción del desarrollo fenológico de sus cultivos, por medio del análisis climático de la localidad.

Capítulo 1. Definición de proyecto.

Con el fin de establecer las características de este proyecto se hace uso de este capítulo, donde se expondrán las características que definen al proyecto.

1.1 Problemática.

La situación climática actual afecta directamente actividades primarias como lo es la agricultura, poniendo con esto en riesgo a toda la sociedad en general pues es una actividad que genera empleos, y abastece de alimento a la población mundial. Dentro de México esto se ve claramente en diversos Estados, entre ellos Aguascalientes, donde las temperaturas extremas en conjunto con el estrés hídrico contribuyen a la pérdida o disminución de cultivos, teniendo como consecuencias inmediatas fuera del campo la falta de abastecimiento de ciertos alimentos o el alto precio de algunos otros. Con esto se puede definir como la problemática a tratar la mejora de la producción agrícola, por medio de la implementación de técnicas de inteligencia artificial creando un modelo que sea ajustable y replicable, cuya eficiencia se prueba por medio de un caso de estudio específico: el cultivo de jitomates dentro de Verduras Mexicanas La Boquilla.

1.2 Objetivo.

Evaluar la capacidad predictiva de técnicas de inteligencia artificial que permitan conocer los efectos del cambio climático en el desarrollo de los cultivos comparando distintas arquitecturas de redes neuronales con distintas variables fenológicas con el fin de optimizar las toma de decisiones en la agricultura, disminuyendo los riesgos de la actividad y aumentando el rendimiento de las cosechas

Para lograr dicho objetivo es necesario plantear de manera particular algunos más, como:

Implementar modelos predictivos por medio de redes neuronales a la fenología del cultivo en base a variables climáticas y fenológicas para determinar la adaptabilidad de la herramienta a una predicción robusta.

Comparar entre diversos métodos de predicción para evaluar los alcances de la red neuronal respecto al desempeño de modelos clásicos (ARIMA) para mostrar la eficiencia de las redes neuronales.

Dentro del caso de estudio se aplicará como el análisis de variables fenológicas para comparar las toneladas de jitomates cosechadas, para poder incrementar las mismas.

1.3 Hipótesis.

Las redes neuronales permitirán obtener predicciones más precisas en la predicción de eventos fenológicos en comparación a métodos de la estadística clásica como los modelos ARIMA, y su aplicación permite eficientar los procesos agrícolas.

1.4 Preguntas de investigación.

Para intentar probar la hipótesis se plantean algunas preguntas que ayuden en la investigación.

Dentro de las distintas técnicas de predicción ¿las redes neuronales resultan útiles como un método que eficientice tiempos o logre mejores resultados?

¿La predicción fenológica afecta positivamente la producción de cultivos?

1.5 Contribución.

Como principal contribución se tiene la validación de las redes neuronales como un modelo preciso en la predicción fenológica competitivo y superior a métodos tradicionales teniendo así modelos replicables y de rápido ajuste. Mediante su aplicación en el caso de estudio se busca abordar el impacto dentro de la agricultura, logrando la aplicación de las redes neuronales para lograr que la agricultura y los agricultores sean capaces de adaptarse rápidamente a las situaciones adversas.

1.6 Impacto.

Por medio de este proyecto se pretende lograr una mejoría en la producción agrícola, teniendo con esto un impacto dentro de la alimentación y la economía de la sociedad. El caso de estudio permitirá tratar la aplicación de redes neuronales a un nivel meramente local y con un cultivo de jitomates, sin embargo, debido a las necesidades actuales de la sociedad y el medio ambiente, tomando como referencia la Agenda de Desarrollo Sostenible 2030 de la ONU, o las distintas instituciones mexicanas en conjunto con los programas que lanzan donde la prioridad es la alimentación y la toma de medidas en cuanto a consecuencias climáticas y desastres naturales con un enfoque en la agricultura sostenible, el proyecto solo servirá como base a algo que se puede aplicar dentro de otras localidades con climas similares al estado de Aguascalientes, con cultivos de jitomate, o bien tomar como referencia este caso para extender el uso de estas tecnologías a diversos cultivos en distintas regiones con sus respectivas características climáticas.

Con todos estos puntos expuestos queda planteado el proyecto dentro de su caso de estudio.

Capítulo 2. Antecedentes.

Como se ha mencionado en otras secciones de este documento la importancia de la agricultura es muy grande para la sociedad, y los efectos adversos que continuamente están afectando las producciones han hecho que el interés por predecir y tomar medidas preventivas o de apoyo a los cultivos sea demasiado grande. La relevancia del tema ha generado investigaciones de la fenología que se incluyen a continuación como antecedentes del tema.

La fenología se ha usado durante años como observación y registro de los distintos ciclos de vida de los seres vivos, dentro de la agricultura es un estudio de gran importancia que permite no solo saber la etapa de vida de una planta, sino que ayuda a que los agricultores tengan el conocimiento para la toma de decisiones dentro del cultivo, un ejemplo bastante obvio de esto es definir en qué momento un cultivo está listo para ser cosechado, se puede tomar como referencia a García (2018) quién explica de manera más técnica como la fenología 'permite que se ubiquen áreas y herramientas necesarias para la producción de cultivos así como necesidades biológicas de las distintas plantas. Ahora dentro del proceso de crecimiento de las plantas influyen diversos elementos como el clima, el agua, fertilizantes utilizados, etc., todo esto hace que sea un tanto complejo de analizar, añadiendo el conocimiento de que pueden suceder casos extremos o fuera de lo común, como el incremento de las temperaturas, lo cual afecta directamente la fenología de un cultivo. Dentro de lo que señala la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) se habla de la sensibilidad de la fenología a los cambios, haciendo con esto interesante e importante el poder predecir ciertos eventos dentro del crecimiento de una planta para poder tomar medidas en beneficio del cultivo (FAO, 2017).

Dentro de esta área han sido desarrollados diversos proyectos aplicados a una gran variedad cultivos, como ejemplo de ello se tiene la aplicación a cultivos de: papas, un proyecto desarrollado por Flores-Magdaleno et al. (2014), dentro de México; arroz, un estudio desarrollado en Asia por Guo et al. (2021); trigo, un proyecto

TESIS TESIS TESIS TESIS TESIS

trabajado en México por Moreno Gutiérrez et al. (2019); cafetales en México como el de Parada Molina et al. (2020); viñedos con ejemplos de aplicación en Chile: un proyecto aplicado por Jorquera-Fontena & Orrego-Verdugo (2010), y otro más por Ortega-Farías et al. (2002); y maizales como los desarrollados por Valdez-Torres et al. (2012), Mejía Ramírez et al. (2019), y García-Montesinos et al. (2020). Todos estos proyectos incluyen el análisis fenológico de algún cultivo, y éstos en conjunto con proyectos que trabajan de manera directa la predicción fenológica o climatológica sirven como referencia a los métodos utilizados, y a su vez como referencia a lo que se pretende lograr en esta tesis mediante el caso de estudio de los cultivos de jitomate dentro de Aguascalientes, México, por ello dentro de los siguientes párrafos se incluye información de algunos de estos antecedentes.

En el año 2002 fue publicado en Chile un artículo para el desarrollo de modelos predictivos de fenología aplicado a la vid para vino Cabernet Sauvignon y Chardonnay por Samuel Ortega-Farías, Pedro Lozano, Yerko Moreno y Lorenzo León, donde se explica un estudio realizado para predecir la fenología de la vid en base al pH del suelo, así como la propia fenología de la vid (hojas, frutos, etc.), esto con el fin de analizar la fenología de cada etapa de la planta y poder definir por medio de grados días acumulados (que es una forma de medir el tiempo durante el cual la temperatura a estado por encima o debajo de cierto parámetro) las etapas de la vid y poder usar dicha información en procesos como la cosecha o la necesidad de ciertos mantenimientos sobre el cultivo, como la necesidad de aplicar fertilizantes, trabajando con cinco variables distintas y la implementación de una ecuación exponencial a partir de la acidez del suelo. (Ortega-Farías et al., 2002).

Más tarde, en el año 2010, se realizó un nuevo artículo donde se analiza cómo afecta el cambio climático en la fenología de la vid, de igual manera un estudio desarrollado en Chile, esta vez por Emilio Jorqueta-Fontena y Raúl Orrego-Verdugo. En este caso el trabajo se enfoca en conocer cómo el aumento de la temperatura afecta el proceso fenológico de la vid, partiendo del aumento en la temperatura a nivel mundial y como está ha afectado la producción de vid en otras partes del mundo. El estudio se desarrolló mediante la medición constante de temperaturas,

del crecimiento de la vid y con ayuda del modelo de crecimiento fenológico de ésta. En el artículo se muestra la relación entre los grados días con la fenología de la planta, mostrando que dentro de los espacios de estudio que el aumento en la temperatura genera una aceleración en el crecimiento de la vid con efectos distintos de acuerdo al punto en que se presente dentro del desarrollo de la planta, razón por la cual hace énfasis en la necesidad de tomar medidas frente al calentamiento global, en beneficio de la producción vinícola, (Jorquera-Fontena & Orrego-Verdugo, 2010).

En 2012 se presenta un modelo de predicción fenológica para el maíz, cuyo fin fue predecir los eventos fenológicos del maíz blanco para evitar la pérdida de los cultivos dentro de México, enfocándose en este caso en identificar etapas donde el cultivo se encuentre en peligro por plagas. Dicho modelo se realizó mediante la regresión polinomial, verificando la fenología de la plaga y la regresión polinomial de tercer grado para la fenología del maíz, logrando establecer de ambos el momento en que la plaga podría estar presente dentro del maíz (Valdez-Torres et al., 2012).

En el año 2013 se publica SI. FE. SOJA, un modelo de simulación de fenología de soja, por Hugo Felipe Peltzer y Nelson Gerardo Peltzer, siendo este un modelo para representar el momento en que ocurren los distintos eventos fenológicos de la soja, permitiendo con esto la toma de decisiones sobre el cultivo. (Peltzer & Peltzer, 2013).

De igual manera se publicó un artículo sobre la predicción fenológica de la papa a partir del tiempo térmico de la misma. Este trabajo publicado en el 2014 trabaja la fenología de los cultivos de papas en Sinaloa México, mediante la implementación de tres métodos distintos (método de temperatura media, grados día y días papa) con el fin de que mediante la predicción de la fenología de la papa se puedan evitar pérdidas o altos costes en el cultivo de la papa debido a la variabilidad climática. En el trabajo se llegó a la conclusión de que al hacer el análisis por medio de días papa se presenta una menor variabilidad en los resultados con un menor error en la

predicción hecha (los días papa son el número de días en que la papa está bajo las condiciones necesarias para su crecimiento) (Flores-Magdaleno et al., 2014).

De manera más reciente se presentó un evaluador de daño fenológico en el trigo, donde se presenta un sistema que evalúa y presenta esta información logrando una precisión del 84% por medio de la predicción por redes neuronales. (Moreno Gutiérrez et al., 2019)

Por otro lado, un estudio en Veracruz, México, mostró los efectos de la variabilidad climática en la fenología de los cafetales (analizándolo desde la precipitación), lográndolo por medio de análisis estadístico, con la herramienta InfoStat. (Parada Molina et al., 2020)

Finalmente, se toma como última referencia la publicación sobre la fenología del arroz y su predicción por medio de machine learning, un trabajo desarrollado y aplicado a campos de arroz en China, donde se mostró como la predicción por machine learning era más efectiva en la predicción a diferencia métodos de regresión múltiple. (Guo et al., 2021)

De esta manera se toman estos trabajos como antecedentes a lo que se plantea lograr en este trabajo por medio del uso de las redes neuronales, se puede observar la importancia y relevancia de la predicción fenológica alrededor del mundo, el cómo las afectaciones climáticas dañan diversos cultivos en variadas zonas geográficas, y cómo es posible analizar por diversos métodos la fenología de los cultivos.

Capítulo 3. Metodología.

3.1 Conceptos introductorios.

Para poder adentrarse en la explicación del proyecto es necesario aclarar algunos conceptos que permitirán facilitar la comprensión de los temas, de manera que sea más claro lo que se pretende lograr por medio de este proyecto y la manera de lograrlo, para tener conceptos específicos se recomienda al lector ir a la sección de glosario.

Cómo se ha mencionado en otras secciones anteriores a este capítulo se puede observar que el proyecto pretende una aplicación de las redes neuronales dentro de la agricultura, para la identificación de fases fenológicas, llegando con esto a que es la fenología y porque es útil dentro de la agricultura. Tomando como referencia conceptos investigados en el diccionario de la Real Academia Española (RAE, 2011), cuando se habla de la fenología se habla del estudio de todas las etapas de vida de un ser vivo, en el caso de este proyecto se enfoca la fenología a las plantas, siendo esta rama conocida como fitofenología, analizando incluso los elementos que interfieren en estas como lo pueden ser los diversos elementos meteorológicos, al hacer el estudio de las etapas de vida permite entonces conocer características de etapas específicas como lo puede ser la floración de una planta, y junto con estas características propias del ser vivo, las características necesarias para que el organismo sea capaz de entrar o salir de esta etapa. Dentro de la agricultura la fenología es de suma importancia puesto que permite, al conocer el ciclo de vida de los distintos cultivos, potencializar los recursos invertidos como fertilizantes o agua, además de tomar medidas preventivas ante situaciones que pongan en riesgo el cultivo y establecer tiempos exactos para actividades como el sembrar o cosechar.

Todos estos ciclos de vida se ven afectados por factores como el clima, que influye directamente en los procesos de vida de las plantas, como un ejemplo muy burdo se puede plantear uno dictado por la experiencia, una buganvilia puede estar o no floreada y esto depende completamente de la humedad y la cantidad de sol que reciba, siendo que cuando se ve expuesta a situaciones de estrés como la escasez

de agua o una fuerte y constante exposición solar es cuando la planta tiene más flores, intentando dar un respaldo a esto se pueden observar los cuidados necesarios de esta planta como estar a sol directo y ser regada pocas veces (Mandy, 2022), de esta manera el clima influye en los alimentos cultivados dentro de los campos ya sean zanahorias, cebollas, o en este caso de estudio, los jitomates. Entonces, es necesario para mantener un desarrollo correcto de los cultivos analizar distintas variables climáticas como la humedad, la exposición solar, y la temperatura. Dentro del capítulo 2 se mencionan diversos proyectos donde se hace el análisis por medio de días “papa”, temperatura o grados día, en el primer caso el término se adapta a cualquier cultivo cambiando la palabra papa por el de la planta a analizar, pero ambos términos se refieren al tiempo en que un cultivo se encuentra entre temperaturas (máximas o mínimas) que delimitan su zona de desarrollo, dando con esto un tiempo acumulado, en base a los grados, para el desarrollo o el alcance de las distintas etapas de desarrollo.

Por otro lado, un poco alejado de la agricultura, lograr la elaboración del proyecto requiere del uso de diversas técnicas y tecnología para poder analizar estos fenómenos y en base a ello predecir la etapa fenológica en que se encuentre un cultivo. Para esto se debe entender el uso de la palabra “predecir” dentro del proyecto, el término como tal es simplemente decir o anunciar con antelación algo, siendo con esto un término bastante vago y amplio a la vez, una forma de predecir es mediante el análisis de datos pasados que permitan intuir lo que sucederá, usando para estos análisis la estadística y más recientemente la inteligencia artificial; esto se conoce como análisis predictivo y es bastante útil y utilizado en diversas áreas para determinar eventos y tomar decisiones respecto a estos.

Los análisis predictivos parten completamente de las matemáticas ya que permiten modelar situaciones reales, con esto se llega a la estadística, la cual es propiamente una rama de las matemáticas que permite recolectar e interpretar datos, teniendo así el modelado de los sistemas (Ayuda. INEGI, n.d.). Por otro lado, la inteligencia artificial, conocida simplemente como IA, es una implementación de la tecnología para simular procesos humanos como el razonamiento, para esto se hace uso de

TESIS TESIS TESIS TESIS TESIS

algoritmos y métodos que simulan el pensamiento o el accionar humano, y hay diversas maneras de aplicarlo o crearlo, una de ellas son las redes neuronales (Iberdrola Corporativa, n.d.). Cuando se habla del ser humano se sabe que los procesos cerebrales se llevan a cabo por medio de la transmisión de información entre las distintas neuronas, este proceso se adapta dentro de la inteligencia artificial dando pie a las redes neuronales que son una forma o método de la inteligencia artificial que simula estos procesos neuronales reales en los seres humanos. Básicamente se crea un sistema creado por neuronas que procesan y transmiten información entre sí, permitiendo que la inteligencia artificial sea capaz de obtener y dar resultados, entre ellos los buscados en este proyecto, la predicción.

En conjunto estas pequeñas aclaraciones permitirán que la lectura de los siguientes capítulos resulte más sencilla.

3.2 Metodologías usadas en la predicción.

En el capítulo 2 se habló de diversos proyectos realizados para la predicción de etapas fenológicas de diversos cultivos, sirviendo como referencia a lo que se pretende realizar en el proyecto, pero a lo largo de este nuevo capítulo se busca explicar la manera en que en este proyecto se lograrán los objetivos planteados, por esto se iniciará hablando un poco de algunas metodologías usadas para la predicción y al cierre del capítulo se hablará de cómo serán aplicadas estas metodologías y el propósito de ser implementadas en la ejecución del proyecto.

Como se podrá imaginar la predicción parece bastante importante en la sociedad, por lo que los análisis predictivos son puestos en práctica en áreas como negocios para predecir niveles de venta o comportamiento de clientes, o en las finanzas para poder actuar en las bolsas de valores de manera certera, o bien, dentro de la salud un ejemplo sería conocer el comportamiento de un virus o la propagación de éste. Debido a esto existen diversas técnicas utilizadas para la predicción de datos, todas útiles, con diversas tasas de éxito y funcionalidades más o menos aptas a distintas situaciones, entre estas se tienen: la regresión lineal, las series temporales, análisis

bayesiano, machine learning o redes neuronales, siendo estas dos últimas, métodos de inteligencia artificial.

3.2.1 Regresión lineal.

Esta es una técnica matemática que permite modelar diversas variables como ecuaciones lineales, básicamente busca trazar una línea recta entre los datos pertenecientes al modelo. Esta técnica es muy útil debido a que es relativamente sencilla, las respuestas se obtienen al sacar las distancias de los puntos del modelo a la recta marcada; permiten trabajar con más de una variable de entrada, existiendo por ello dos modelos, la regresión lineal simple y la regresión lineal múltiple; y es una técnica aplicable dentro de sistemas de inteligencia artificial. La siguiente fórmula muestra la forma base de una regresión lineal simple:

$$y = \beta_0 + \beta_1 * x + \varepsilon$$

En la fórmula de la regresión lineal simple se utilizan dos parámetros β_0 (intercepto) y β_1 (pendiente) para representar la recta pendiente de la regresión, considerando una variable de error ε . Para la regresión lineal múltiple se sigue el mismo patrón en la función, un vector de parámetros β correspondientes a un vector de variables x , definido por un espacio de p dimensiones (Gujarati, 2009), cuya fórmula es:

$$y = \beta_0 + \beta_1 * x_1 + \beta_2 * x_2 + \dots + \beta_p * x_p + \varepsilon$$

3.2.2 Series temporales.

Permiten clasificar o acomodar datos en relación al tiempo, es decir que acomodan cronológicamente los datos observados lo cual hace de vital importancia este factor. Esta es nuevamente una técnica que puede ser utilizada en modelos clásicos y en sistemas de aprendizaje profundo y redes neuronales, puesto que se usan las series temporales para poder entrenar el sistema, el cual podrá establecer patrones a partir de estas series y brindar resultados sobre el futuro. (SPSS Statistics Subscription - Classic, n.d.).

Dentro de esos patrones se encuentran los siguientes (Box et al., 2015):

- La tendencia. Revisa los patrones que se generan a largo plazo.
- Ciclo. Patrones que se repiten sin un tiempo fijo.
- Estacionalidad. Los ciclos que se crean con período fijo, como ejemplo de esto se pueden ver las estaciones del año: altas temperaturas en verano, descensos de temperatura que inician en otoño, etc.
- Ruido. Los residuales, es decir, todo aquello que no entra en las clasificaciones anteriores teniendo por ejemplo eventos anómalos o especiales.

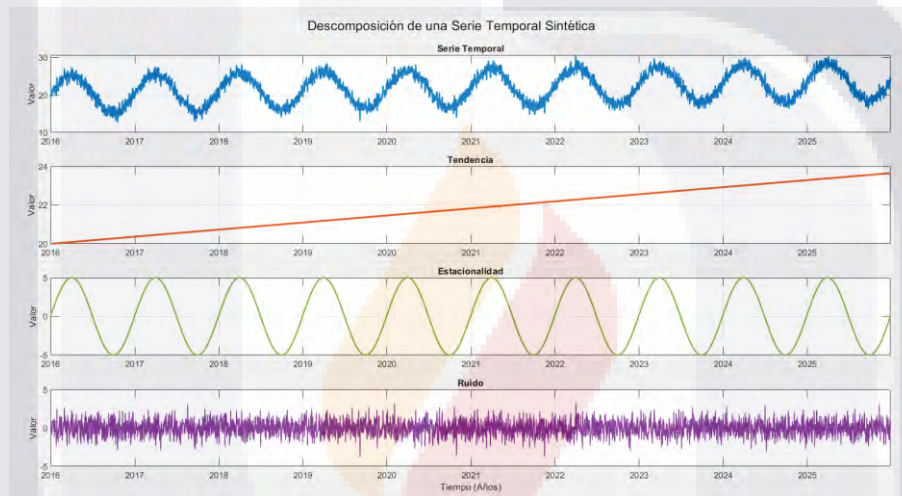


Figura 1 Elementos de serie temporal.

La Figura 1 muestra cómo se pueden ver estos patrones dentro de una serie de tiempo, la serie que se compone por todos los patrones descritos, como el gráfico superior, la tendencia en el caso del gráfico se representa como una línea ascendente que refleja el incremento de temperatura gradual cada año, la estacionalidad graficada como una función seno refleja el cambio de temperaturas a lo largo del año, los ciclos dado que carecen de periodicidad no se contemplan en este gráfico, finalmente, el ruido son esas variaciones que para efectos del gráfico se muestran como aleatorios. Todos forman parte de las series temporales que permiten entonces analizar datos por medio de dichos patrones.

3.2.3 Análisis Bayesiano.

Dentro de la estadística el análisis bayesiano permite analizar y contrastar varias hipótesis para poder lograr una inferencia respecto a ellas, su funcionamiento base se presenta con la siguiente fórmula:

$$\frac{P(H_1)}{P(H_0)}$$

Fórmula donde se hace una comparativa entre las probabilidades de que sucedan la hipótesis 1 $P(H_1)$, y la hipótesis 2 $P(H_0)$, y este análisis permite incluso predecir al inferir mediante distintos elementos la probabilidad de que alguna de las hipótesis resulte correcta (Macías et al., 2018), además funciona de manera iterativa por lo que permite añadir y modificar información para actualizar y ajustar las probabilidades de cada hipótesis para un mejor análisis y mejores resultados.

El proceso general de esta metodología se trabaja como un ciclo, dada la naturaleza iterativa del modelo, incluye una probabilidad inicial, $P(H)$, que sirve como primer análisis para la decisión sobre las hipótesis, posteriormente para verificar la hipótesis se requiere comparar los datos contra la misma, $P(D|H)$, para esto se usa como estimador la verosimilitud finalizando con una probabilidad *a posteriori*, $P(H|D)$, resultado del análisis hecho y por tanto la actualización hecha por los datos con que se alimentó.

Este análisis puede ser incluso utilizado al momento de utilizar otros métodos, puesto que se puede utilizar como análisis para optimizar los resultados al realizar ajustes y modificaciones en los parámetros propios de cada uno.

3.2.4 Machine learning.

Parte de la inteligencia artificial, machine learning es una disciplina que permite que las máquinas sean entrenadas y capaces de aprender por sí mismos bajo uno de los siguientes tres conceptos: aprendizaje supervisado, donde la inteligencia artificial es entrenada de manera previa; el aprendizaje no supervisado, en el cual

no se cuenta con una etapa de entrenamiento o aprendizaje previo al uso de la inteligencia, siendo alimentada al momento estar siendo utilizada o ejecutada; y el aprendizaje por refuerzo donde se utiliza la experiencia como base del aprendizaje. Todo esto tiene una gran cantidad de usos al día de hoy y uno de ellos es la predicción, puesto que permite la identificación de patrones entre los datos hace posible que se logre obtener predicciones (Mitchell, 1997).

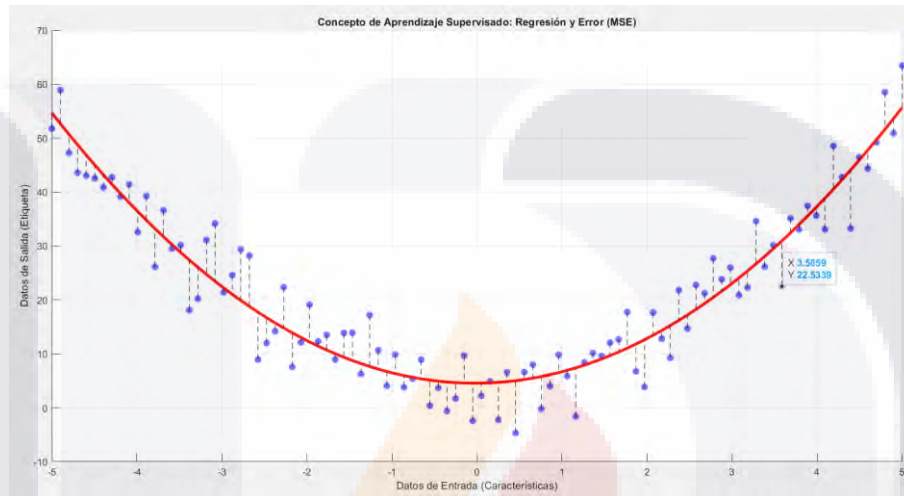


Figura 2 Modelo por Machine Learning.

Como una muestra de cómo funciona el machine learning, se tiene la Figura 2, en ella se muestra un análisis realizado por este método. Los puntos azules representan los datos utilizados para ajustar el modelo y, con color rojo, las predicciones hechas por el modelo. En este ejemplo, el método analiza los datos y realiza un modelo que permite hacer una aproximación a la distribución de los datos reales, es decir, trabaja los residuos buscando minimizar los errores para obtener una aproximación para cada punto en este caso en específico los errores, el cual se calcula a través del Error Cuadrático Medio (MSE, por sus siglas en inglés):

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \widehat{Y}_i)^2$$

Esto es aplicable al querer hacer predicciones dado que la metodología permite crear un modelo en base al cuál predecir a partir de datos históricos.

3.2.5 Árboles de decisiones.

Dentro de las diversas técnicas propias del aprendizaje de máquina, machine learning, existen los árboles de decisiones. Un árbol de decisión es una técnica en la que se separan datos históricos bajo distintos grupos, donde en cada grupo se encuentran datos similares entre sí. Con esto se sabe que los árboles de decisión ayudan a clasificar los datos y realizar una regresión ayudando con esto a que se pueda realizar la predicción de distintos eventos. (¿Qué Es Un Árbol De Decisión? | IBM, n.d.)

Los árboles de decisión son usados como una herramienta en la toma de decisiones, dentro de las características de estos se encuentran elementos para la generación del diagrama (árbol de decisión) como los nodos tanto de decisión, que representan los puntos de inicio de la problemática con los datos iniciales, de eventos que se identifican como todos aquellos nodos que indican condiciones o probabilidades de que suceda cierta situación, y finales, conocidos también como hojas donde se refleja el resultado de cierta línea de decisión; además de las líneas, o ramas, que muestran el camino y consecuencias entre cada nodo, esto es análogo a lo que se realiza por medio de los árboles de decisión creados por machine learning, con nodos raíz, nodos de decisión, hojas y ramas, donde los resultados se analizan. Dado que se analizan resultados por medio de la regresión, minimizando el MSE, cuya fórmula se describe anteriormente en el apartado de machine learning, satisfaciendo así la necesidad de buscar el resultado óptimo (Breiman et al., 1984).

Parte de la importancia de este método yace en su interpretabilidad y el uso de una lógica sencilla que permiten que sea práctico y rápido al momento de comparar múltiples opciones y resultados.

3.2.6 Redes neuronales.

Las redes neuronales se detallan ahora profundizando en las características que brindan su funcionamiento y adaptabilidad de las redes neuronales como herramienta de la inteligencia artificial. Una red neuronal aprende, memoriza, o

TESIS TESIS TESIS TESIS TESIS

categoriza, lográndolo por medio de los siguientes elementos: la arquitectura de una red neuronal, el diseño o estructura en que están interconectadas las diferentes neuronas (o componentes lógicos) que forman parte de la red, con esto se definen entradas y salidas de datos así como la dirección en que se transmite la información con que sea alimentada la red neuronal; el aprendizaje donde se alimenta la red neuronal con distintos datos relevantes al uso de la red neuronal buscando que sea entrenada hasta lograr una variable de error aceptable en los resultados obtenidos; y la capacidad de clasificar la cual hará que la red neuronal tenga suficiente información y conexiones óptimas para crear a partir de los datos guardados una clasificación de patrones, logrando con esto que la red neuronal sea capaz de obtener o inferir su propia información sin necesidad de que sea explícita la información al momento de ser entrenado, esta capacidad es la que permite entonces que la predicción sea llevada a cabo.

Ahora, para la creación de una red neuronal se deben considerar las siguientes etapas: búsqueda y manejo de datos (ingreso de datos para la predicción), creación de la red neuronal, entrenamiento y prueba de la red (validando y analizando los resultados obtenidos). (Escobar R. et al., 2010)

Es importante analizar entonces, una vez conociendo las características y consideraciones de una red neuronal, las variantes que se pueden crear de acuerdo a las modificaciones aplicadas dentro de la red, modificaciones hechas en base a las necesidades del problema a resolver, para esto se tiene que la red neuronal cuenta con una capa de entrada, una capa de salida y entre estas dos, una o más capas ocultas en las que se procesa la información, pudiendo jugar entonces con el número de nodos (que son las unidades que procesarán la información) en cada capa, y el número de capas ocultas, de manera que la información comenzará a ser procesada en la capa de entrada, pasando por las distintas capas ocultas antes de arrojar la información inferida en la capa de salida. Ahora, entendiendo que la red neuronal funciona a partir del procesamiento lógico de la información se comprende que serán necesarias funciones que permitan este procesamiento, teniendo funciones de activación y funciones de entrenamiento, las cuales, nuevamente, son

modificables de acuerdo a la información que se trata y el objetivo de la red neuronal, abriendo así la puerta a que haya una gran variedad de aplicaciones para las redes neuronales cuya complejidad es adaptable, características que serán aprovechadas para lograr el objetivo de este trabajo.

Como se menciona existen una gran variedad de funciones utilizadas en las redes neuronales, pero de manera genérica se explican a continuación las más comunes o básicas para funciones de activación.

Función Lineal. Es una función con valor de salida de x , donde:

$$f(x) = x$$

En la Figura 3, mostrada a continuación, se puede observar de manera gráfica el comportamiento de dicha función, donde se ve claramente la recta que define la función.

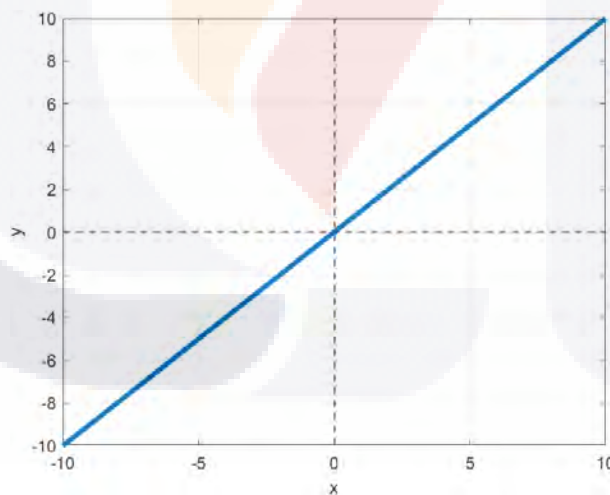


Figura 3 Gráfica de función lineal.

Función sigmoide. Con una curvatura en forma de S y valores de salida de 0 a 1, interpretables como probabilidades, cuya pendiente se modifica en base a la

entrada, teniendo que valores negativos tienden a 0 y positivos muy grandes tienden a 1:

$$f(x) = \frac{1}{(1 + e^{-x})}$$

De manera gráfica este comportamiento puede observarse dentro de la Figura 4, gráfica de función sigmoide, donde el valor de y mínimo es 0 y el máximo 1, tal y como se menciona en el párrafo anterior.




Figura 4 Gráfica de función sigmoide.

Función tangente hiperbólica. Con valores de salida de -1 a 1, y una pendiente modificable de acuerdo a los valores de entrada (Matich, 2001):

:

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$$

Cuya representación puede encontrarse definida por lo mostrado en la Figura 5.




Figura 5 Gráfica de función hiperbólica.

Existen otras funciones utilizadas con menor frecuencia, definidas a continuación:

Función ReLu. Función de unidad lineal rectificada, con salida de 0 a x, o sea, una función lineal con gradiente de 1, da una respuesta lineal para cualquier valor positivo, y todo aquel inferior a 0 arroja como resultado 0:

$$f(x) = \max(0, x)$$

En la Figura 6 se muestra de manera gráfica la función ReLu, donde se ve una recta de valor en y 0 para todas las x iguales o menores a 0, y una respuesta lineal para cualquier valor de x superior a 0.

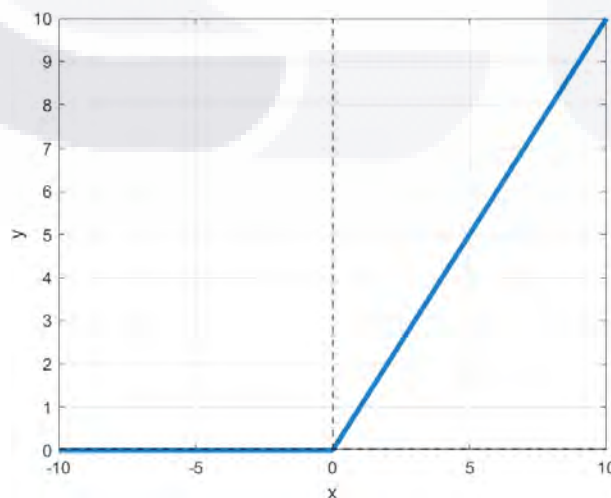


Figura 6 Gráfica de función ReLu.

Función Softmax. Función exponencial normalizada, trabaja con vectores tratándolos como probabilidades, por ello es normalmente utilizada en problemas de clasificación:

$$f(x) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$$

La respuesta de esta función se observa dentro de manera gráfica dentro de la Figura 7, mostrada a continuación, dentro de un rango de x de -10 a 10.

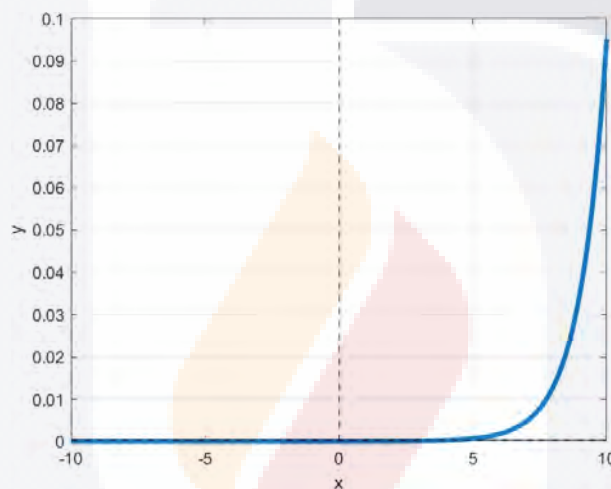


Figura 7 Gráfica de función softmax.

Función base radial. Es una función de tipo Gaussiana la cual determina el valor de salida en base a la distancia respecto al origen:

$$f(x) = e^{-\frac{(x-c)^2}{2\sigma^2}}$$

(Introducción A las Funciones de Activación En las Redes Neuronales, 2024)

Esta última ecuación se encuentra gráficamente representada por la Figura 8, en la cual es posible observar la distribución Gaussiana de la función.




Figura 8 Gráfica de función base radial.

Los distintos usos dados a cada uno de los métodos explicados han permitido obtener en otras áreas resultados más o menos eficaces, dando la idea de que las redes neuronales son una excelente opción debido a la rapidez de la obtención de resultados, así como la certeza de estos. Debido a su arquitectura existen también distintos tipos de redes descritas a continuación que se trabajaran como metodologías en la evaluación fenológica:

Red neuronal feedforward.

Como una de sus principales características se encuentra la falta de retroalimentación en donde, los datos que alimentan a la primera capa son analizados y pasados a la siguiente de manera consecutiva hasta llegar a la capa de salida (Haykin, 2009).

Red neuronal recurrente.

Las redes neuronales recurrentes RNN por sus siglas en inglés (Recurrent Neural Networks), son redes neuronales que trabajan especialmente con series temporales que funcionan por medio de ciclos recurrentes (Goodfellow et al., 2016), contrarias a las redes feedforward las redes recurrentes tienen conexiones de retroalimentación.

Red neuronal función base radial.

Las redes neuronales de función base radial, RBFN por sus siglas en inglés (Radial Basis Function Network) son una variación de las redes feedforward, donde se utiliza una función gaussiana para hacer los cálculos (Buhmann, 2003).

Red neuronal convolucional.

La red neuronal convolucional o CNN (Convolutional Neural Network), son utilizadas en el procesamiento de imágenes dada su arquitectura, capaz de interpretar patrones, con distintas dimensiones y capas que analizan y agrupan información (Goodfellow et al., 2016).

Mapa autoorganizado.

SOM, siglas para Self Organizing Map, o bien, en español mapa autoorganizado. Se introduce como una opción a comparar entre las redes dada la gran diferencia respecto a las mencionadas anteriormente, ya que, trabaja bajo el concepto de aprendizaje no supervisado, dentro de su funcionamiento agrupa datos lo cual es de ayuda para identificar patrones en las variables y en base a ello predecir (Kohonen, 2001).

TESIS TESIS TESIS TESIS TESIS

Para poder lograr los objetivos del proyecto se trabajará con las redes neuronales para la predicción de las etapas fenológicas del jitomate en relación a la situación climática de la región del caso de estudio (Aguascalientes), usando una recopilación de datos históricos de humedad y temperatura, información recopilada dentro de los invernaderos, mediante la implementación de dos métodos distintos que permitirán evaluar todas las variables y su efecto sobre el jitomate, lo cual, finalmente, permitirá probar la hipótesis al trabajar ambos métodos para comparar sus resultados y así verificar la eficiencia de las redes neuronales en la predicción fenológica de cultivos.

Uno de los métodos a utilizar será el método ARIMA que permitirá hacer la predicción mediante los análisis en base a series temporales, siendo este utilizado como un método clásico, y que dentro de la predicción ha mostrado su gran utilidad. El segundo método a utilizar, como se ha mencionado anteriormente son las redes neuronales, las cuales serán usadas como el método de inteligencia artificial y puesto a prueba contra el modelo ARIMA.

Capítulo 4. Exploración de datos y ajuste de modelo.

Con lo definido en el capítulo 3 sobre redes neuronales es posible tener una idea básica de lo necesario para la construcción de redes neuronales, logrando programarlas con diversos recursos y distintos lenguajes de programación, lo cual permite diversificar la estructura de la red neuronal. En este trabajo, se tiene como propósito evaluar e identificar la mejor opción para tratar la predicción fenológica en base a los cambios climáticos, por lo cual dentro de las redes neuronales es importante realizar un análisis de distintas estructuras para identificar la más o las más aptas para el propósito dicho, sabiendo que estas se compararán a su vez con la otra metodología seleccionada (modelos ARIMA).

La exploración de redes neuronales se logra al buscar y evaluar diversos modelos que permitan, por medio de sus características, mostrar el análisis logrado desde diferentes ángulos de una misma predicción, con el fin de que los modelos creados sean fieles y útiles representaciones de la complejidad de variables que intervienen en la fenología. Entre las redes seleccionadas se encuentran:

- Red feedforward (FFN, por sus siglas en inglés).
- Red neuronal recurrente (RNN, por sus siglas en inglés).
- Red de función base radial (RBFN, por sus siglas en inglés).
- Red convolucional (CNN, por sus siglas en inglés).
- Mapa autoorganizado (SOM, por sus siglas en inglés).

Y como otra opción de inteligencia artificial:

- Máquina de soporte vectorial (SVM, por sus siglas en inglés).

Gracias a su variedad, y a la vez, a su alta modificabilidad se ajustan a su vez distintos parámetros en la arquitectura de cada una de ellas, que optimicen la

configuración del modelo realizado para obtener una aproximación adecuada que resulte de utilidad para una predicción de calidad.

Previo a realizar la evaluación de las distintas redes neuronales se desglosa un poco sobre los primeros datos que se analizarán y pondrán a prueba las predicciones de las distintas redes en este capítulo, tomando como evaluadores el MSE y el tiempo de ejecución de cada red. Dentro de las variables fenológicas con mayor variabilidad se encuentran las variables climáticas, por ello se toman datos históricos de clima del estado de Aguascalientes, teniendo 3 casos de estudio: Estación Meteorológica Automática de Aguascalientes (SMN-ESMA) la cual cuenta con información de 90 días entre septiembre y noviembre (recabada cada 5 minutos) de temperatura, precipitación, humedad, presión atmosférica, radiación solar, dirección del viento, rapidez del viento y dirección de ráfaga; Estación Meteorológica Aguascalientes Sur con información diaria de los meses de abril y mayo de 2024, sobre temperatura máxima, temperatura mínima, humedad promedio y presión atmosférica promedio; Estación Meteorológica La Boquilla (860030), con información de agosto 2024 de temperatura, dirección del viento, velocidad del viento y radiación. Siendo estos tres casos de estudio un primer análisis antes del caso específico para esta tesis, donde se considerarán además de variables climáticas las variables de la fenología del cultivo.

4.1 Modelado de variables climáticas.

4.1.1 Caso de estudio 1: Estación Meteorológica Automática de Aguascalientes (SMN-ESMA).

Datos: Temperatura, precipitación humedad, presión atmosférica, radiación solar, dirección del viento, rapidez del viento y dirección de ráfaga.

Variable a predecir: Temperatura.

Variables explicativas: Precipitación humedad, presión atmosférica, radiación solar, dirección del viento, rapidez del viento y dirección de ráfaga.

4.1.2 Caso de estudio 2: Estación Meteorológica Aguascalientes Sur.

Datos: Temperatura máxima, temperatura mínima, humedad promedio y presión atmosférica promedio

Variable a predecir: Temperatura máxima.

Variables explicativas: Temperatura mínima, humedad promedio y presión atmosférica promedio.

4.1.3 Caso de estudio 3: Estación Meteorológica La Boquilla (860030).

Datos: Temperatura, dirección del viento, velocidad del viento y radiación.

Variable a predecir: Radiación.

Variables explicativas: Temperatura, dirección del viento, velocidad del viento y radiación.

4.2 Ajuste de modelo.

4.2.1 Red neuronal: Feedforward.

Comenzando por la red neuronal más genérica se utiliza una red feedforward, usualmente una red neuronal utilizada como referencia dadas sus características y razón por la cual es de utilidad en este caso para un primer acercamiento con la predicción por medio de redes neuronales y una arquitectura base contra la cual comparar el resto de redes más específicas. La arquitectura mostrada en la siguiente Figura (Figura obtenida directamente de Matlab, con la red utilizada) representa la red utilizada para las predicciones en esta tesis.




Figura 9 Estructura de red neuronal 1.

Dentro de la Figura 9 se observa que la red neuronal tiene 5 capas ocultas cada una de ellas con 10 nodos, la entrada y una capa de salida. Con esta primera red se evalúan las funciones que modelen mejor al sistema, teniendo 6 análisis distintos: a, b, c, d, e y f, cuya diferencia radica precisamente en la función de activación utilizada en sus capas ocultas teniendo que a: función lineal, b: función sigmoide, c: función hiperbólica, d: función ReLu, e: función softmax y f: función base radial, todas con el algoritmo Levenberg-Marquardt como función de entrenamiento y una función lineal en la capa de salida.

De esta manera se utilizan las 6 redes neuronales programadas y previamente explicadas para predecir una variable dentro de los casos de estudio, considerando dentro de las redes neuronales el 85% de los datos para entrenamiento y el 15% para prueba, además de que para las 6 redes neuronales se usaron los mismos datos de prueba y de entrenamiento en cada caso, obteniendo que:

Resultados para caso de estudio 1: Estación Meteorológica Automática de Aguascalientes (SMN-ESMA).

La siguiente imagen (Figura 10) muestra las predicciones de temperatura hechas por cada red neuronal, de izquierda a derecha y de arriba abajo por red neuronal a (función lineal), b (función sigmoide), c (función hiperbólica), d (función ReLu), e (función softmax) y f (función base radial).

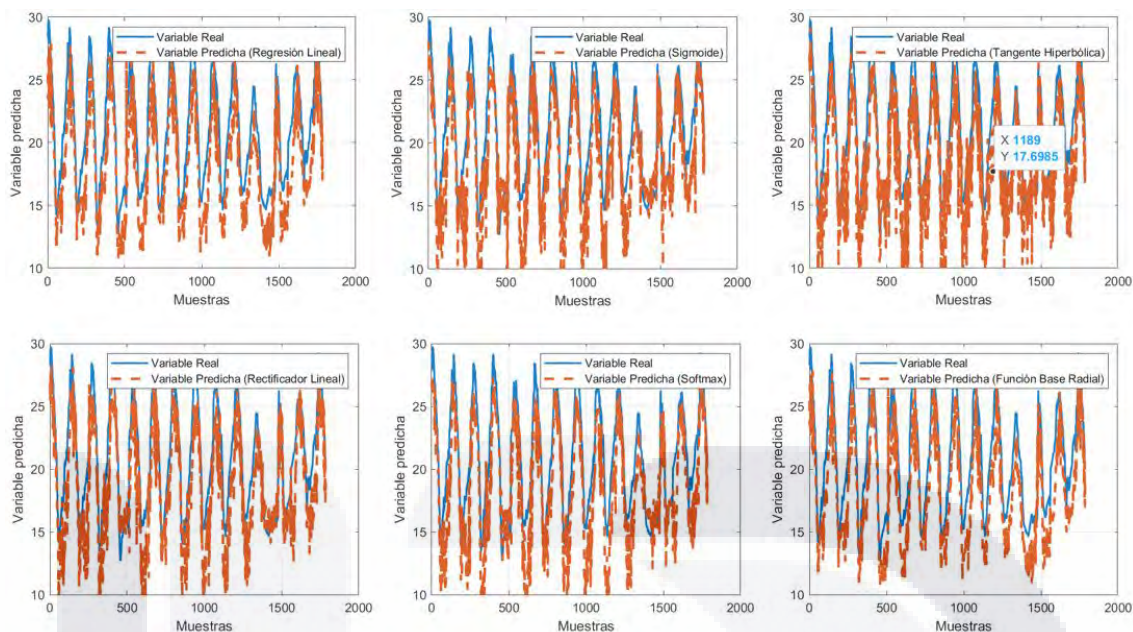


Figura 10 Resultados de predicción caso de estudio SMN-ESMA.

Dichos resultados son evaluados observando numéricamente, dentro de la Tabla 1, el error mínimo cuadrado (MSE) y el tiempo de ejecución de cada configuración de la red feedforward para este primer caso de estudio.

Función de la red	Lineal	Sigmoide	Tangente hiperbólica	ReLu	Softmax	Base radial
MSE	8.05	8.62	8.68	8.75	8.27	10.05
Tiempo	2.99s	15.86s	13.37s	14.30s	39.45s	11.62s

Tabla 1 MSE y tiempo del caso de estudio SMN-ESMA.

Resultados obtenidos para caso de estudio 2: Estación Meteorológica Aguascalientes Sur.

Dentro de la Figura 11 es posible observar de manera gráfica las predicciones hechas por las 6 redes neuronales (a-f), donde de izquierda a derecha en la primera fila se tienen los resultados de las redes a, b y c, y en la segunda fila de las redes d, e y f.

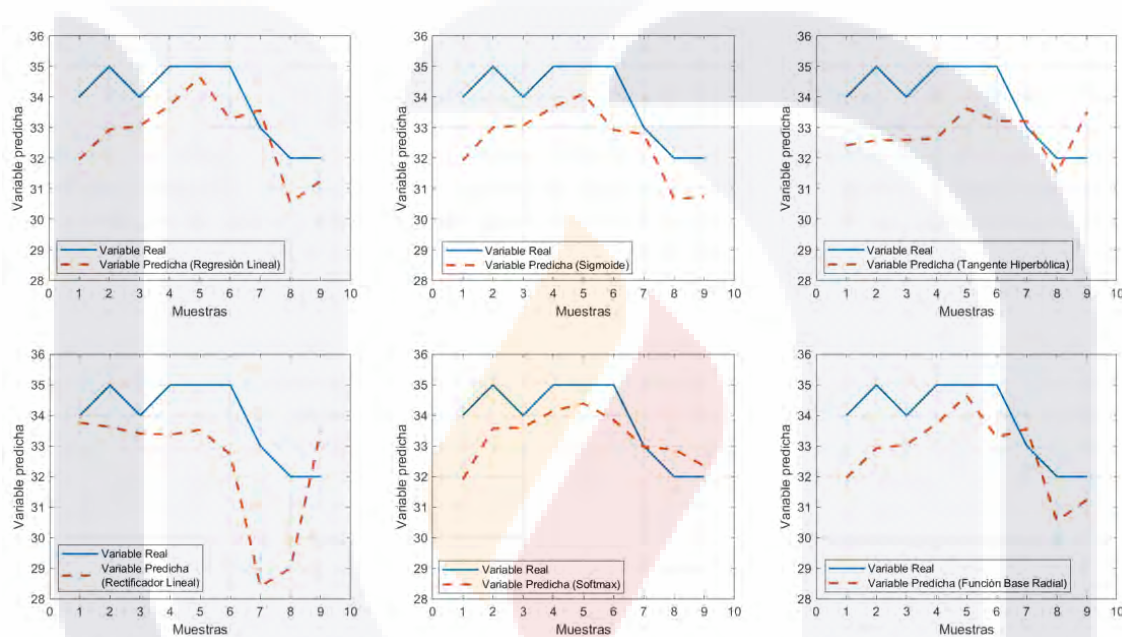


Figura 11 Resultados de predicción caso de estudio Estación Meteorológica Sur.

Para hacer más fácil la interpretación de la gráfica se incluye en la Tabla 2 las evaluaciones realizadas a cada modelo, comparando los errores (MSE) y tiempos de ejecución de las distintas configuraciones de la red, de esa manera se condensan los datos para su análisis, mostrando que el menor error lo obtiene la red e (programada con Softmax), y los tiempos, aunque todos menores a 4 segundos, el mejor valor se obtuvo por la red programada con la función lineal.

Función de la red	Lineal	Sigmoide	Tangente hiperbólica	ReLu	Softmax	Base radial
MSE	2.88	3.20	18.23	4.83	2.37	10.81
Tiempo	2.15s	3.72s	3.82s	3.90s	3.86s	3.92s

Tabla 2 Resultados de predicción caso de estudio Estación Meteorológica Sur.

Resultados obtenidos caso de estudio 3: Estación Meteorológica La Boquilla (860030).

Las predicciones hechas por cada una las redes neuronales se pueden encontrar de manera gráfica en la Figura 12, donde cada gráfica muestra la predicción hecha por una de las redes, utilizando los mismos datos del caso de estudio en cada red.

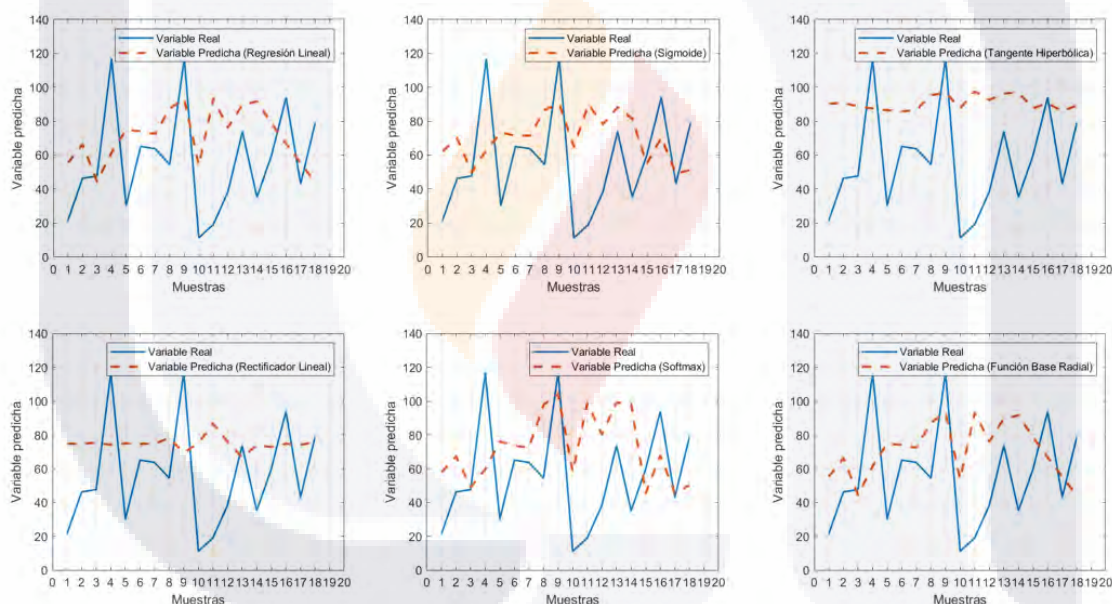


Figura 12 Resultados de predicción caso de estudio Estación La Boquilla.

Dentro de la ya menciona imagen los resultados se encuentran de izquierda a derecha y de arriba debajo para la red a, b, c, d, e y f.

Para hacer un mejor análisis se hace uso de la Tabla 3 donde se encuentran el error mínimo cuadrado y el tiempo de ejecución de cada una de las redes, haciendo a su vez la comparación con entre los resultados de cada una, a partir de lo cual se

puede hacer una mejor evaluación, en este caso la alta variabilidad de la radiación y los pocos datos muestran que las redes no están siendo capaces de modelar acertadamente el modelo, todos los errores son superiores a 1000, por lo que el tiempo a pesar de ser bajo no demuestra que alguna red sea más eficiente que las otras.

Función de la red	Lineal	Sigmoide	Tangente hiperbólica	ReLu	Softmax	Base radial
MSE	1.38×10^3	1.88×10^3	1.70×10^3	1.41×10^3	1.27×10^3	2.80×10^3
Tiempo	2.16s	2.39s	3.81s	3.86s	4.02s	3.95s

Tabla 3 Resultados de predicción cado de estudio Estación La Boquilla.

4.2.2 Red neuronal recurrente (RNN).

En el capítulo 3 se define a la red neuronal recurrente, tomando como justificación la característica de retroalimentación es que incluyen en la comparación, muchas de las variables fenológicas son analizables por medio de series temporales, por ejemplo, el clima es un ejemplo de tendencia y estacionalidad, características inherentes de las series temporales (Box, et al., 2015), tomando esto como base se considera adecuado trabajarlas como opción en la predicción para cultivos.

Se construye de acuerdo a la arquitectura mostrada en la Figura 13, constituida por cinco capas ocultas, donde las tres primeras capas tienen diez nodos y las dos últimas 5 nodos por capa, además de la entrada y la capa de salida.




Figura 13 Arquitectura de red neuronal recurrente.

Resultados obtenidos para el caso de estudio 1: la Estación Automática de Aguascalientes:

Al igual que la red feedforward se evalúa esta nueva red para obtener predicciones de temperatura para este caso de estudio, tomando las mismas variables explicativas y el mismo conjunto de prueba y entrenamiento, observando la imagen 14 se pueden ver los resultados comparando la variable real de la predicha




Figura 14 Predicción de temperatura por RNN para Estación Automática de Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 61.83.

Tiempo de ejecución: 18.10s.

Resultados obtenidos para el caso de estudio 2: Estación Sur de Aguascalientes:

Evaluando la red RNN para las predicciones de temperatura máxima para este caso de estudio, tomando las mismas variables explicativas y el mismo conjunto de prueba y entrenamiento que en el análisis de la feedforward, donde la imagen 15 permite observar la variable real de color azul contra las predicciones hechas por la red en color rojo.

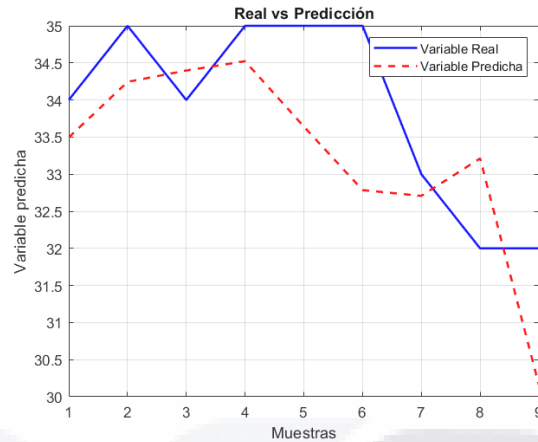


Figura 15 Predicción de temperatura máxima por RNN para Estación Sur Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 1.43.

Tiempo de ejecución: 3.67s.

Resultados obtenidos para el caso de estudio 3: Estación La Boquilla:

En este caso de estudio se predice radiación solar tomando las mismas variables explicativas y el mismo conjunto de prueba y entrenamiento que en el análisis de la red feedforward, mostrando a continuación dentro de la imagen 16 las predicciones hechas por medio de la red recurrente.

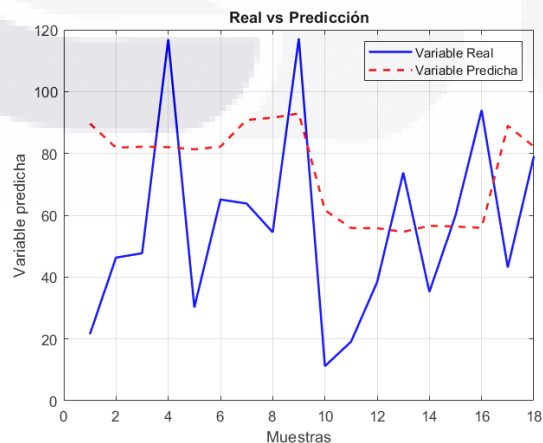


Figura 16 Predicción de radiación solar por RNN para Estación La Boquilla.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 1.25×10^3 .

Tiempo de ejecución: 4.61s.

4.2.3 Redes de función base radial (RBFN).

Tomando una de las variaciones de las redes feedforward se selecciona trabajar con las redes de función base radial, con el fin de probar la eficiencia de un tipo distintos de función de análisis respecto al resto de redes. De manera general su arquitectura se encuentra representada por la Figura 17, cuenta con una capa de entrada, una capa oculta y una capa de salida.




Figura 17 Arquitectura de red neuronal de función base radial.

La complejidad de esta red se puede modificar al cambiar el funcionamiento interno de la red, lo que permite ajustarla a distintas necesidades, para hacer la evaluación y verificar cuál es más apta para la predicción fenológica se opta por utilizar dos: regresión generalizada, que realiza estimaciones no lineales y converge rápidamente; y proceso incremental, que va añadiendo nodos hasta llegar a una precisión deseada, con el fin de revisar cuál de las dos es más útil de acuerdo a la característica de los datos con que se alimente, parte de que sea seleccionada es también el hecho de que son redes generalmente muy rápidas, lo cual es relevante al incluir dentro de las comparaciones el tiempo de ejecución.

Resultados obtenidos para el caso de estudio 1: Estación Automática de Aguascalientes:

Para esta red neuronal se mostrarán los resultados de las configuraciones a la par, siendo así que la RBFN que en la Figura 18 se muestran las predicciones hechas para el primer caso de estudio, temperatura en la estación automática de Aguascalientes, donde del lado izquierdo se tienen los resultados obtenidos por la red de regresión generalizada, y del derecho por la red de proceso incremental.

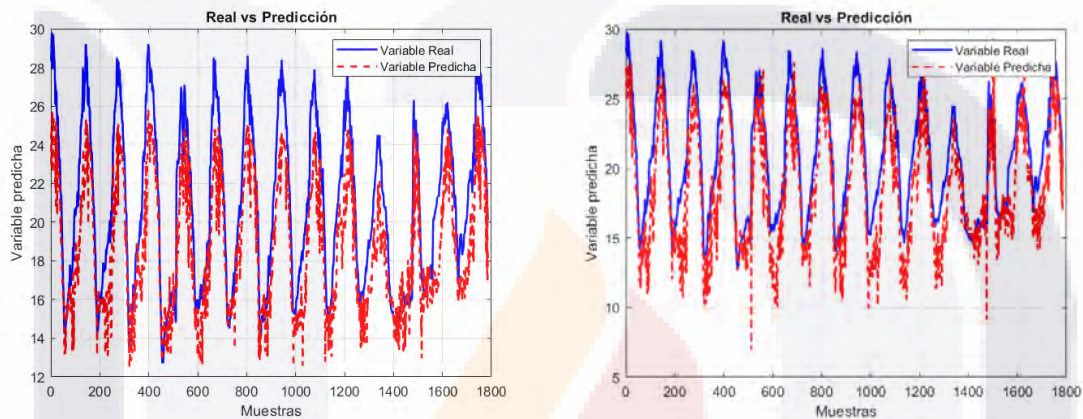


Figura 18 Predicción de temperatura por RBFN para Estación Automática de Aguascalientes.

Cálculo de error: Se calcula un error mínimo cuadrático (MSE) de 7.05 para regresión generalizada y 7.92 para la red de proceso incremental.

Tiempo de ejecución: Con un tiempo de 1.07s para RBFN de regresión generalizada y 66.87s para proceso incremental.

Resultados obtenidos para el caso de estudio 2: Estación Sur de Aguascalientes:

Ejecutando ahora los programas para la predicción de temperatura máxima en el segundo caso de estudio (estación sur de Aguascalientes) se obtienen los resultados para la red de función base radial, donde la Figura 19 permite apreciar la variable real contra la variable predicha siendo del lado izquierdo la evaluación para

la red de regresión generalizada y del derecho la evaluación para el proceso incremental.




Figura 19 Predicción de temperatura máxima por RBFN para Estación Sur Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 3.54 para la red con regresión generalizada y 2.31 para la red con proceso incremental.

Tiempo de ejecución: La red programada con regresión generalizada tomó un tiempo de 0.81s, mientras que la programada con proceso incremental tuvo un tiempo de 1.06s.

Resultados obtenidos para el caso de estudio 3: Estación La Boquilla:

Prediciendo radiación solar para los datos recopilados de la estación de La Boquilla se muestra la imagen 20 con los resultados obtenidos al trabajar con la red neuronal de función base radial, donde del lado izquierdo se muestra la gráfica de la variable real contra la predicha al usar la regresión generalizada, y del lado derecho la gráfica de la variable real contra la predicha al usar el proceso incremental.

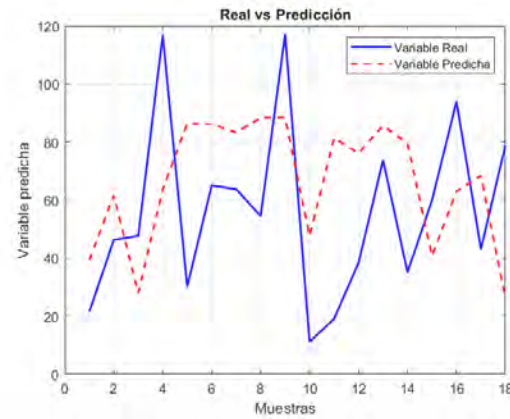
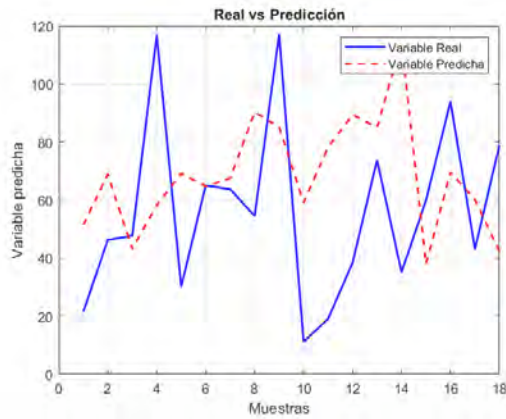


Figura 20 Predicción de radiación solar por RBFN para Estación La Boquilla.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 1.46×10^3 para regresión generalizada y 1.29×10^3 para proceso incremental.

Tiempo de ejecución: 0.80s en la red que utiliza regresión generalizada y 1.09s en la RBFN programada con un proceso incremental.

4.2.4 Red convolucional (CNN).

Se utiliza una red neuronal convolucional o CNN (Convolutional Neural Network), aunque son usadas principalmente para el procesamiento de imágenes en este caso se programa para analizar el problema de la fenología, justificando su uso en la capacidad que tienen de identificar patrones, en este caso esto podría ser de utilidad en la identificación de características de las variables fenológicas, función que se evaluará contra el resto de redes. La arquitectura se ajusta para trabajar con 1 dimensión, 2 capas de reducción, 2 convolucionales y 2 completamente conectadas, que en conjunto permiten analizar y agrupar la información para poder hacer una predicción (Goodfellow et al., 2016).

Resultados obtenidos para el caso de estudio 1: Estación Automática de Aguascalientes:

Al igual que para el resto de redes se tomando las mismas variables explicativas y el mismo conjunto de prueba y entrenamiento, pudiendo ejecutar el programa y obtener la predicción de temperatura para el caso de estudio, observando la imagen 21 se pueden ver los resultados comparando la temperatura real con la temperatura predicha.




Figura 21 Predicción de temperatura por CNN para Estación Automática de Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 8.23.

Tiempo de ejecución: 26.15s.

Resultados obtenidos para el caso de estudio 2: Estación Sur de Aguascalientes:

Evaluando la red CNN para las predicciones de temperatura máxima para este caso de estudio, se obtienen los resultados mostrados en la Figura 22, donde la temperatura máxima real se muestra de color azul, mientras que la temperatura máxima predicha se muestra de color rojo.




Figura 22 Predicción de temperatura máxima por CNN para Estación Sur Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 2.35.

Tiempo de ejecución: 21.96s.

Resultados obtenidos para el caso de estudio 3: Estación La Boquilla:

Prediciendo la radiación solar, tomando las mismas variables explicativas y el mismo conjunto de prueba y entrenamiento que en el resto de análisis, se observa dentro de la imagen 23 los resultados logrados por medio de la red convolucional.




Figura 23 Predicción de radiación solar por CNN para Estación La Boquilla.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 1.63×10^3 .

Tiempo de ejecución: 9.16s.

4.2.5 Mapas Autoorganizado (SOM).

Se utiliza también un mapa autoorganizado debido a la forma en que analiza la información, diferente al resto de redes trabajadas anteriormente en este documento, al trabajar por medio del aprendizaje no supervisado utilizando su capacidad de identificar patrones en las variables fenológicas y prediciendo en base a ellas.

Construido para estos análisis como una malla de 5x5, esta arquitectura se puede observar en la Figura 24.




Figura 24 Arquitectura de SOM.

Resultados obtenidos para caso de estudio 1: Estación Automática de Aguascalientes:

Utilizando los mismos conjuntos de prueba y entrenamiento que en las redes anteriores se predice la temperatura para este caso de estudio, los resultados obtenidos al evaluar por medio del mapa autoorganizado se pueden observar dentro de la imagen 25 donde se comparan la temperatura real contra la temperatura predicha.




Figura 25 Predicción de temperatura por SOM para Estación Automática de Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 9.35.

Tiempo de ejecución: 5.52s.

Resultados obtenidos para caso de estudio 2: Estación Sur de Aguascalientes:

Evaluando la red SOM para las predicciones de temperatura máxima se obtiene la Figura 26, la cual permite observar la variable real de color azul contra las predicciones hechas por la red en color rojo, recordando que se predice temperatura.

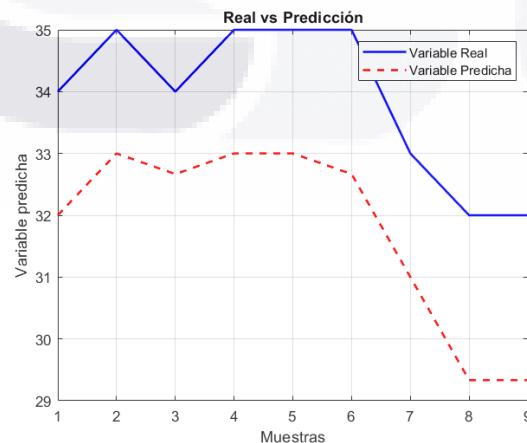


Figura 26 Predicción de temperatura máxima por SOM para Estación Sur Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 4.60.

Tiempo de ejecución: 2.07s.

Resultados obtenidos para caso de estudio 3: Estación La Boquilla:

Finalmente, para este caso de estudio se predice nuevamente la radiación solar, trabajando con el mapa autoorganizado programado, teniendo que la Figura 27 permite apreciar la radiación real contra la predicha de acuerdo a los datos con que se entrenó.




Figura 27 Predicción de radiación solar por SOM para Estación La Boquilla.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 986.03.

Tiempo de ejecución: 2.25s.

Máquina de soporte vectorial (SVM).

Como última metodología de inteligencia artificial se trabaja también una máquina de soporte vectorial, SVM (Support Vector Machine), la cual, a pesar de no ser propiamente una red neuronal, si es una herramienta de aprendizaje automático que ha mostrado tener en otros casos buenos resultados a la hora de realizar

predicciones, siendo utilizada en este proyecto como otro método de comparación principalmente por su robustez frente a las redes neuronales.

Resultados obtenidos para caso de estudio 1: Estación Automática de Aguascalientes:

Se trabaja al igual que el resto de redes neuronales, con el mismo conjunto de prueba y entrenamiento, la Figura 28 permite observar la temperatura real (de color azul) contra la temperatura predicha por la SVM (en color rojo).

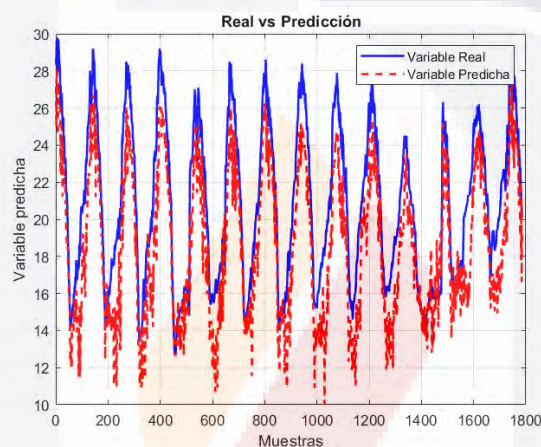


Figura 28 Predicción de temperatura por SVM para Estación Automática de Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 7.34.

Tiempo de ejecución: 3.93s.

Resultados obtenidos para caso de estudio 2: Estación Sur de Aguascalientes:

Se ejecuta la SVM para predecir la temperatura máxima, tomando las mismas variables explicativas y el mismo conjunto de prueba y entrenamiento que en el análisis de las redes neuronales, la imagen 29 muestra la variable real de color azul contra las predicciones hechas por la red en color rojo.




Figura 29 Predicción de temperatura máxima por SVM para Estación Sur Aguascalientes.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 2.48.

Tiempo de ejecución: 0.48s.

Resultados obtenidos para caso de estudio 3: Estación La Boquilla:

La Figura 30, mostrada a continuación, muestra los resultados obtenidos por la máquina de soporte vectorial (SVM), donde la radiación solar real es la variable a predecir y en color rojo la radiación predicha por SVM.




Figura 30 Predicción de radiación solar por SVM para Estación La Boquilla.

Cálculo de error: Con un error mínimo cuadrático (MSE) de 1.15×10^3 .

Tiempo de ejecución: 0.48s.

Todas las redes neuronales programadas y puestas a prueba con los casos de estudio de variables meteorológicas permiten obtener un resultado deseado, que era precisamente predecir alguna de las variables en base a distintas variables explicativas, teniendo conjuntos de datos con características diferentes, por ejemplo, la primera base de datos (Estación Meteorológica Automática de Aguascalientes) contaba con una gran cantidad de datos siendo también el caso con más variables explicativas, por el contrario de la estación de La Boquilla la cual tenía las variables más pobres en cuanto relaciones con ellas mismas y al mismo tiempo con más variación.

Esto permite realizar un primer análisis de la construcción dada a cada una de las redes neuronales, observando que los resultados varían ampliamente no solo en cuanto a arquitectura de la red sino también en cuanto a la naturaleza de los datos a evaluar. Con esto se puede adelantar que efectivamente las redes neuronales funcionan como una herramienta para predecir y que pueden tener utilidad en el análisis climático y por tanto se pueden utilizar en el análisis fenológico, pero que la mejor opción se elegirá una vez que se trabaje sobre el conjunto de datos que pertenezcan al caso específico.

Capítulo 5. Caso de estudio VERDUMEX.

En el capítulo anterior se habla de las redes neuronales seleccionadas y la arquitectura dada a cada una de ellas evaluando sobre algunos casos de estudio del clima de Aguascalientes. En este nuevo capítulo se busca hablar del caso de estudio donde se aplica este proyecto, conociendo las necesidades del caso de estudio, los datos que se encuentran y las aplicaciones que se pueden dar para cerrarlo con la evaluación de las distintas redes neuronales.

El trabajo que da pie a esta investigación comienza en Verduras Mexicanas La Boquilla (VERDUMEX) encontrados en el municipio de Jesús María, Aguascalientes, donde se lleva a cabo el cultivo de dos variedades de jitomate dentro de 5 invernaderos, llevando registro y control de variables climáticas dentro del invernadero 3 y 5 (con sensores y tableros), además del análisis de fenología, trabajando esta parte por muestreo de plantas en cada invernadero, conociendo y controlando la fertilización de los cultivos, así como la polinización de las plantas por medio de abejorros.



Figura 31 VERDUMEX.

La Figura 29 muestra de izquierda a derecha algunas imágenes recopiladas en la visita hecha a Verduras Mexicanas La Boquilla, siendo la primera la vista exterior de algunos invernaderos, al centro las plantas de jitomate cultivadas dentro de los invernaderos, y a la derecha el tablero que recopila información del clima dentro de uno de los invernaderos y que a su vez automatiza el movimiento de las ventanas.

Dentro de la Tabla 4 se pueden observar algunas de las distintas variables que son registradas en la Boquilla y que son parte del estudio fenológico de los cultivos.

Variables Climáticas	Variable fenológica
Temperatura	Crecimiento de la planta
Humedad relativa	Número de flores abiertas
	Tamaño de pedicelos
	Número de racimos
	Número de hojas
	Número de frutos

Tabla 4 Variables registradas por VERDUMEX.

Además de estas variables se tienen algunas ya definidas como lo pueden ser las características propias de cada tipo de planta trabajada en VERDUMEX, es decir, un ejemplo de esto sería la duración del ciclo de vida de la planta donde para el tipo 1 se tienen 29 semanas y para el tipo 2 14 semanas, esto se conoce debido a años anteriores de cosecha en VERDUMEX.

Como se ha mencionado a lo largo de todo el documento, el propósito de predecir yace en ayudar a conocer la fenología de los cultivos y poder tomar decisiones para el cuidado del mismo, por lo que tras identificar las distintas variables que pueden intervenir se puede desarrollar un modelo que permita definir el cultivo de jitomates como se lleva a cabo en VERDUMEX, es decir que se puede trabajar con las variables deseadas o requeridas y con esto dar mayor o menor complejidad al sistema, ayudando a que los alcances del proyecto sean tales que cumplan las necesidades del cultivo o la empresa, de manera que se puedan conocer temperaturas ideales, necesidades de fertilizantes, abejorros, o incluso tiempos

óptimos de cosecha de acuerdo a lo que haya vivido el cultivo o las situaciones a las que se haya expuesto.

En este sentido para este primer proyecto se trabajan únicamente las variables climáticas puesto que es lo que se ha planteado como primera necesidad, que es afrontar el cambio climático en relación a la fenología del jitomate, dado que no es posible controlar las variables en cada uno de los invernaderos, pero dejando en claro con lo anterior que el proyecto se puede seguir trabajando para mejorar resultados y evaluar más necesidades fenológicas del cultivo.

5.1 Predicción de variables climáticas VERDUMEX.

Para probar la predicción de las distintas redes neuronales en este caso de estudio se toma como primer análisis la predicción para las variables climáticas donde se toman como variables los registros de dos invernaderos distintos (invernadero 3 e invernadero 5), con temperatura máxima, temperatura mínima, humedad relativa máxima y humedad relativa mínima por día, con el registro de las semanas en las que se ha estado cultivando el jitomate, utilizando las mismas redes neuronales descritas en el capítulo anterior.

Es importante mencionar que para todos los casos se tomaron los mismos valores como variables de entrenamiento y prueba, de manera que la comparación hecha entre los resultados de todas las redes neuronales sea significativa.

5.1.1 Feedforward

- Invernadero #3

La Figura 32 nos permite observar la predicción de temperatura mínima hecha por la red neuronal feedforward, de donde se obtienen algunos estadísticos que nos permitan hacer una comparación del sistema con el resto de redes, para esto se considera que se evalúa 50 veces la red neuronal, esto aplica para ambos

invernaderos con todas las redes neuronales, este análisis final se muestra en la parte de resultados.




Figura 32 Temperatura mínima real y predicha por red feedforward en Invernadero #3.

- Invernadero #5

Para el Invernadero #5 se vuelve a intentar predecir la temperatura mínima, donde se obtiene como resultado la predicción mostrada en la Figura 33, en este caso teniendo de color rojo la temperatura mínima predicha y en color azul la temperatura mínima real registrada por los sensores en el invernadero.




Figura 33 Temperatura mínima real y predicha por red feedforward en invernadero 5.

5.1.2 RNN

Recordando la red neuronal recurrente se pone a prueba con la información recopilada de ambos invernaderos obteniendo como resultados las predicciones mostradas por las Figuras 33 y 34, siendo la Figura 33 correspondiente al Invernadero #3, y la Figura 34 al Invernadero #5. En ambos casos se predice temperatura mínima, comparándola con la temperatura mínima real registrada en los invernaderos.

- Invernadero #3




Figura 34 Temperatura mínima real y predicha por red recurrente en invernadero 3.

- Invernadero #5




Figura 35 Temperatura mínima real y predicha por red recurrente en invernadero 5.

5.1.3 RBFN (regresión generalizada)

Se hace el mismo desarrollo para las redes neuronales de función base radial, donde la primera en ponerse a prueba es la red programada con regresión generalizada. La Figura 36 muestra los resultados obtenidos por esta red tras ser entrenada y trabajada con la información del Invernadero #3, mientras que la Figura 37 muestra la temperatura mínima predicha por la red dada la información del Invernadero #5.

- Invernadero #3




Figura 36 Temperatura mínima real y predicha por red base radial (RG) en invernadero 3.

- Invernadero #5




Figura 37 Temperatura mínima real y predicha por red base radial (RG) en invernadero 5.

5.1.4 RBFN (proceso incremental)

Recordando que las redes función base radial se trabajaron bajo dos configuraciones distintas se muestran dentro de las Figuras 38, temperatura predicha en el Invernadero #3, y 39, temperatura predicha en el Invernadero #5, los resultados obtenidos al trabajar con la red programada con proceso incremental.

- Invernadero #3




Figura 38 Temperatura mínima real y predicha por red base radial (PI) en Invernadero #3.

- Invernadero #5




Figura 39 Temperatura mínima real y predicha por red base radial (PI) en Invernadero #5.

5.1.5 CNN

Para las redes convolucionales se sigue el mismo procedimiento que para el resto de redes neuronales, entrenando la red neuronal con la información histórica de los invernaderos, comenzando por el Invernadero #3 donde se logran las predicciones mostradas dentro de la Figura 40, posteriormente se trabaja con la información del Invernadero #5, a partir de la cual se obtiene la predicción mostrada dentro de la Figura 41, ambas mostradas a continuación.

- Invernadero #3




Figura 40 Temperatura mínima real y predicha por red convolucional en Invernadero #3.

- Invernadero #5




Figura 41 Temperatura mínima real y predicha por red convolucional en Invernadero #5.

5.1.6 SOM

Se finaliza el análisis de redes neuronales con los mapas autoorganizados (SOM), donde la Figura 42 muestra las predicciones hechas para el Invernadero #3 tras ser entrenado con los históricos registrados dentro del invernadero, y la Figura 43 donde se aprecian los resultados para el Invernadero #5, sabiendo que ambas Figuras muestran la predicción de temperatura mínima (en color rojo en los gráficos) contra la temperatura mínima real registrada en cada invernadero (de color azul).

- Invernadero #3




Figura 42 Temperatura mínima real y predicha por SOM en Invernadero #3.

- Invernadero #5




Figura 43 Temperatura mínima real y predicha por SOM en Invernadero #5.

5.1.7 SVM

Para finalizar el análisis con herramientas de inteligencia artificial se cierra el caso de estudio con las máquinas de soporte vectorial, donde se obtienen como resultados las predicciones mostradas por las Figuras 44 y 45, para los invernaderos #3 y #5 según corresponde.

- Invernadero #3




Figura 44 Temperatura mínima real y predicha por SVM en Invernadero #3.

- Invernadero #5




Figura 45 Temperatura mínima real y predicha por SVM en Invernadero #5.

Este análisis se desarrolló siguiendo el mismo proceso que en las redes neuronales (en cuanto a variables de entrenamiento y prueba, así como número de pruebas), con el fin de funcionar como otro control para evaluar la eficiencia de las redes neuronales para el caso de estudio.

5.2 Implementación de las redes neuronales en el análisis fenológico del cultivo.

Finalmente, para poder cerrar el análisis fenológico es necesario encontrar la relación de las variables fenológicas respecto al rendimiento obtenido de jitomate (este último se analiza de manera individual más adelante para comparar contra el modelo ARIMA). Como principal barrera se encuentra la información obtenida de las variables fenológicas correspondientes al año 2025, mientras que la información de cosechas de jitomates corresponde al año 2019.

Sin embargo, para lograr el análisis se cuenta con información sobre las plantas que empata con la fecha en que se recopilaban otras variables como las climáticas anteriormente evaluadas, es en base a éstas que se realizará el análisis fenológico, esto será modificable para involucrar más variables, predecir cosechas futuras,

analizar la toma de decisiones o cambiarlo para ser aplicado a otros cultivos u otros estados.

El modelo que se presentará a continuación sirve para relacionar las variables que permitan comenzar a identificar puntos de oportunidad para las decisiones sobre el cultivo.

5.2.1 Análisis fenológico Invernadero #5.

Frutos en planta (a predecir): Semana 20 a 24.

Crecimiento de planta y flores abiertas (información fenológica): Semana del 20 al 24.

Temperatura y humedad en el invernadero (información climática): Semana 12 a 24.

Nivel de polinización (información fenológica): Semana 14 a 24.

Ya que la información climática y de polinización es información previa a la de la fenología y desarrollo de la planta se opta analizar por una red recurrente que permite analizar valores pasados (como retrasos) para hacer el modelo y predicciones correspondientes, esta información referente a la red neuronal se menciona dentro del capítulo anterior.




Figura 46 Predicción de fenología Invernadero #5

La Figura 46 muestra los resultados obtenidos por medio de la RNN (en línea punteada), donde el modelo es bastante cercano a la fenología del jitomate, con lo que se muestra que la red neuronal, seleccionada en base a las características de los datos, es capaz de simular adecuadamente la fenología de los cultivos y ser utilizada como una herramienta por el agrónomo o agricultor. En este caso el error se muestra al inicio de la gráfica, donde los frutos predichos son más de los que realmente existen, en este sentido sería importante hacer también un análisis a las variables para observar si hay puntos anómalos, en este caso la serie de datos es bastante corta y no contempla todo el ciclo del jitomate lo cual es un factor importante en el error notado.

Además, el análisis se realizó en un tiempo de: 2.7, con un MSE fue: 11.1 y un coeficiente de determinación (R^2) de 0.87.

Discusión de Resultados

Dentro de esta sección se encuentra la discusión de los resultados obtenidos, donde se incluye el análisis de los resultados del caso de estudio con las múltiples redes neuronales, añadiendo en base a dicho análisis los resultados obtenidos para la predicción de toneladas de jitomate cosechadas por VERDUMEX en el 2019, el cual se resuelve por medio de una red neuronal, seleccionada en base a los resultados obtenidos previamente, y por medio del modelo ARIMA.

En el capítulo anterior se ponen a prueba cada una de las redes neuronales programadas para analizar la predicción de temperatura en base a los históricos recopilados por VERDUMEX, mostrando gráficamente los resultados obtenidos por cada una de ellas, sin embargo, para poder hacer un análisis de los resultados obtenidos se muestran a continuación unas Tablas donde se compara el error obtenido, así como el tiempo de ejecución.

Análisis Invernadero #3.

Red Neuronal	Error absoluto	MSE	R ²	Sesgo	Tiempo
Feedforward	2.8538	13.6062	-5.6192	-1.5615	0.4047
RNN	2.5743	10.896	-4.3007	-1.3597	0.5045
RBFN regresión	1.5848	4.3769	-1.1293	-1.3484	0.0546
RBFN incremental	6.8931	192.535	-92.6657	4.8359	0.0976
CNN	1.7615	4.9759	-1.4207	-0.7547	12.0365
SOM	1.9744	5.559	-1.7044	-1.5237	0.3072
SVM	1.9109	4.6985	-1.2857	-1.5418	0.0284

Tabla 5 Errores y tiempos obtenidos para el Invernadero #3.

Dentro de la Tabla 5 se muestra el análisis de los errores y tiempos obtenidos para las predicciones hechas por las distintas redes neuronales con la información recopilada del Invernadero #3, las predicciones de temperatura se encuentran en el capítulo anterior en las distintas imágenes, para este análisis se calcula el error

absoluto, el error mínimo cuadrado encontrado dentro de la columna MSE, en la siguiente columna el coeficiente de determinación que nos ayuda a saber si nuestra red define apropiadamente al sistema y en qué porcentaje lo hace, mostrando también el sesgo de los resultados obtenidos y finalmente el tiempo de ejecución que le tomó a cada red neuronal llegar a dar una predicción. De esta manera la Tabla 5 permite realizar una comparación estadística de todas las predicciones realizadas para el Invernadero #3 con el fin de analizar cuál es la que mejor define al modelo.

Se puede observar así que los errores más bajos son para la red neuronal de función base radial programada con la regresión generalizada, seguida por la red convolucional (CNN). Por otro lado, el coeficiente de determinación nos muestra para todos los casos que no hay una buena aproximación de las redes neuronales con el sistema, indicando un problema, donde se puede intuir que dadas las características de los datos utilizados, así como las características de las redes neuronales y las necesidades para una buena predicción que el problema viene de que existe muy poca información, en este caso muestras, para ajustar mejor el modelo considerando que las variables climáticas son ampliamente cambiantes y sujetas a diversos factores como la ciclicidad y afectadas por los cambios climáticos que afectan al mundo, las redes neuronales no logran deshacerse de la generalización con los datos con que fueron alimentadas. Sin embargo, es posible verificar que nuevamente algunos de los valores que se pueden considerar menos malos son los obtenidos por la red de función base radial con regresión generalizada y la CNN, coincidiendo así con el análisis hecho de sus errores, para este coeficiente se añade también a la máquina de soporte vectorial (SVM) como una opción al tener también uno de los menos malos.

El sesgo nos habla de que tanto difiere la predicción del valor real de la temperatura donde se tiene que las predicciones más certeras se obtienen nuevamente por la CNN, seguida de la red de función base radial con regresión generalizada.

Finalmente, al buscar eficiencia evaluamos el tiempo para saber si los resultados obtenidos por las redes compiten con el resto, teniendo aquí que los menores

tiempos son para la máquina de soporte vectorial y la red de función base radial de regresión generalizada. Para esta característica la red convolucional deja de competir con el resto de redes puesto que tiene el peor tiempo de ejecución, mientras que la función de base radial con proceso incremental muestra un buen tiempo, observando, sin embargo, que obtuvo los peores resultados para errores y R^2 .

De esta manera, tras analizar los distintos factores y considerando que no se puede crecer inmediatamente la base de datos con que se realizan las predicciones de temperatura y que las diferencias entre los errores, sesgo y coeficiente de determinación son más grandes y relevantes para el análisis que la diferencia entre tiempos de ejecución (analizando por ejemplo la máquina de soporte vectorial, la CNN y la red de función de base radial con regresión generalizada), se puede concluir que la mejor opción para el invernadero 3 es la red de función base radial con regresión generalizada. Esto se comparará igualmente con lo observado para el invernadero 5, el modelo ARIMA y el caso de predicción de toneladas cosechadas de jitomate.

Análisis Invernadero #5.

Tal como se realiza para los resultados obtenidos para el Invernadero #3, se muestra ahora el resumen del análisis de la predicción realizada para el Invernadero #5, teniendo de esta manera la Tabla 6.

Invernadero 5 (promedios)					
Red Neuronal	Error absoluto	MSE	R^2	Sesgo	Tiempo
Feedforward	4.0397	22.7836	-6.7395	-3.4845	0.4942
RNN	4.4577	26.1306	-7.8765	-3.6854	0.5499
RBFN regresión	4.2266	21.6477	-6.3537	-4.2266	0.0535
RBFN incremental	4.5242	30.4718	-9.3512	-2.2184	0.1091
CNN	3.5009	17.0764	-4.8008	-2.9717	14.3805
SOM	4.0718	20.4011	-5.9302	-4.0718	0.3491
SVM	4.4528	21.7904	-6.4022	-4.4528	0.0294

Tabla 6 Errores y tiempo obtenido para el Invernadero #5.

Dentro de la Tabla 6 se encuentran los valores para el error absoluto, el error mínimo cuadrado (MSE), el coeficiente de determinación (R^2), el sesgo y el tiempo que tomó obtener la predicción por cada una de las redes neuronales probadas para el caso del Invernadero #5.

Con la información observada dentro de la Tabla es posible identificar que los errores más bajos se obtuvieron por la CNN, que es la única con una diferencia notable al resto de redes con un error de 3.5, la red feedforward, el mapa autoorganizado (SOM), la red de función base radial (RBFN) programada con regresión generalizada con un error absoluto de 4.2 es la mediana de los datos y, finalmente, el mayor error de 4.52 para la RBFN de proceso incremental.

En cuanto al error mínimo cuadrado se conserva la red convolucional como la red con el menor error (de 17.07), el mapa autoorganizado con un error de 20.4, en este caso la red de función base radial de regresión generalizada obtiene el tercer menor error mínimo cuadrado siendo éste de 21.64, y como cuarta opción se posiciona la máquina de soporte vectorial (SVM) con un error de 21.79, nuevamente el peor resultado es para las predicciones hechas por función base radial con proceso incremental, aunque las redes recurrentes también tienen un error mínimo cuadrado bastante alejado al del resto de redes.

Por su parte, el coeficiente de determinación está indicando que el proceso no está siendo bien definido por ninguna de las redes, puesto que todos tienen valores bastante altos y en este caso negativos, nuevamente se plantea esto como una consecuencia de la propia variabilidad de las variables climáticas evaluadas sumado a la poca cantidad de datos con que se entrenaron. A pesar de esto se evalúa y se toman como mejores redes las que se encuentran menos alejadas del valor ideal para un coeficiente de determinación, teniendo así a la red convolucional con -4.8, el mapa autoorganizado con -5.9 y la red de función base radial de regresión generalizada con -6.3, repitiendo así el orden del error mínimo cuadrado, por lo que con los estadísticos revisados hasta ahora se van marcando como mejores opciones estas tres redes neuronales. El sesgo que permite evaluar que

tan alejada está la predicción (temperatura máxima) de la variable real muestra que para el Invernadero #5 la más cercana es la RBFN programa con proceso incremental la cual tiene el menor sesgo con un valor de -2.21, seguida por la CNN, donde la que muestra estar más alejada es la RBFN de regresión generalizada, con un valor de -4.22.

Finalmente, el tiempo se añade para evaluar de manera general la eficiencia de cada red, teniendo que el menor tiempo de ejecución fue para la máquina de soporte vectorial, seguida de poco por la red de función base radial programada con regresión generalizada, donde ambas tomaron en su ejecución menos de 1 décima de segundo, dando el peor tiempo para la red convolucional siendo éste de 14.38, demasiado grande en comparación al resto, con el hecho de que la información con que se alimentó la red fue poca hace pensar que el tiempo en un caso más robusto de información puede ser menos eficiente, aunque se siguen hablando de segundos para estos casos de estudio.

Haciendo un análisis general de lo observado los mejores resultados fueron obtenidos por la red convolucional, sin embargo, el tiempo de ejecución fue demasiado grande en comparación al resto, mientras que las diferencias entre los errores y los coeficientes de determinación no fue significativamente amplia por lo que se podría desplazar la red convolucional y seleccionar como ejemplo la red de función base radial de regresión generalizada o el mapa autoorganizado como posibles selecciones, sus errores fueron mayor a la CNN pero cercanos, mientras que el tiempo fue significativamente menor en ambos casos, sobre todo con la RBFN de regresión generalizada, no se descarta CNN porque el tiempo sigue siendo en segundos, es decir, a pesar de ser alto en comparación al resto de redes, no presenta un problema computacional o de retrasos mayor para VERDUMEX. Aunque la selección de la red será adaptable de acuerdo al próximo caso de estudio.

Análisis de toneladas cosechadas de jitomate.

Para finalizar los análisis con redes neuronales se presentan las toneladas de jitomate cosechadas para dos tipos distintos de plantas, el primero con un período de 15 semanas, el segundo con 30 semanas, siendo series bastante cortas de información y no teniendo más información para dicho período de tiempo se considera usar una red neuronal recurrente para su análisis, la cual toma justamente información pasada sobre la misma variable para realizar la predicción, obteniendo así la siguiente predicción de cosecha:




Figura 47 Predicción de toneladas cosechadas para 15 semanas.

La Figura 47 muestra el ajuste obtenido por la red neuronal para las toneladas de jitomate cosechadas en un período de 15 semanas. Por otro lado, la Figura 48 muestra el ajuste hecho para el período de cosecha de 29 semanas. Ambas redes ajustadas de acuerdo a los datos que facilitó VERDUMEX sobre las cosechas de 2 especies distintas de jitomate.




Figura 48 Predicción de toneladas cosechadas de jitomate (29 semanas).

Para hacer un buen análisis y comparación se realiza el cálculo de algunos estadísticos para evaluar el ajuste de ambos casos, información encontrada en la Tabla 7.

Semanas de cosecha	Error absoluto	MSE	R ²	Sesgo	Tiempo
15	0.7835	1.7982	0.9024	-0.2252	1.1629
29	1.4268	3.4910	0.8780	-0.0576	0.1965

Tabla 7 Errores y tiempo de RNN para cosechas.

La Tabla muestra el error absoluto, el error mínimo cuadrado (MSE), el coeficiente de determinación (R^2), el sesgo y el tiempo obtenidos de la predicción para ambas especies de jitomate (de 15 semanas de cosecha y de 29 semanas), correspondientes a las imágenes 47 y 48 mostradas anteriormente. Como se había mencionado predicciones realizadas por medio de las redes neuronales recurrentes, mostrando de manera general una buena predicción con un error bajo y un coeficiente de determinación, para ambos casos, bastante cercano a 1 lo cual indica que el modelo realizado por la red neuronal si está acercando las predicciones a lo real, con tiempos bastante bajos, pudiendo hacer ajustes a la red para acercar aún más el modelo a la realidad, sin embargo, dado que solo se analiza un año de cosechas para cada tipo de jitomate se busca no sobre ajustar la red, de manera que la red neuronal si esté prediciendo y no solo memorizando los datos que ya tiene, por esto aunque es posible aumentar el coeficiente de determinación hasta 0.97 para la cosecha de 29 semanas y hasta 0.95 para la cosecha de 15 semanas modificando la red neuronal se opta por dejar la configuración que arroja los promedios mostrados en la Tabla 7 para que si se puedan realizar predicciones, pero no se comentan errores por sobre ajuste, pudiendo modificarse a futuro con nuevas entradas de entrenamiento.

Este mismo análisis se realiza por medio de los modelos ARIMA, contra los cuáles se evaluará la eficiencia de la red neuronal recurrente, la seleccionada para este caso en específico, teniendo lo siguiente:

Con un modelo de regresión polinomial se obtiene para la especie de jitomates con cosecha de 29 semanas el modelo mostrado en la Figura 49.




Figura 49 Modelo de regresión para cosecha de 29 semanas.

El modelo mostrado en la Figura tiene una R^2 de 0.955, lo cual indica que gran parte de la cosecha puede ser explicada por el modelo, el cual se expresa matemáticamente con la siguiente ecuación.

$$Cosecha = 3.8434t - 0.277t^2 + 0.0051t^3$$

Por otro lado, para el jitomate con período de cosecha de 15 semanas se tiene el modelo realizado por regresión no lineal mostrado en la siguiente ecuación.

$$Cosecha = e^{2.5392 - 0.0081t^2} + \varepsilon$$

El cual es observable dentro de la Figura 50, con un coeficiente de determinación de 0.788.



Figura 50 Modelo de regresión para cosecha de 15 semanas.

Comparando estos coeficientes de determinación contra los obtenidos por las redes neuronales se tiene que con la configuración que se seleccionó como final para la red neuronal, para las cosechas de 15 semanas se logró una mejor aproximación al modelo por la red neuronal recurrente con un valor de 90.24%, superior al obtenido por el modelo de regresión con valor de 78.8%, es decir, que el modelo encontrado por la red neuronal explica aproximadamente el 90% de la varianza de los datos, en este caso de las toneladas cosechadas para esta especie de jitomate, donde la diferencia entre ambos modelos es bastante significativa, aproximadamente con 12% entre ambas, concluyendo que tomar la red neuronal es una opción más precisa que el modelo ARIMA.

La segunda comparación se realiza para la especie de jitomate con cosecha de 29 semanas, teniendo aquí que el modelo de regresión ARIMA define la varianza en un 95.5%, siendo superior por aproximadamente 8% a la red neuronal que tiene 87.8%, mostrando así que el modelo de regresión es mejor para este caso. No obstante se tiene que considerar la flexibilidad de las redes neuronales a los problemas, dado que es posible ajustar y configurar la red para que se aproxime más al sistema, por medio de una de dichas configuraciones es posible alcanzar

una R^2 , promedio para 50 ejecuciones, de 0.96, mostrando que es posible superar al modelo ARIMA, sin embargo, esta configuración se deja temporalmente de lado como precaución a un sobre ajuste hasta que se cuente con mayor información para validar y evitar la problemática planteada, pero demostrando que las redes neuronales si tienen la capacidad de superar a los métodos tradicionales dada su maleabilidad.

Análisis fenológico del cultivo.

El análisis se cierra para la fenología retomando el último caso del capítulo 6 donde ya se está analizando un caso de la fenología del jitomate, tomando variables de importancia en el desarrollo fenológico que ayudan a predecir el número de frutos por planta relacionado estrechamente con la salud del jitomate y la cantidad de producto que se podrá cosechar, con una sola red neuronal probada y por los pocos datos para modelar, se logró explicar el sistema en un 87%, esto señala un buen modelo y confirma lo dicho en el párrafo anterior, además de ser esto transferible y demuestra que se puede ir modificando breve y rápidamente para modelar las características específicas de cada caso y obtener modelos de calidad para predecir y mejorar las situaciones agrícolas.

Conclusión

A lo largo del documento se implementaron las redes neuronales con distintas arquitecturas y configuraciones con el fin de analizar como trabajaban para predecir distintas variables de un mismo caso de estudio, como ejemplo de esto se tiene el primer análisis realizado a variables climáticas de distintas partes del estado de Aguascalientes donde se mostró como afecta el tipo de variable, su varianza, la cantidad de muestras y la cantidad de variables a los resultados obtenidos, logrando un primer acercamiento a las redes neuronales trabajadas para la tesis.

El objetivo de la tesis es el utilizar la inteligencia artificial como herramienta en los cultivos para mejorar las cosechas, así como la hipótesis donde se planteaba si las redes neuronales presentaban una mejora respecto a los métodos clásicos como el ARIMA.

Por medio de las distintas pruebas desarrolladas con los datos obtenidos de VERDUMEX para el cultivo y cosecha de jitomate se logra observar en un primer instante que la predicción si es de suma importancia para trabajar dentro de sistemas de agricultura, puesto que permite que se realice una toma de decisiones basada en información de calidad dada por los cultivos y la experiencia de los agrónomos al mando en VERDUMEX, la importancia de mantener un buen equilibrio para lograr la mejorar calidad en los productos disminuyendo los errores y desechos de los procesos, donde herramientas ya sean tradicionales como los modelos ARIMA como los resultantes de la inteligencia artificial si son necesarios. En VERDUMEX se plantea para esta primer tesis la predicción de variables climáticas y de toneladas cosechadas de jitomate, sin embargo, dentro de la fenología del jitomate, e incluso de cualquier otra planta hay muchas variables que afectan al desarrollo biológico de las especies, donde existe un cuidadoso control para mantener el equilibrio en procesos naturales que se convierten en procesos relevantes para la economía y sostenibilidad a futuro, como se menciona dentro de algunos objetivos a distintos niveles a favor de la ecología, la economía, la salud y la alimentación, por lo cual la complejidad crece y las herramientas predictivas

TESIS TESIS TESIS TESIS TESIS

toman un rol aún más importante para la evaluación integral de los diversos elementos relacionados, sobre todo cuando hay una gran diversidad de riesgos para estos.

La comparación entre resultados obtenidos permite observar que realmente las redes neuronales son una gran opción en términos de predicción, ya que no sólo logran buenos resultados o aproximaciones bastante precisas, sino que además, representan una opción bastante rápida y sobre todo maleable y ajustable a las necesidades de la problemática, esto representa en el caso de los cultivos de jitomate una gran ventaja para adaptar soluciones a las necesidades del productor, en este caso VERDUMEX, a factores externos como el cambio climático, e incluso adaptarlo fácilmente para el análisis de otras especies o cultivos.

Esta afirmación se puede realizar en base a las comparaciones realizadas, para el último caso donde se presenta, dentro de la discusión de resultados, el ajuste de modelos para las toneladas cosechadas de jitomate. En uno de los casos la red neuronal recurrente superó en gran medida al ajuste logrado por el modelo ARIMA, teniendo un 12% de diferencia entre ambas, con un 90% a favor de la RNN para coeficiente de determinación, donde por medio de las distintas Tablas se observa un tiempo bastante bajo de ejecución y errores bajos, que hablan sobre la precisión de la red, para el otro caso, si bien la red neuronal estuvo por debajo del modelo ARIMA por 8%, con un 87% para la red neuronal y un 95% para el modelo ARIMA, de valores de R^2 , la red neuronal permitió ser lo suficientemente maleable para mejorar las aproximaciones hechas en ambos casos, demostrando que son un método bastante eficiente y útil para el análisis de las variables trabajadas en este tipo de análisis.

Además las redes neuronales muestran una gran variedad de arquitecturas que les permiten acercarse más al modelo real del sistema que se trabaje, como muestra de ello la predicción desarrollada a las variables climáticas para ambos invernaderos del caso de estudio, donde se muestran distintas redes neuronales que permiten hacer una comparación y selección acorde a las necesidades del problema, en dicho caso se opta por señalar a la red neuronal de función base radial y regresión

generalizada como la mejor opción en términos de eficiencia para el caso, dado que tenía para ambos casos unos de los errores más bajos manteniendo siempre un tiempo muy bajo y altamente competitivo con el resto de redes neuronales, caso contrario a las redes convolucionales que si bien mostraban buenos resultados perdían en términos de rapidez dejándolas de manera global un poco por debajo de la red de regresión generalizada. A su vez se demostró con el cambio de variables a analizar la ventaja de las redes neuronales, donde se seleccionó una red neuronal recurrente, que no había sido competitiva en cuanto a predicción de variables climáticas, como la opción más adecuada para predicción de toneladas cosechadas de jitomate, dada la escasez de datos para trabajar contando únicamente los propios valores de cosechas de años pasados.

Esto demuestra a su vez el impacto positivo que pueden tener las redes neuronales dentro de la predicción fenológica al poder ajustar rápidamente y ejecutar predicciones para distintas situaciones dentro del cultivo, lo cuál permitirá que el agricultor, en este caso VERDUMEX, optimice sus procesos mediante la implementación de tecnologías.

Glosario

FAO.

Organización de las Naciones Unidas para la Alimentación y la Agricultura.

Fenología.

Tomando la definición de la Real Academia Española, *“La fenología es el estudio de los fenómenos biológicos en relación con el clima, particularmente en los cambios estacionales”* (RAE, 2011). Resulta de la combinación de las palabras *logos* y *phainomenon*, ambas provenientes del griego, teniendo así que es el estudio de la manifestación, donde se observan y analizan los diversos fenómenos biológicos que ocurren de acuerdo a los cambios estacionales.

La importancia de la fenología como ciencia está en su función como herramienta para conocer los efectos del cambio climático, un ejemplo de esto sería la migración de ciertas especies de aves bajo ciertas características climáticas que coinciden con estaciones del año, o bien cuando los árboles que dejan caer sus hojas cuando comienza el otoño. Al hablar de que estudia los fenómenos biológicos hace referencia a los distintos reinos de los seres vivos, pero para efectos de este proyecto se tomará la rama correspondiente de la fenología que se enfoca al reino vegetal.

Fitofenología.

Ésta es una de las dos ramas de la fenología, dedicada al estudio de los efectos climáticos en el desarrollo de las plantas. Como se describe por la RAE: “Estudio de los fenómenos biológicos en relación con el clima” (RAE, 2011). Pero, ¿qué implica estudiar estos efectos? pues bien, permite que se analicen y conozcan puntos importantes en el ciclo de vida de las plantas tales como la germinación, la floración o su muerte, solo por mencionar algunas, en conjunto con todos los aspectos que influyen sobre ellas incluyendo entre estos los factores climáticos como lo son las

precipitaciones o los rayos del sol, y microorganismos como ejemplo de algunos factores vivos que intervienen.

Ahora, la fenología, y más específicamente la fitofenología, permite que se tengan conocimientos sobre las distintas especies de plantas logrando que se utilice como herramienta en el control y la mejora de la producción de frutos que se utilizan como alimento, solo por dar un ejemplo, mientras que en la actualidad su relevancia se ve incrementada por el daño climático. El cómo se relacionan ambas es muy sencillo, que pasa en un planeta cambiante con climas que pueden resultar extremos y muchas veces completamente impredecibles como sequías o inundaciones, si bien la fenología ha sido importante por diversas razones desde hace mucho tiempo, con estos factores resulta importante comprenderla aún más para poder tomar medidas en pro del medio ambiente, en este caso de la producción y los cultivos de diversas especies en búsqueda de disminuir pérdidas, manteniendo y mejorando los cultivos, con la información que se tiene de la fenología se pueden implementar de manera adecuada, por ejemplo, un ajuste en los niveles del agua o en los nutrientes añadidos a la tierra.

Existe una gran variedad de plantas, cada una de ellas con aspectos específicos de su especie, diferentes ciclos de vida (como el caco con un ciclo de vida largo contra una lechuga cuyo ciclo es bastante corto), diferentes necesidades nutricionales, diferentes necesidades climáticas, por ello es importante distinguir las especies a trabajar, para conocer con esto sus necesidades específicas y trabajar sobre ellas el proyecto, ajustando así los parámetros del evaluador a los parámetros propios de la planta en cuestión.

Inteligencia artificial.

La inteligencia artificial es donde se plantean o incluyen todos aquellos inventos con la capacidad de recrear las habilidades humanas ya sean de lógica o de acción, dado con esto pie a numerosas clasificaciones de acuerdo a sus características tales como: aprender, percibir y razonar, características que en conjunto permiten

simular el pensamiento humano y recreando por tanto su actuar. En la actualidad la inteligencia artificial se encuentra de manera más común en herramientas o aparatos del uso cotidiano, dentro de sus ventajas se encuentra el automatizar y potencializar las capacidades del ser humano.

Red neuronal.

Es un método de inteligencia artificial que trata de analizar y procesar la información de la manera en que lo hace un cerebro humano, con usos como la medicina, marketing, previsión y predicción.

SAGARPA.

A nivel nacional es la Secretaría de Agricultura y Desarrollo Rural, existe para fomentar el desarrollo agropecuario como actividad económica.
(<https://www.gob.mx/agricultura/que-hacemos>)

SEDRAE.

La SEDRAE es una secretaría dentro del estado de Aguascalientes, sus siglas vienen de Secretaría de Desarrollo Rural y Agroempresarial. Es una secretaría que busca fomentar la aplicación de programas que ayuden a aumentar la productividad del campo, fortaleciendo el sector agroalimentario desde una perspectiva de responsabilidad ambiental y social **(como referenciar: <https://www.aguascalientes.gob.mx/sedrae/>).**

SI. FE. SOJA.

TESIS TESIS TESIS TESIS TESIS

SIFESOJA es el nombre dado al modelo de simulación de fenología de soja, dentro del proyecto Modelo de simulación de fenología de soja (SI. FE. SOJA), (Peltzer & Peltzer, 2013).



Referencias

¿Qué es un árbol de decisión? | IBM. (n.d.). [https://www.ibm.com/mx-es/topics/decision-](https://www.ibm.com/mx-es/topics/decision-trees#:~:text=Un%C3%A1rbol%20de%20decisi%C3%B3n%20es,nodos%20internos%20y%20nodos%20hoja)

[trees#:~:text=Un%C3%A1rbol%20de%20decisi%C3%B3n%20es,nodos%20internos%20y%20nodos%20hoja](https://www.ibm.com/mx-es/topics/decision-trees#:~:text=Un%C3%A1rbol%20de%20decisi%C3%B3n%20es,nodos%20internos%20y%20nodos%20hoja).

Ayuda. INEGI. (n.d.).

<https://cuentame.inegi.org.mx/ayuda/estadistica.aspx#:~:text=La%20Estad%C3%ADstica%20es%20una%20rama,el%20fin%20de%20obtener%20conclusiones>.

Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). Wiley.

Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and regression trees*. Chapman and Hall/CRC.

Buhmann, M. D. (2003). *Radial Basis Functions: Theory and Implementations*. Cambridge University Press.

De Agricultura Y Desarrollo Rural, S. (n.d.). ¿Cómo beneficia la agricultura a las familias mexicanas? [gob.mx. https://www.gob.mx/agricultura/es/articulos/como-beneficia-la-agricultura-a-las-familias-mexicanas](https://www.gob.mx/agricultura/es/articulos/como-beneficia-la-agricultura-a-las-familias-mexicanas)

De Información Agroalimentaria Y Pesquera, S. (n.d.). Mapa de Riesgos del Sector Agroalimentario. [gob.mx. https://www.gob.mx/siap/documentos/mapa-de-riesgos-del-sector-agroalimentario](https://www.gob.mx/siap/documentos/mapa-de-riesgos-del-sector-agroalimentario)

Desarrollo Sostenible. (2017, November 13). La Asamblea General adopta la Agenda 2030 para el Desarrollo Sostenible. <https://www.un.org/sustainabledevelopment/es/2015/09/la-asamblea-general-adopta-la-agenda-2030-para-el-desarrollo-sostenible/#>

TESIS TESIS TESIS TESIS TESIS

Escobar R., L., Váldez H., J., & Zapata C., S. (2010). Redes Neuronales Artificiales en predicción de Series de Tiempo. Una aplicación a la Industria. <https://www.palermo.edu/ingenieria/Pdf2010/CyT9/02.pdf>

Flores-Magdaleno, H., Flores-Gallardo, H., & Ojeda-Bustamante, W. (2014). Predicción fenológica del cultivo de papa mediante tiempo térmico. *Revista Fitotecnia Mexicana*, 37(2). <https://doi.org/10.35196/rfm.2014.2.149>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.

Gujarati, D. N. (2009). *Basic Econometrics* (5th ed.). McGraw-Hill.

Guo, Y., Fu, Y., Hao, F., Zhang, X., Wu, W., Jin, X., Robin Bryant, C., & Senthilnath, J. (2021). Integrated phenology and climate in rice yields prediction using machine learning methods. *Ecological Indicators*, 120. <https://doi.org/10.1016/j.ecolind.2020.106935>

Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson Education.

Iberdrola Corporativa. (n.d.). *¿Somos conscientes de los retos y principales aplicaciones de la Inteligencia Artificial?* Iberdrola. <https://www.iberdrola.com/innovacion/que-es-inteligencia-artificial>

Introducción a las funciones de activación en las redes neuronales. (2024, 15 abril). Datacamp. Recuperado 1 de septiembre de 2024, de <https://www.datacamp.com/es/tutorial/introduction-to-activation-functions-in-neural-networks>

Jorquera-Fontena, E., & Orrego-Verdugo, R. (2010). Impacto del calentamiento global en la fenología de una variedad de vid cultivada en el sur de Chile. *Agrociencia*, 44(4).

Macías, M. E. R., Riojas-Garza, A., Contreras-Estrada, D., & Martínez-Ezquerro, J. D. (2018). Análisis bayesiano. Conceptos básicos y prácticos para su interpretación y uso. *Deleted Journal*, 65(3), 285–298. <https://doi.org/10.29262/ram.v65i3.512>

Mandy. (2022, July 1). Bugambilia: cómo cuidarla para que crezca y florezca | Plantify. Plantify. <https://plantify.mx/blog/guia-plantas/bugambilia-cuidados/>

Matich, D. J. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. Historia.

Mitchell, T. M. (1997). Machine Learning^{**.} McGraw-Hill

Moran, M. (2024, January 30). Hambre y seguridad alimentaria - Desarrollo Sostenible. <https://www.un.org/sustainabledevelopment/es/hunger/>

Moran, M. (2024a, January 26). Consumo y producción sostenibles - Desarrollo Sostenible. <https://www.un.org/sustainabledevelopment/es/sustainable-consumption-production/>

Moreno Gutiérrez, S. S., Toriz Palacios, A., Lopez Perez, S., & Ruiz Vanoye, J. A. (2019). Evaluador inteligente de daño fenológico en la planta de trigo. CIENCIA ergo sum, 26(3). <https://doi.org/10.30878/ces.v26n3a7>

Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO). (2000). El estado mundial de la agricultura y la alimentación 2000. Roma: FAO.

Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO). (2017). El estado mundial de la agricultura y la alimentación 2017: Aprovechar la tecnología para afrontar el cambio climático. Roma: FAO.

Ortega-Farías, S. O., Lozano, P., Moreno, Y., & León, L. (2002). DESARROLLO DE MODELOS PREDICTIVOS DE FENOLOGÍA Y EVOLUCIÓN DE MADUREZ EN VID PARA VINO CV. CABERNET SAUVIGNON Y CHARDONNAY. Agricultura Técnica, 62(1). <https://doi.org/10.4067/s0365-28072002000100003>

Parada Molina, P. C., Cervantes Pérez, J., Ruiz Molina, V. E., & Cerdán Cabrera, C. R. (2020). Efectos de la variabilidad de la precipitación en la

fenología del café: caso zona cafetalera Xalapa-Coatepec, Veracruz, Mex. Ingeniería y Región, 24. <https://doi.org/10.25054/22161325.2752>

Parra, S. (2024, February 7). 2023 fue el año más caluroso en décadas. Y 2024 podría ser peor. [www.nationalgeographic.com.es. https://www.nationalgeographic.com.es/medio-ambiente/2023-fue-ano-mas-caluroso-decadas-2024-podria-ser-peor_21360](https://www.nationalgeographic.com.es/medio-ambiente/2023-fue-ano-mas-caluroso-decadas-2024-podria-ser-peor_21360)

Peltzer, H. F., & Peltzer, N. G. (2013). Modelo de simulación de fenología de soja (SI.FE.SOJA): una herramienta útil para evitar el estrés hídrico durante el periodo crítico. Congreso Argentino de AgroInformática.

RAE. (2011). Real Academia Española. En Madrid.

Saz Peiró, P., & Ortiz Lucas, M. (2007). Fisiología y Bioquímica en el ayuno. Medicina Naturista, 1(1), 13-22.

SPSS Statistics Subscription - Classic. (n.d.). <https://www.ibm.com/docs/es/spss-statistics/saas?topic=forecasting-introduction-time-series>

United Nations. (n.d.). Alimentación | Naciones Unidas. <https://www.un.org/es/global-issues/food#:~:text=Seg%C3%BAAn%20la%20edici%C3%B3n%202023%20de l,personas%20en%20comparaci%C3%B3n%20con%202019>.

Valdez-Torres, J. B., Soto-Landeros, F., Osuna-Enciso, T., & Báez-Sañudo, M. A. (2012). Modelos de predicción fenológica para maíz blanco (*Zea mays* L.) y gusano cogollero (*Spodoptera frugiperda* J. E. Smith). Agrociencia, 46(4).